

Capítulo III – Análise Comparativa entre Controladores PI e PI-Neural em Sistemas Térmicos

John Everson Rodrigo Mello Jayme ⁸

Renato Kazuo Miyamoto ⁹

Leonardo Yuji Ishizaki ¹⁰

RESUMO

Os controladores PI são amplamente empregados no setor industrial. No entanto, enfrentam desafios significativos no controle de sistemas com consideráveis atrasos de tempo e na busca por ganhos ideais. Essa abordagem requer modelos matemáticos e sua robustez é afetada por variações nos parâmetros do processo. Este estudo propõe uma análise comparativa entre um controlador PI convencional e um controlador PI-Neural aplicado a um sistema térmico de uma planta didática Smar PD3-P. A função de transferência da planta foi determinada por meio de experimentos de aplicação da resposta ao degrau de tensão. Após a determinação da função de transferência, um controlador PI foi sintonizado utilizando o método de Dorf e Bishop. Foram realizados ensaios experimentais no sistema com mudanças bruscas na temperatura de referência para avaliar o desempenho do controle PI. Posteriormente, um controlador PI-neural foi implementado, utilizando uma estratégia de sintonia que não necessita de modelagem do sistema. Os resultados demonstraram uma melhoria de aproximadamente 15% no tempo de estabilidade e uma melhor linearidade em comparação com o controle clássico PI.

Palavras-chave: PI-Neural. Controle clássico. Métodos de sintonia. Identificação de Sistemas.

Comparative Analysis Between PI and PI-Neural Controllers in Thermal Systems

ABSTRACT

PI controllers are widely employed in the industrial sector. However, they face significant challenges in controlling systems with considerable time delays and in the search for optimal gains. This approach requires mathematical models, and its robustness is affected by variations in process parameters. This study proposes a comparative analysis between a conventional PI controller and a PI-Neural controller applied to a thermal system of a Smar PD3-P didactic plant. The transfer function of the plant was determined by means of experiments of application of the response to the stress step. After determining the transfer function, a PI controller was tuned using the Dorf and Bishop method. Experimental tests were carried out on the system with sudden changes in the reference temperature to evaluate the performance of the PI control. Subsequently, a PI-neural controller was implemented, using a tuning strategy that does not require system modeling. The results demonstrated an improvement of approximately 15% in stability time and a better linearity compared to the classic PI control.

Key words: PI-Neural. Classic control. Tuning methods. Systems Identification.

⁸ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

⁹ Doutor em Engenharia Elétrica. UniSenaiPR - Campus Londrina.

¹⁰ Mestre em Engenharia Elétrica UniSenaiPR - Campus Londrina.

1 INTRODUÇÃO

O setor industrial apresenta constante atualização de seus processos produtivos em busca de melhoria em sua produtividade para se manter competitivo no mercado. Nesse cenário, o controle e a automação de processos é uma das áreas fundamentais para aumentar a rentabilidade das unidades, e pode contribuir significativamente no tempo e no desempenho desses processos (CAMPOS; TEIXEIRA, 2010).

A automação de processos fundamenta-se na aplicação de tecnologia para otimizar e controlar tarefas de forma eficiente e precisa, utilizando controladores. Os controles se dividem em sistemas de malha aberta e malha fechada. Um sistema de malha aberta é um sistema de controle onde a saída não é comparada com a referência para fazer ajustes durante o processo. Em um sistema de malha fechada ocorre uma realimentação que compara a saída com a entrada através de um valor de referência tornando o controle mais preciso e menos sensível (GARCIA, 2021).

O controle em malha fechada do tipo PI é um método tradicional de controle no qual são definidos os ganhos proporcional e integrativo, com o objetivo de permitir que o sistema opere dentro de uma dinâmica aceitável (ASTROM; HAGGLUNG, 1995). No entanto, essa estratégia de controle apresenta dificuldades de ajuste de seus parâmetros de sintonia, justificado pelo mau dimensionamento de projeto ou devido a inexperiência de seus operadores.

De acordo com Bialkowski (1993), Ender (1993), McMillan (1995) e Hersh e Johnson (1997), o setor industrial de papel e celulose possui mais de 2000 malhas de controle. Desse total, apenas 20% possuem um bom funcionamento e 80% possuem desempenho insatisfatório. Dentre os que possuem desempenho não satisfatório, 30% são devido a ajustes indevidos do controlador; 30% devido a problemas de válvulas de controle; e 20% devido a problemas de projeto de processo ou sistema de controle (YU, 2013).

Segundo Ender (1993), na indústria de processos um total de 30% das malhas opera no modo manual, 20% dos controladores usam ajustes de fábrica e 30% apresentaram problemas no sensor e válvula de controle. Nas indústrias de processos químicos metade das válvulas necessitam de manutenção precoce devido aos ajustes errôneos (McMILAN, 1994). Na indústria de manufatura de processos, engenheiros e

gerentes citaram o ajuste do controlador como um problema difícil (HERSH; JOHNSON, 1997; YU, 2013).

Embora amplamente aplicados, os controladores PI frequentemente apresentam respostas transitórias deficientes e podem não fornecer robustez adequada em relação às variações nos parâmetros do processo. No cenário atual, as tecnologias de otimização de controles estão ganhando destaque no campo da inteligência artificial, como por exemplo as Redes Neurais Artificiais (RNAs) (FERREIRA; DE MOARES, 2016). Embora os sistemas de controle baseados em RNAs tenham sido extensivamente testados em simuladores computacionais, sua implementação em testes práticos ainda apresenta desafios significativos.

Uma rede neural é um sistema projetado para emular a forma como o cérebro humano executa tarefas específicas ou responde a estímulos de interesse (HAYKIN, 2001). Ela pode ser considerada um sistema adaptativo que fundamenta-se em um modelo matemático inspirado na estrutura de seres vivos, oferecendo uma maneira simplificada de emular o funcionamento do cérebro humano em computadores (FERREIRA; DE MOARES, 2016).

A motivação central deste trabalho consiste em realizar uma análise comparativa entre um controlador PI convencional e um controlador PI-Neural aplicado a um sistema térmico de uma planta didática Smar PD3-P. Primeiramente, a função de transferência da planta foi obtida por meio da resposta ao degrau a uma entrada de tensão. Após a obtenção da função de transferência, um controlador PI foi ajustado usando a abordagem proposta por Dorf e Bishop. Ainda, foi implementado um controlador PI-neural que empregou uma estratégia de sintonia que dispensou a necessidade de modelagem do sistema.

2 FUNDAMENTAÇÃO TEÓRICA

Atualmente, os sistemas de controle automático estão amplamente presentes em diversos setores industriais, como qualidade de produtos, linhas de montagem, máquinas operatrizes, tecnologia espacial, defesa, transporte, energia e robótica. Eles desempenham um papel crescente na evolução da civilização e tecnologia modernas, influenciando praticamente todos os aspectos de nossas atividades cotidianas (Faccin, 2004).

Com base nos dados coletados, os sistemas de controle utilizam algoritmos e lógica de controle para tomar decisões e emitir comandos para dispositivos e atuadores, como válvulas, motores, aquecedores etc., a fim de ajustar e manter as variáveis do processo dentro de faixas desejadas. O controle em malha fechada do tipo PI é um método clássico de regulação no qual os ganhos proporcional e integral são ajustados com o intuito de garantir que o sistema funcione dentro de uma resposta dinâmica adequada.

2.1. Controlador PI convencional

O controle Proporcional-Integral (PI) representa uma das estratégias de controle mais amplamente reconhecidas. Sua eficácia prontamente comprovada, aliada à sua simplicidade de implementação, estabelece-o como uma das abordagens mais comuns nos processos industriais de primeira ordem. O conceito fundamental à aplicação de um controlador PI precede na leitura de um sensor, na comparação desse valor com uma referência, na posterior avaliação da resposta do atuador por meio dos cálculos dos componentes proporcional e integral, resultando na combinação desses dois elementos para estabelecer a saída desejada, conforme a equação (1) (Oliveira, 2014).

$$u(t) = k_p e(t) + \frac{k_p}{T_i} \int_0^t e(t) dt \quad (1)$$

onde:

$u(t)$ é a saída do controlador;

K_p é o ganho proporcional;


$e(t)$ é o erro;

T_i é o tempo integrativo.

Segundo Ogata (2003), na maioria das vezes, os controladores usados nas indústrias são configurados no local, onde se observa como o sistema responde. Quando essas configurações são feitas por operadores, os resultados podem ser afetados por falta de atenção para certas situações, falta de reconhecimento de fatores externos que podem afetar o controle ao longo do tempo e imprecisões nas ações, o que pode fazer com que as configurações não funcionem bem.

Devido a essa necessidade, diversos métodos de sintonia têm sido divulgados na literatura. Conseqüentemente, têm surgido abordagens automáticas para a proposição de regras de sintonia. O controlador PI atua em malha fechada em que a variável a ser controlada é continuamente medida por um sensor localizado no processo. Essa medição é então fornecida ao controlador, que gera um sinal de erro atuante, representando a diferença entre a saída atual e o valor de referência desejado (*setpoint*), conforme a Figura 1 (SILVA, 2021).

Figura 1 – Modelagem do controlador PI



Fonte: autoria própria (2023)

O controlador age com o objetivo de minimizar esse erro atuante, ajustando a entrada do sistema de acordo com a diferença identificada, buscando manter a saída o mais próxima possível do valor de referência.


2.2. Métodos de sintonia para controlador PI

A origem dos controladores PI remonta ao trabalho pioneiro de Ziegler e Nichols, em 1942, quando propuseram o primeiro método de ajuste para esses controladores. Esse método trouxe consigo uma transformação significativa na abordagem de controle de sistemas, estabelecendo as bases para a estabilização e controle de uma vasta gama de processos industriais. A notável eficácia desses controladores é evidenciada pelo fato de que podem ser aplicados com sucesso em aproximadamente 90% dos cenários industriais existentes (Saraiva, 2011, [s.d.]).

O Método de Ziegler-Nichols para sistemas de primeira ordem com a resposta ao degrau é uma técnica de sintonia clássica para controladores PI. Primeiro, um sinal de entrada degrau é aplicado ao sistema, e a resposta do sistema é observada. A curva de reação é analisada, representando a resposta do sistema ao longo do tempo, com foco no tempo de atraso (L) e no tempo de subida (T) conforme a Figura 2. Com base nesses parâmetros da curva de reação, podem ser aplicadas regras empíricas da Tabela de Ziegler-Nichols para determinar os valores iniciais do ganho proporcional

(Kp) e do tempo integral (Ti) do controlador PI. A escolha dos valores de Kp e Ti depende do grau de oscilação aceitável no sistema, com opções que variam de uma sintonia conservadora a uma sintonia mais agressiva.


Figura 2 – Método de Ziegler Nichols para curva de reação



Fonte: Ogata, Katsuhiko, 2010

O método CHR desenvolvido em 1952 por K. L. Chien, J. A. Hrones e J. B. Reswick, sendo o pioneiro a modelar um sistema de primeira ordem com tempo morto, propõe dois critérios de desempenho, a resposta rápida sem sobrevalor (CHR- 0%) e outra com 20% sobrevalor (CHR – 20%), possui características diferenciadas tanto na mudança de setpoint quanto na perturbação da carga (Saraiva,2011, [s.d.]). Já Broída sugere a modelagem de um processo de *n*-ésima ordem através da utilização de uma curva de primeira ordem com tempo de atraso. Nesse contexto, esse modelo representa uma função de transferência de primeira ordem, onde se observa um intervalo de tempo entre os pontos A (representando 28% da amplitude) e B (representando 40% da amplitude), conforme Figura 3.

Figura 3 – Método de Broída para Curva de reação



Fonte: <http://www.abenge.org.br/cobenge/legado/arquivos/5/Artigos/128939.pdf>

A Tabela 1 é um registro dos cálculos efetuados com relação aos métodos de sintonia adotados. Especificamente, para a determinação dos valores de T e L, optou-se pelo método de Broída, uma decisão que se fundamenta na ausência de tempo morto nas curvas de reação.

Tabela 1 – comparativos de Métodos de sintonia

Método	Kp	Ti	Ki
Ziegler Nichols	$0.9*(T/L)$	$3*L$	Kp/Ti
Chien-Hrones-Reswick	$(0.6*T)/(K*L)$	$4*L$	Kp/Ti
Chien-Hrones-Reswick 20%	$(0.95*T)/(K*L)$	$1.4*T$	Kp/Ti
Dorf e Bishop	$0.6*(K)$		$(1.2*K)/T$

Fonte: autoria própria (2023)

As redes neurais têm emergido como uma alternativa promissora ao tradicional controle Proporcional-Integral (PI) em diversos contextos. Essa abordagem se baseia na capacidade das redes neurais artificiais de aprender a partir de dados e adaptar seu comportamento de acordo com o ambiente, tornando-as particularmente adequadas para sistemas complexos e não-lineares.

2.3. Redes Neurais Artificiais


Em sua forma mais ampla, uma rede neural é um sistema projetado para emular o modo como o cérebro aborda uma tarefa específica. Isso é tipicamente alcançado por meio da implementação de componentes eletrônicos ou da simulação computacional (FERREIRA; DE MOARES, 2016). Assim, as redes neurais artificiais podem ser definidas como um conjunto de ferramentas computacionais inspiradas no sistema nervoso de seres vivos (SILVA; SPATTI; FLAUZINO, 2010).

Em vez de depender de modelos matemáticos precisos, as redes neurais podem aprender a controlar um sistema através de um processo de treinamento, ajustando-se dinamicamente às variações e incertezas que podem desafiar o controle PI convencional. Isso permite o desenvolvimento de estratégias de controle mais adaptáveis e robustas, com potencial para melhorar o desempenho em uma ampla gama de aplicações, desde automação industrial até veículos autônomos e sistemas de controle de processos complexos.

2.3.1. Neurônio biológico

O processamento de informações no cérebro humano é governado por elementos processadores biológicos que operam em paralelo. A unidade fundamental do sistema nervoso cerebral é o neurônio, cuja função principal consiste na condução de impulsos, ou seja, estímulos elétricos. O neurônio é composto por três componentes principais: dendritos, responsáveis por receber estímulos de outros neurônios ou do ambiente externo; o corpo celular, encarregado de processar todas as informações provenientes dos dendritos, a fim de gerar um potencial de ativação que determina se o neurônio emitirá um impulso elétrico ao longo de seu axônio, conforme a Figura 4 (GOMIDE, 2012).

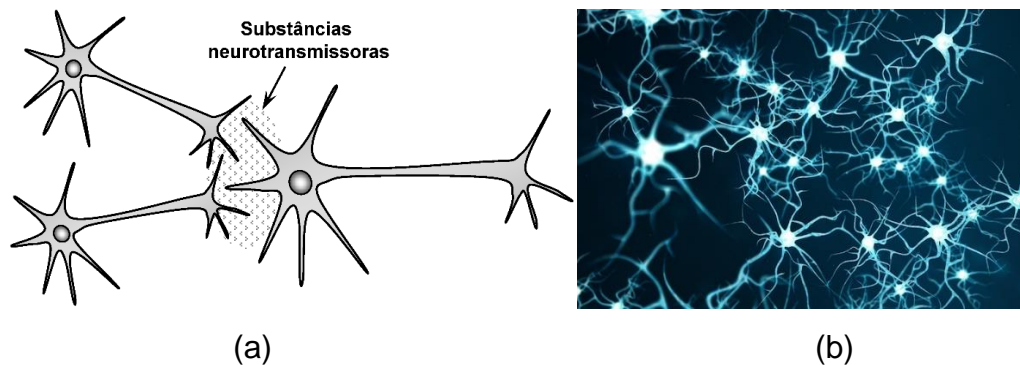
Figura 4 – Neurônio biológico



Fonte: SILVA; SPATTI; FLAUZINO (2010)

Os neurônios biológicos são responsáveis por todo o processamento executado e gerenciado pelo cérebro humano. Essas células nervosas são os blocos de construção do sistema nervoso e atuam na comunicação, transmissão de informações e coordenação das funções cerebrais. No entanto, é importante destacar que não há contato físico direto entre eles. A comunicação entre neurônios ocorre por meio de estruturas chamadas sinapses, imersas em substâncias neurotransmissoras, que permitem a transferência de informações de um neurônio para outro, conforme ilustra a Figura 5.

Figuras 5: Interconexão de neurônios: (a) substâncias neurotransmissoras; (b) neurônios biológicos interconectados




Fonte: (a) SILVA; SPATTI; FLAUZINO (2010); (b) freepik.com

As substâncias neurotransmissoras são responsáveis por ponderar a transmissão de impulsos elétricos entre os neurônios. Essas substâncias químicas, liberadas em resposta a estímulos elétricos, atuam na modulação da intensidade e na direção da transmissão de sinais nervosos.

2.3.2. Neurônio artificial

No contexto do modelo biológico, as influências transmitidas pelas conexões sinápticas são representadas no neurônio artificial por meio de um conjunto de pesos sinápticos (denominados $w_1, w_2 \dots w_n$). De maneira análoga, a importância de cada entrada individual (x_j) para o neurônio é determinada multiplicando-a pelo peso sináptico correspondente. Isso significa que todas as informações vindas de fora e recebidas pelo neurônio são consideradas, sendo a saída do neurônio artificial o resultado dessas ponderações das entradas, conforme a Figura 6 (GOMIDE, 2012).

Figura 6 - Neurônio artificial.



Fonte: SILVA; SPATTI; FLAUZINO (2010)

Um neurônio artificial é comumente representado matematicamente por meio de uma equação que descreve como ele combina suas entradas, aplica pesos a elas e, em seguida, passa o resultado por uma função de ativação. A equação matemática para um neurônio artificial é geralmente expressa da seguinte forma (SILVA; SPATTI; FLAUZINO, 2010).

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (2)$$

onde:

i é o número de entradas do neurônio;

w_i é o peso associado com a i -ésima entrada;

θ é o limiar de ativação associado ao neurônio;

x_i é a i -ésima entrada do neurônio;

u é a saída do neurônio.

A saída do neurônio pode ser calculada pela equação (3):

$$y = g(.) = g(u) \quad (3)$$

onde:

$g(.)$ é a função de ativação do neurônio.

A função de ativação $g(\cdot)$, é geralmente uma função não linear que introduz não linearidades no processo. Exemplos comuns de funções de ativação incluem a função sigmoide, a função tangente hiperbólica, a função degrau e a função linear. A escolha da função de ativação depende da tarefa e da arquitetura da rede neural.

O funcionamento de um neurônio artificial em redes neurais pode ser resumido em algumas etapas fundamentais. Primeiro, o neurônio artificial recebe um conjunto de valores, que representam as variáveis de entrada. Cada entrada é então multiplicada pelo seu peso sináptico correspondente, e essas multiplicações são somadas para obter o potencial de ativação (u) do neurônio. Esse potencial de ativação é uma combinação linear das entradas ponderadas pelos pesos, o que permite ao neurônio atribuir diferentes importâncias a cada entrada (HAYKIN, 2001).

Em seguida, o potencial de ativação é submetido a uma função de ativação apropriada. Essa função de ativação serve para limitar a saída do neurônio e introduzir não-linearidades no processo. Após a aplicação da função de ativação, o neurônio artificial produz uma saída que representa a resposta do neurônio às entradas e pesos

dados. Essa saída é então utilizada como entrada para neurônios subsequentes na rede neural ou pode ser a saída final da rede, dependendo da arquitetura da rede e da tarefa em questão (SILVA; SPATTI; FLAUZINO, 2010).

Em resumo, um neurônio artificial em redes neurais processa informações recebidas por meio de multiplicações ponderadas, calcula um potencial de ativação, aplica uma função não-linear de ativação e, finalmente, gera uma saída que é usada para realizar tarefas de processamento de dados, aprendizado, ou tomada de decisões (GOMIDE, 2012).

2.4. Modelagem matemática de sistemas térmicos

As equações diferenciais são fundamentais na teoria de controle, especialmente quando se trata de sistemas dinâmicos contínuos no tempo. Elas descrevem a relação entre as variáveis do sistema e como essas variáveis mudam com o tempo. Para sistemas lineares e invariantes no tempo (LTI), as equações diferenciais que descrevem o sistema podem ser representadas como equações diferenciais lineares de ordem n (OGATA, 2010).

Uma maneira inteligente de lidar com Equações Diferenciais Ordinárias (EDOs) de sistemas lineares é empregar a Transformada de Laplace. O conceito fundamental dessa transformada reside na substituição do operador diferencial d/dt ou d/dx por uma variável no domínio da frequência representada por 's'. Dessa forma, as equações diferenciais são convertidas em equações algébricas (Fischer Abati, 2020).

Os sistemas térmicos são sistemas físicos que envolvem transferência e conversão de energia térmica, e eles operam com base no princípio fundamental da lei da conservação de energia, também conhecido como o primeiro princípio da termodinâmica. Este princípio estabelece que a energia total de um sistema isolado permanece constante, ou seja, a energia não pode ser criada nem destruída, apenas transformada de uma forma para outra.

Em sistemas térmicos, a lei da conservação de energia é aplicada especificamente à energia térmica. Isso implica que a soma das energias térmicas internas do sistema, as trocas de calor com o ambiente e o trabalho realizado (ou

recebido) no sistema devem ser iguais. Em termos matemáticos, a lei da conservação de energia para sistemas térmicos pode ser expressa como:

$$C \cdot \frac{dT}{dt} = \sum q_{ent} - \sum q_{sai} \quad (4)$$

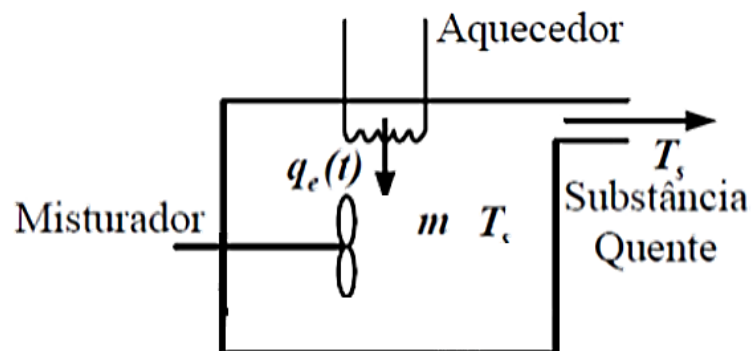
em que: q é a taxa de fluxo de calor, dT é a derivada da temperatura no tempo e C é a capacitância térmica. A resistência térmica (R_T) é a variação de temperatura pela variação na taxa de fluxo de calor:

$$R_T = \frac{T_s - T_e}{q_{sai}} \quad (5)$$

Para os casos em que não há vapor ou temperatura de entrada, conforme ilustra a Figura 7, considera-se que $T_e = 0$, e assim obtém-se:

$$R_T = \frac{T_s}{q_{sai}} \rightarrow q_{sai} = \frac{T_s}{R_T} \quad (6)$$

Figura 7 – modelagem sistema térmico



Fonte: Ogata, Katsuhiko, 2010

Aplicando os conceitos do princípio fundamental da lei da conservação de energia, tem-se:

$$C \cdot \frac{dT}{dt} = q_{ent} - q_{sai} \quad (7)$$

Substituindo a equação (6) em (7):

$$C \cdot \frac{dT_s}{dt} = q_{ent} - \frac{T_s}{R_T} \quad (8)$$

Simplificando:

$$R_T \cdot C \cdot \frac{dT_s}{dt} + T_s = R_T \cdot q_{ent} \quad (9)$$

Rearranjando o sistema, obtém-se:

$$T_s \cdot (R_T \cdot C \cdot s + 1) = R_T \cdot Q_{ent} \quad (10)$$

Assim, a função de transferência que representa o sistema térmico da Figura 7, pode ser obtido:

$$FT = \frac{T_s}{Q_{ent}} = \frac{R_T}{R_T \cdot C \cdot s + 1} \quad (11)$$

A modelagem matemática de sistemas térmicos é empregada em diversas áreas da engenharia, ciência e tecnologia devido à sua importância para o entendimento, projeto, otimização e controle de sistemas que envolvem a transferência de energia térmica.

3 METODOLOGIA

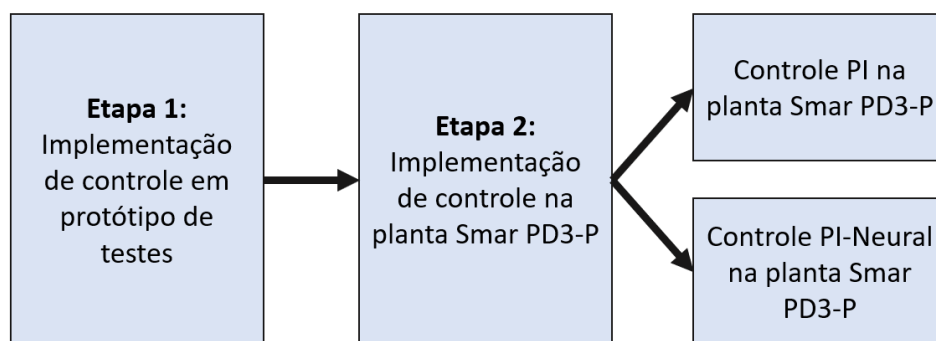
Neste trabalho foram conduzidos experimentos em uma planta didática de temperatura com o objetivo de avaliar métodos de sintonia de controladores. Os experimentos ocorreram em duas etapas, conforme ilustra a Figura 8. Na etapa 1, um protótipo foi utilizado para validar os métodos de controle, e um *script* de validação foi desenvolvido para compará-los. A função de transferência do protótipo foi determinada por meio de experimentos de aplicação de um degrau de tensão. A planta experimental foi configurada para coletar dados de temperatura, com dois conversores desempenhando funções específicas no sistema.

Em seguida, a função de transferência da planta foi identificada por meio de experimentos semelhantes aos do protótipo, mas com considerações específicas para

a água como meio de aquecimento. Após a determinação da função de transferência, o controle PI foi sintonizado com sucesso utilizando o método de Dorf e Bishop.

Na etapa 2, os procedimentos se repetiram, no entanto, aplicados a uma planta didática Smar PD3-P. A planta didática Smar PD3-P é um equipamento utilizado em treinamentos e cursos relacionados a automação industrial e engenharia. Ela é produzida pela empresa Smar, uma renomada fabricante de instrumentação e automação industrial. A PD3-P é um sistema projetado para fornecer uma plataforma de ensino prática, na qual os estudantes e profissionais possam aprender sobre diversos conceitos e técnicas relacionados à automação industrial e ao controle de processos.

Figura 8 – Etapas da metodologia



Fonte: Autoria Própria (2023)

A seguir, será detalhado os procedimentos metodológicos utilizados nesse trabalho.


3.1. Método de identificação utilizado

O método de identificação aplicado no sistema foi o de Broída, que traça a resposta do sistema de primeira ordem a curva superior, verificasse que a um intervalo em comum entre elas definidos em intervalos de tempo de 28 e 40% de K, o qual se define pelo intervalo de início da curva até seu limite máximo. O delta Y, os intervalos de T e L, são calculados pelas fórmulas demonstradas na Figura 9.

O método de Broida é amplamente utilizado para otimizar o desempenho de sistemas de controle. Ele se baseia em algoritmos de otimização que buscam ajustar os parâmetros do controlador de forma a atender aos requisitos de desempenho desejados. Esse método permite aprimorar a estabilidade, a resposta transitória e a rejeição de distúrbios em sistemas de controle, garantindo que o sistema atenda

eficazmente às demandas do processo controlado. Ao iterativamente ajustar os parâmetros do controlador e avaliar o impacto dessas mudanças no sistema, o método de Broida contribui para a melhoria contínua da eficácia dos controladores em uma variedade de aplicações industriais e de engenharia.

Figura 9 – Método de Broida

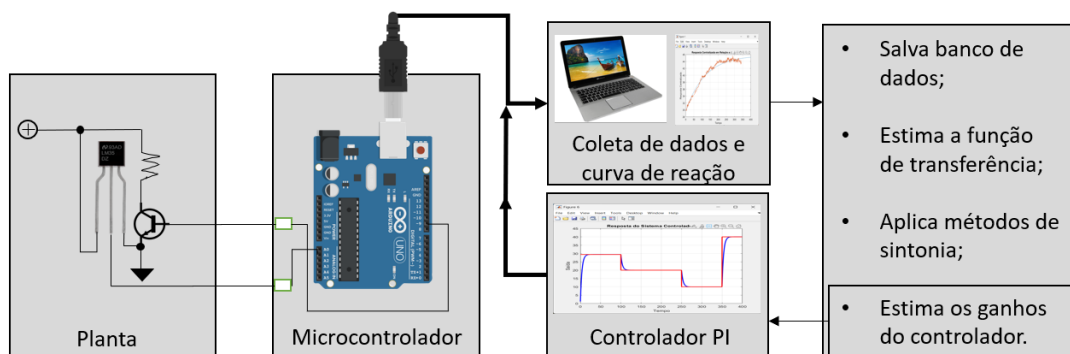


Fonte: Autoria Própria (2023)

3.2. Implementação de controle em protótipo de testes

Inicialmente, foram conduzidos testes em um protótipo como parte do processo de validação dos métodos de sintonia. Além disso, durante esse estágio, foi elaborado um script de validação dos métodos. Isso permitiu uma avaliação comparativa dos diferentes métodos de sintonia, a fim de identificar o mais eficaz. Essa abordagem foi adotada devido ao fácil manuseio e disponibilidade de deslocamento do protótipo, juntamente com a disponibilidade de acesso e flexibilidade de horários para o treinamento da rede neural.

Figura 10 – Fluxograma de implementação no protótipo




Fonte: Autoria própria (2023)

3.2.1. Determinação da Função de Transferência do protótipo

Com o propósito de identificar a função de transferência do protótipo foram conduzidos experimentos que consistiram na aplicação de um degrau de tensão conhecido por meio de um microcontrolador Atmel 328P da plataforma Arduino. Esse degrau de tensão foi aplicado para determinar a resposta da planta em malha aberta, incluindo sua curva de reação até atingir o regime permanente. Os dados resultantes dessas experimentações foram então submetidos a análises utilizando técnicas de avaliação de sistemas lineares. Esse procedimento possibilitou a dedução das relações matemáticas que descrevem o comportamento da planta em relação às variações nas entradas, conforme observa-se na Figura 11.

Figura 11 – Curva de reação do protótipo



Função de transferência

$$\frac{2.277}{118.1s + 1}$$

Protótipo


Fonte: autoria própria (2023)

3.2.2. Método de sintonia utilizado para o controle PI, Chien-Hrones-Reswick 20%

Ao escolher o método de teste ideal para o protótipo, realizou-se uma análise comparativa dos gráficos obtidos por meio do *script* de validação. A análise destacou o método de Chien-Hrones-Reswick com uma margem de 20% (Figura 12(b)), como a escolha mais eficaz e apropriada para o protótipo de teste real. Durante a avaliação dos métodos alternativos, observou-se que o método de Ziegler Nichols (Figura 12(a)), apresentou um *overshoot* inicial de 3 graus no início do degrau e de 1 grau após a

variação do *setpoint*. Além disso, a variável de temperatura demonstrou um atraso de inércia, persistindo na subida após o desligamento antes de se estabilizar.

Figura 12 – Aplicação de métodos de sintonia: (a) Método de Ziegler Nichols; (b) Chien-Hrones-Reswick 20%; (c) Método de Dorf e Bishop; (d) Chien-Hrones-Reswick.



Fonte: autoria própria (2023)

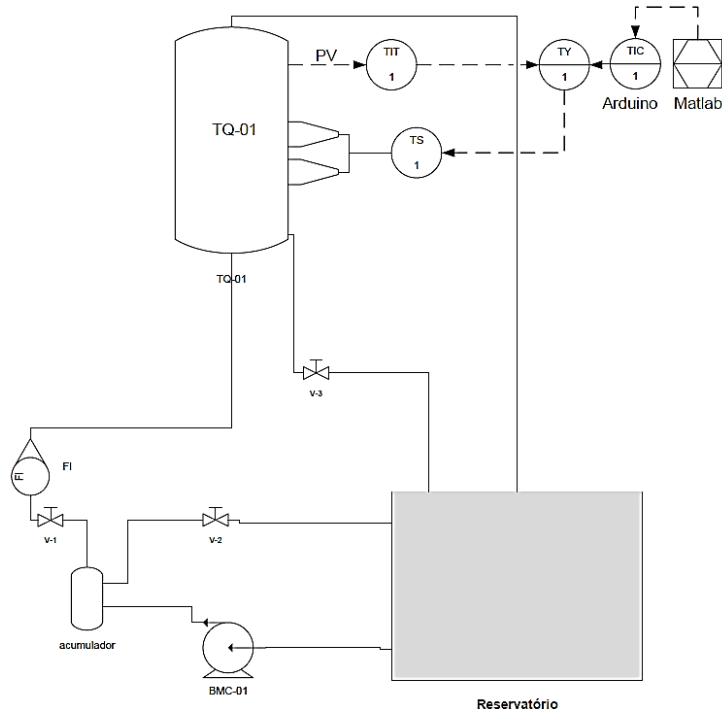
O método de Dorf e Bishop (Figura 12(c)) também revelou um *overshoot* inicial de 0,7 graus, que durou por um período de 100 segundos até a estabilização, com inércia residual na temperatura após o desligamento. A escolha do método de Chien-Hrones-Reswick 20% se fundamentaram na análise detalhada de sua resposta transitória satisfatória, evidenciada pela Figura 12(b). Este método se mostrou altamente eficaz em ambos os degraus, tanto o de partida quanto o de alteração, validando sua aplicação no nosso protótipo de teste real ilustrada na Figura 12(d).

3.3. Implementação de controle em Planta Didática Smar PD3-P

A planta didática Smar PD3-P é uma plataforma de ensino para cursos de automação industrial e engenharia, fabricada pela renomada empresa Smar. Com uma variedade de sensores, instrumentos, atuadores e controladores, a PD3-P oferece aos estudantes a oportunidade de aprender de forma prática os princípios fundamentais da automação e do controle de processos industriais. Essa planta didática oferece práticas envolvidas no controle de processos industriais, preparando-os para lidar eficazmente com desafios do mundo real na indústria.

A planta Smar PD3-P foi concebida e configurada para estabelecer um ambiente controlado, no qual as análises pudessem ser conduzidas de forma precisa e replicável. Essa configuração permitiu a coleta de dados relacionados à temperatura e ao processo de aquecimento, possibilitando a realização de estudos detalhados e a repetição das experiências de forma consistente. A Figura 13 ilustra o diagrama de tubulações e instrumentação (também conhecida como P&ID, do termo em inglês *Piping and Instrumentation Diagram*) utilizada nesse trabalho.

Figura 13 – Diagrama P&ID da planta Didática Smar PD3-P



BMC – bomba trifásica X cv.

FI – Indicador de vazão (rotâmetro).

TIT – Transmissor Indicador de Temperatura.

TY – Reles de conversão mA/V e V/mA.


TIC – Controlador de temperatura (Arduino)

TS – Banco de resistência (X W)

Fonte: autoria própria (2023)

As características específicas da SMAR PD3-P podem variar dependendo do modelo exato, mas geralmente incluem um tanque ou processo de controle, instrumentação, controladores, interface de usuário, software de supervisão e documentação. Ela é uma ferramenta valiosa para treinar e educar engenheiros, técnicos e estudantes nas áreas de automação industrial e controle de processos, permitindo a exploração de conceitos práticos em um ambiente controlado e seguro. Suas características podem ser personalizadas com base nas necessidades específicas de treinamento e aprendizado e estão apresentadas na Figura 14.

Figura 14– Planta didática Smar PD3-P



Fonte: autoria Própria (2023)


3.3.1 Configuração dos conversores

Para a realização deste estudo, foi implementado um sistema experimental composto por dois conversores. O primeiro conversor, do tipo corrente para tensão, foi empregado para coletar dados de temperatura por meio de um transmissor com saída de corrente variando de 4 a 20 mA. A saída deste transmissor foi convertida em um sinal de tensão para permitir a leitura pelo microcontrolador Atmel 328p embarcado na plataforma Arduino.

O segundo conversor, do tipo tensão para corrente, desempenhou um papel crucial no sistema, transformando a saída de tensão em um sinal PWM (*Pulse Width*

Modulation), o qual variava de acordo com as exigências do processo. Este sinal PWM de 4 a 20 mA foi então utilizado para controlar o banco de tiristores, que, por sua vez, regulava a potência fornecida às resistências de aquecimento. Dessa forma, o processo de aquecimento das resistências era controlado de acordo com o sinal de tensão gerado pelo conversor. A Figura 15 ilustra a conexão dos conversores.

Figura 15 – Fluxograma de ligação dos conversores



Fonte: autoria própria (2023)

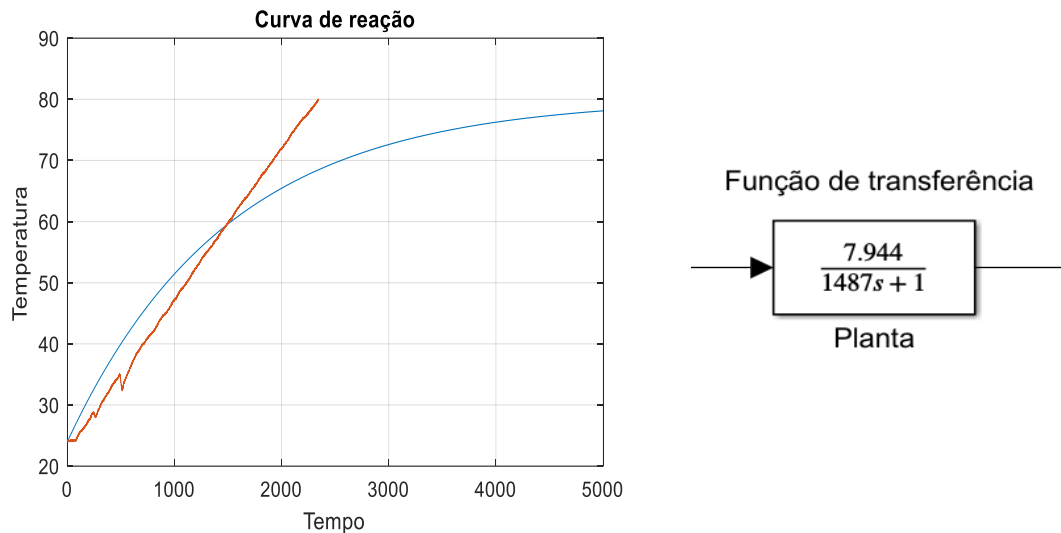
3.3.2. Determinação da Função de Transferência da Planta Smar PD3-P

Com o propósito de identificar a função de transferência da planta, foram conduzidos experimentos que consistiram na aplicação de um degrau de tensão por meio de um microcontrolador da plataforma Atmel. Esse degrau de tensão foi aplicado para determinar a resposta da planta em malha aberta, incluindo sua curva de reação até atingir o ponto de saturação.

No entanto, a planta didática utiliza água líquida como meio de aquecimento, o que implica que não existe um ponto de saturação definido, uma vez que a água entra em ebulição a 100°C. Diferente do resistor utilizado no protótipo, que possui um ponto de saturação bem definido. Porém os dados resultantes dessas experimentações foram então submetidos a análises utilizando técnicas de avaliação de sistemas lineares. Esse procedimento possibilitou a dedução das relações matemáticas que

descrevem o comportamento da planta em relação às variações nas entradas, conforme ilustra a Figura 16.

Figura 16 – Curva de reação da planta Smar PD3-P



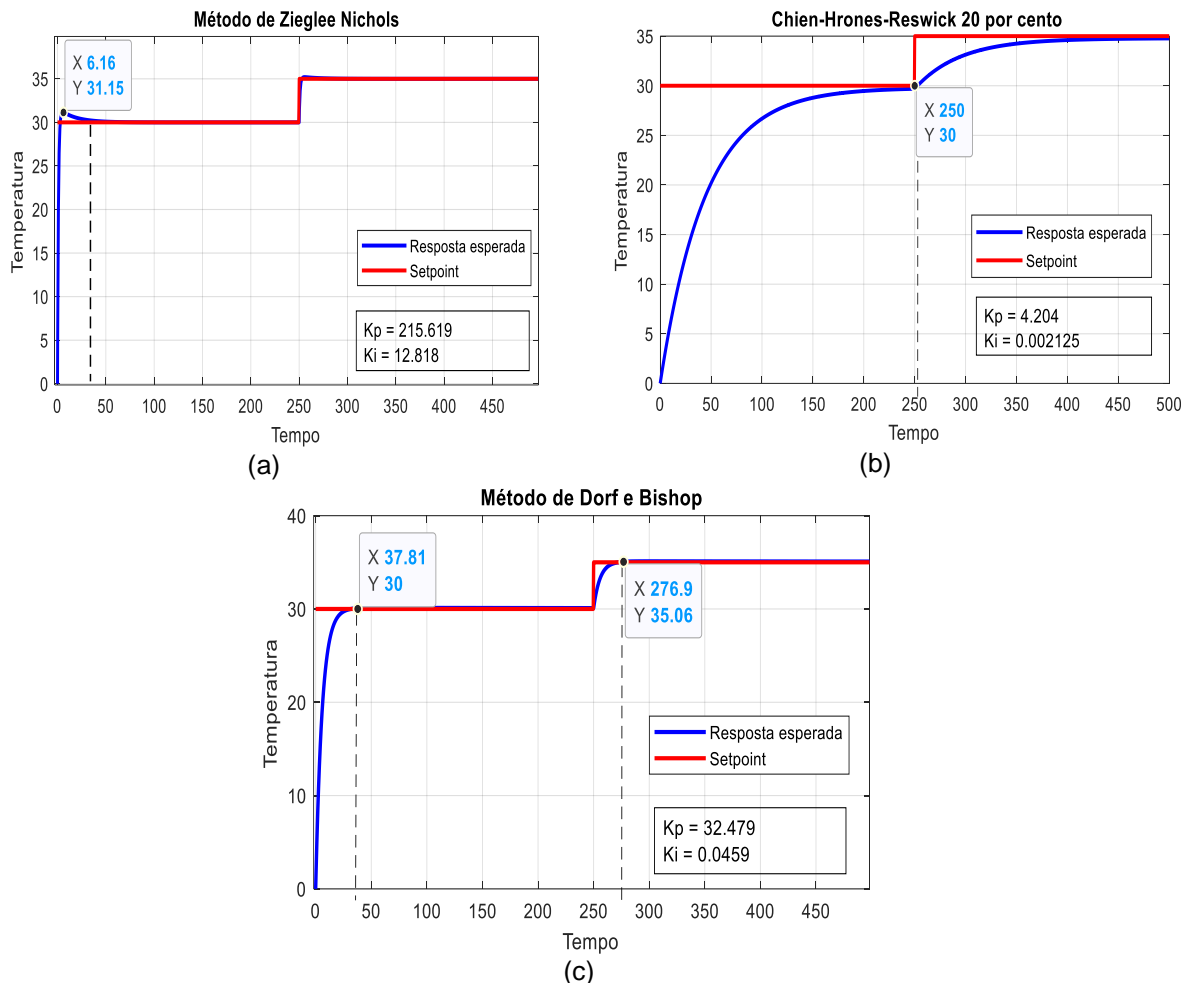
Fonte: autoria Própria (2023)

3.3.3. Método de sintonia utilizado para o controle PI, Dorf e Bishop

Para a escolha do método de sintonia ideal para a planta, realizou-se uma análise comparativa entre alguns métodos clássicos de sintonia. Conforme evidenciado na Figura 17(a), o método de Ziegler Nichols apresentou um *overshoot* de 1,15 graus e um tempo de acomodação de 35 segundos após o tempo de subida. Após uma alteração de 5 graus no setpoint, o *overshoot* diminuiu para 0,15 graus. No entanto, devido à inércia da temperatura nas condições reais, o *overshoot* foi considerado significativamente maior.

Por outro lado, na Figura 17(b), que representa o método de Método de Dorf e Bishop, demonstrou a ausência de *overshoot*, juntamente com um tempo de acomodação de 35 segundos. Isso valida o método como a escolha mais apropriada para o controle, uma vez que a defasagem de tempo resulta em um atraso praticamente nulo na temperatura após o desligamento. Em contrapartida, Chien-Hrones-Reswick 20%, também não apresentou *overshoot*, porém o tempo necessário para a estabilização foram substancialmente maiores, em torno de 250 segundos, tanto no início do *setpoint* quanto durante o deslocamento do *setpoint*. Essa demora excessiva na estabilização invalidou a aplicação desse método.

Figura 17 – Aplicação de métodos de sintonia: (a) Método de Ziegler Nichols; (b) Chien-Hrones-Reswick; (c) Método de Dorf e Bishop.



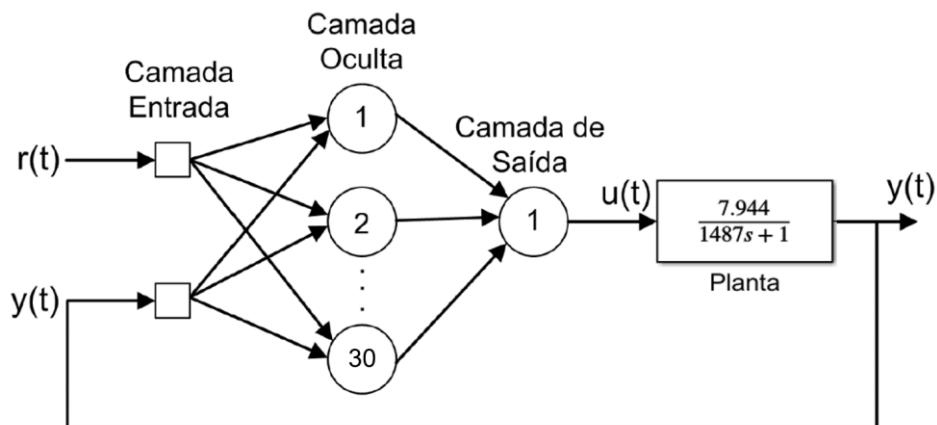
Fonte: autoria própria (2023)

Assim, pelos dados apresentados, optou-se pela escolha do método de sintonia de Dorf e Bishop, com K_p de 32,479 e K_i de 0,0459. O controle foi implementado experimentalmente na planta didática, e os resultados serão discutidos na Seção 4.

3.3.4. Método de controle utilizando um controlador PI-Neural

A rede proposta é composta por três camadas: a camada de entrada, na qual são fornecidos os valores de referência e velocidade real; a camada intermediária, que contém cinco neurônios; e a camada de saída, onde a ação de controle é aplicada. A arquitetura do controlador PI-Neural é adaptada da pesquisa de Junior; Vargas; Goedel (2013) representada na Figura 18.

Figura 18 – Arquitetura do controlador Pi-Neural



Fonte: autoria Própria (2023)

onde:

$r(t)$ é a referência de temperatura;

$u(t)$ é a ação de controle;

$y(t)$ é o valor real de temperatura.

No desenvolvimento deste trabalho, foi empregado um método de treinamento supervisionado utilizando o software MatLab (versão R2020a) em um computador com processador Intel(R) Core (TM) i5-10500H CPU @ 2.50GHz, 2496 Mhz, 6 Núcleo(s), 12 Processador(es) Lógico(s) e Sistema Operacional Microsoft Windows 11 Pro. Durante o treinamento, foram fornecidos dados de entrada e saída que descrevem de maneira satisfatória o comportamento do sistema, permitindo a obtenção dos parâmetros internos ideais para a rede neural. As amostras de treinamento utilizadas foram provenientes de um controlador PI convencional com os parâmetros de sintonia obtidos no método de Dorf e Bishop, com K_p de 32,479 e K_i de 0,0459. Os parâmetros da rede neural proposta estão apresentados na Tabela 2.

Tabela 2 – Parâmetros da rede neural artificial

Arquitetura da rede	<i>Perceptron</i> multicamadas
Tipo de treinamento	Supervisionado
Número de camadas	2
Neurônios na camada escondida	30
Algoritmo de treinamento	<i>Backpropagation</i>
Taxa de aprendizagem	0.1

Épocas	5000
Erro quadrático requerido	1e-8
Ativação camadas intermediárias	Função Logística
Ativação da camada de saída	Função Logística
Amostras para treinamento	4728 amostras
Amostras para validação	1800 amostras

Fonte: A autoria própria (2023).

Para a validação, implementada experimentalmente na planta Smar, foi proposto um método para autoajuste dos pesos, que ocorre em tempo real por meio da multiplicação entre uma taxa de aprendizagem e o erro. Esse escalar é multiplicado a matriz de pesos.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS


A metodologia abordada neste trabalho permitiu uma análise sistemática da planta didática de temperatura e a sintonia eficaz do controlador PI. Os resultados obtidos demonstraram a eficiência da sintonia pelo método de Dorf e Bishop na obtenção de um controle preciso da temperatura. Além disso, enfatizou-se a importância da configuração da planta e da determinação da função de transferência como passos preliminares cruciais para a sintonia bem-sucedida do controlador.

Após a sintonia do controlador, foram realizados ensaios experimentais no sistema, incluindo um teste de degrau, no qual a temperatura de referência foi abruptamente alterada. Os dados resultantes foram registrados e analisados graficamente para avaliar o desempenho do controlador PI. A análise incluiu a verificação da resposta do sistema, a estabilidade e a capacidade de seguir a temperatura de referência.

4.1. Sintonia do Controlador PI:

A etapa crítica deste estudo envolveu a sintonia do controlador PI, que se iniciou com a identificação dos parâmetros iniciais. Posteriormente, foi desenvolvido um *script* em software computacional específico para a sintonia utilizando o método

de Dorf e Bishop. Esse método incluiu a análise e otimização dos ganhos do controlador para alcançar os objetivos desejados de desempenho, como rápida convergência e mínima oscilação. Os resultados indicam a ausência de *overshoot* e um tempo médio de acomodação de 37 segundos, tanto no início do *setpoint* quanto na mudança do degrau, como ilustrado na Figura 19.




Após estabelecer que o método de de Dorf e Bishop apresenta o melhor resultado entre as sintonias de controladores os valores dos ganhos do controlador são armazenados, para serem aplicados experimentalmente na planta didática Smar PD3-P.

4.2. Resultados obtidos através de simulação feita na planta didática Smar PD3-P com PI Clássico

No primeiro teste realizado na planta Smar com os ganhos obtidos, se obteve resultados significativos. Ao iniciar o ensaio experimental, não se observou *overshoot*, indicando uma resposta inicial controlada. No entanto, a temperatura não se estabilizou exatamente sobre o *setpoint* desejado. Após o deslocamento do degrau, houve um *overshoot* de 0,5 graus, que perdurou por um tempo de acomodação de 1820 segundos, equivalente a cerca de 30 minutos.

Esse *overshoot* foi uma observação importante nos resultados, e sua ocorrência foi atribuída à inércia térmica do tanque. A inércia térmica do tanque resulta em um atraso na resposta à mudança de temperatura, o que significa que a temperatura não atinge imediatamente o *setpoint*. Isso levou ao *overshoot*, onde a temperatura ultrapassou temporariamente o valor desejado antes de se estabilizar conforme ilustra a Figura 20. Esses resultados ressaltam a importância de ajustar os ganhos do controlador para minimizar o *overshoot* e alcançar um controle mais preciso da temperatura.

Figura 20 – método de sintonia PI aplicado a planta Smar PD3-P



Fonte: autoria Própria (2023)

No segundo ensaio experimental, foi alcançada uma estabilização melhor, sem a ocorrência de *overshoot*, e o tempo de subida foi de 500 segundos, o que equivale a 8,3 minutos, como ilustrado na Figura 21. Além disso, observou-se que o tempo de subida permaneceu inalterado em relação à simulação anterior apresentada na Figura 20. Outra observação relevante foi que o *overshoot* ocorre quando o aumento do *setpoint* ultrapasse 2,5 graus Celsius, conforme evidenciado na Figura 22.

Na referida figura, apresenta-se três ensaios sobrepostos no gráfico, para a visualização da resposta do sobressinal e do tempo de acomodação, conforme altera-se o valor de referência. No quarto teste, o *overshoot* foi de 0,48 graus Celsius com um tempo de 17,98 minutos.

Figura 21 – Controle PI obtido pelo Método Dorf e Bishop (teste 2)

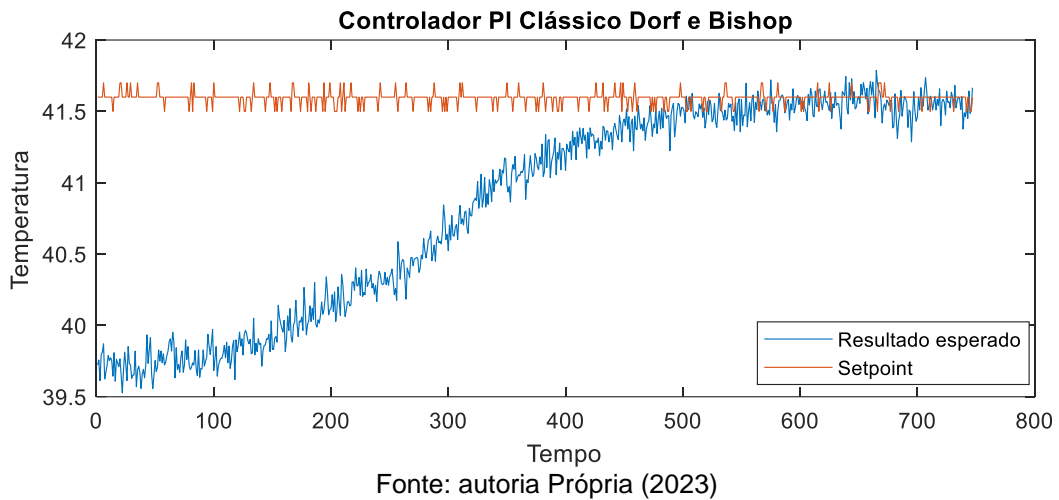
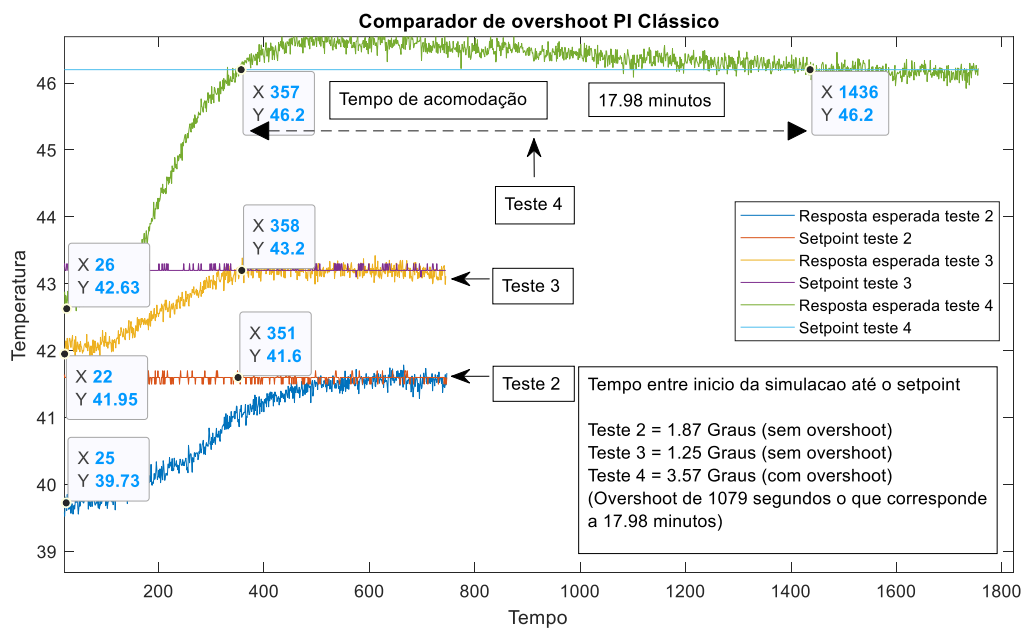


Figura 22 – Comparação do overshoot no controle PI



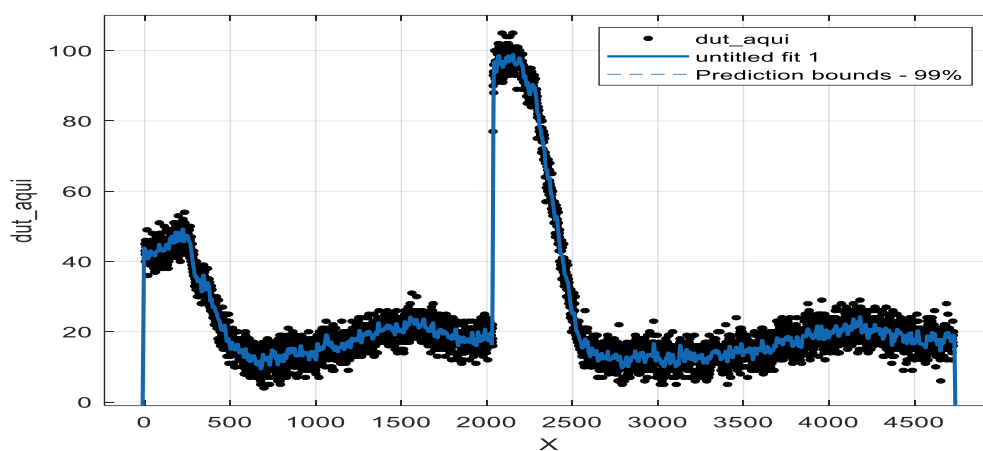
4.3. PI Neural

A melhor resposta do controle PI obtida experimentalmente pelo método de Dorf e Bishop foi utilizada para o treinamento do controlador PI-Neural. Assim, foram coletados e salvos os sinais de *setpoint*, temperatura e *duty cycle*. No modelo da rede neural proposto na Seção 3.3.4, o sinal de *setpoint* refere-se a “ $r(t)$ - referência de temperatura”, o sinal de temperatura refere-se a “ $y(t)$ - valor real de temperatura” e o *duty cycle* refere-se a “ $u(t)$ - ação de controle”.

O *duty cycle* (ciclo de trabalho) em um PWM (*Pulse Width Modulation*, ou Modulação por Largura de Pulso, em português) refere-se à proporção do tempo em que o sinal PWM está em nível alto em relação ao período completo do sinal. Essa variação de PWM é utilizada para o controle dos tiristores responsáveis pelo aquecimento do reservatório.

A Figura 23 ilustra o sinal de *duty cycle* utilizado para o treinamento da rede neural. O referido sinal amostrado foi submetido a uma ferramenta de filtragem (FitCurve – Matlab) para linearização e eliminação de parte dos ruídos.

Figura 23 – Duty de treinamento



Fonte: autoria Própria (2023)


A partir das 4728 amostras de treinamento, obteve-se a melhor configuração da rede neural capaz de aproximar o sinal de controle PWM a partir das entradas de referência e temperatura real. Esse método permite o controle do sistema sem a necessidade do modelo matemático do sistema. A validação ocorreu com 1800 dados que não foram utilizadas no treinamento. Após a etapa de validação computacional, obteve-se as matrizes de pesos $W1$ e $W2$ otimizadas para o controlador PI-Neural.

Adicionalmente, o sistema de controle PI-Neural proposto implementa um ajuste de pesos adaptativo, conforme há erro entre a referência e a temperatura real. Isso ocorre a cada iteração do controle, em que o erro é multiplicado por uma taxa de aprendizagem (n) e somado a matriz de pesos da iteração anterior. Assim, sempre que houver erro haverá adaptação dos pesos. Esse fato pode contribuir para a melhoria da convergência do controle em regime transitório e permanente.

4.4. Resultados obtidos através de simulação feita na planta didática Smar PD3-P com PI Neural

A resposta do controle PI Neural pode ser observada na Figura 24. O *setpoint* foi ajustado para 36,54 graus e observa-se uma melhoria no tempo de subida em comparação ao controle PI Clássico. A temperatura permaneceu estável com poucas variações.

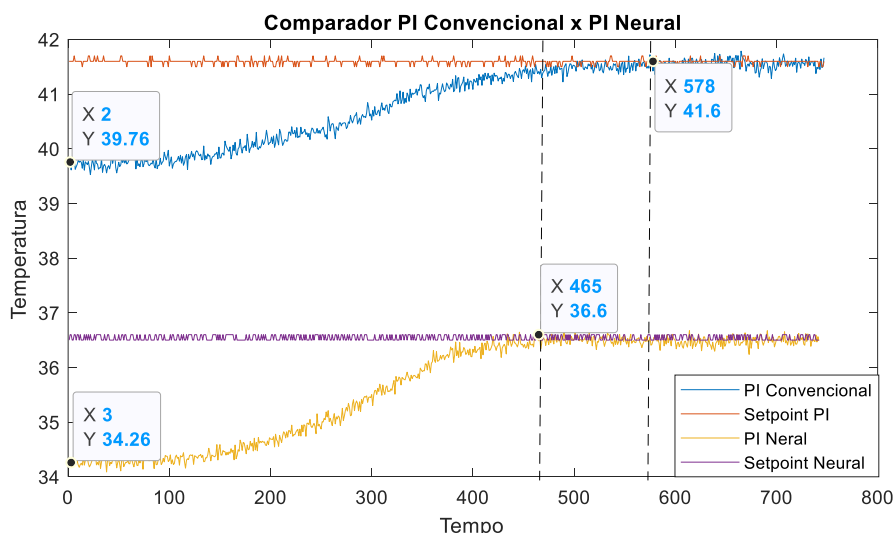
Figura 24 – Controle PI Neural obtido (teste 1)



Fonte: autoria Própria (2023)

A Figura 25 ilustra uma análise comparativa entre a melhor resposta do controlador PI clássico com o controlador PI-Neural. Observa-se, que em ambos os métodos não houve a ocorrência de *overshoot*. O tempo de melhora na resposta foi de 113 segundos.

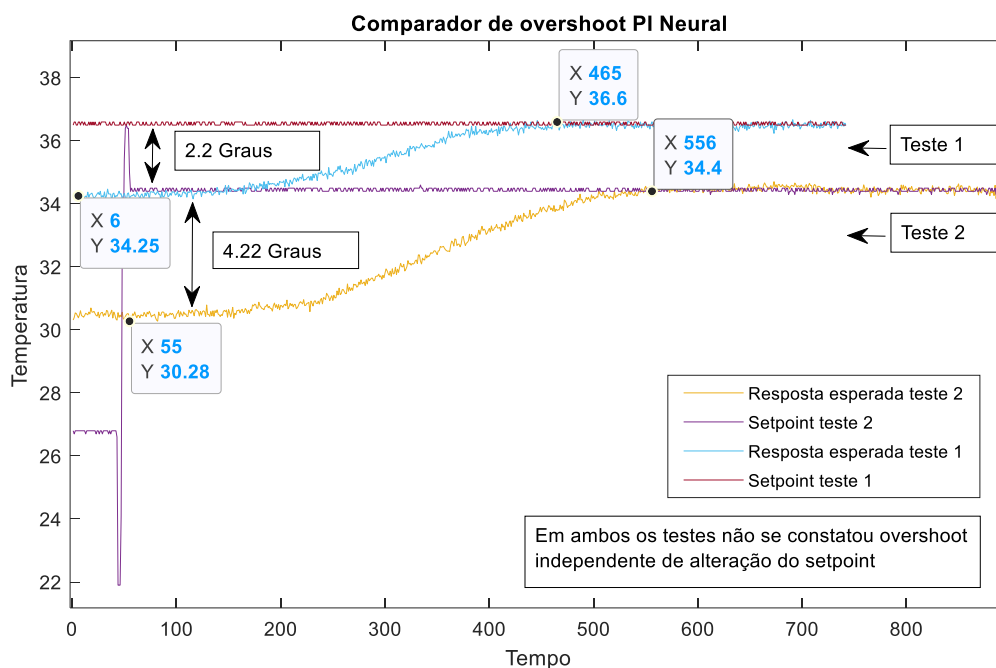
Figura 25– Comparação PI Clássico x PI Neural



Fonte: autoria Própria (2023)

Além disso, como evidenciado na Figura 26, notou-se que, independentemente do valor de alteração do *setpoint*, o controle PI-Neural não apresenta *overshoot*, o que é uma diferença marcante em relação ao PI Clássico, onde *overshoot* já era observado após uma alteração de 2,5 graus no *setpoint*.

Figura 26 – Comparação de overshoot no controle PI Neural




Fonte: autoria Própria (2023)

Uma melhoria substancial adicional, conforme destacado na Figura 27, foi a consistência das simulações do controle PI Neural. Independentemente da distância entre a temperatura atual e a temperatura desejada, nenhuma das simulações apresentou *overshoot*. Isso demonstra de maneira excepcional a eficácia do treinamento dos pesos aplicados à rede neural, validando sua performance de forma sólida e consistente.

Esses resultados indicam que o uso de redes neurais artificiais como método de controle pode ser altamente eficaz na melhoria do desempenho de sistemas de controle, resultando em respostas mais rápidas e uma maior linearidade, o que pode ser fundamental em diversas aplicações práticas. Portanto, os benefícios observados nesse estudo destacam o potencial das redes neurais artificiais como uma ferramenta valiosa no campo do controle de sistemas.

Figura 27 – Todos os testes PI (Clássico e Neural) executados



Fonte: autoria Própria (2023)

Na Figura 27 evidencia-se que o controle PI-Neural pode ser utilizado para uma ampla faixa de valores de referência promovendo uma estabilização aceitável, com melhorias significativas, se comparada ao controle PI convencional.

5 CONSIDERAÇÕES FINAIS

O presente trabalho apresenta um estudo comparativo entre o controlador PI convencional e o controlador PI-Neural aplicado ao controle de sistemas térmicos, com o objetivo de controlar suavemente sua temperatura. O sistema proposto baseou-se em dados gerados em um processo que foi sintonizado por métodos convencionais. A aplicação de um degrau de tensão aos tiristores que controlam um banco de resistências produz uma sequência de dados relativos ao processo. A sintonia de controladores do tipo PI apresentaram bons resultados, validando os métodos propostos na literatura. Com base nos dados de um controle clássico foi proposto um controlador PI-Neural com ajuste de pesos.

Através do método de treinamento, houve o ajuste dos pesos sinápticos dos neurônios da rede com o objetivo de otimizar a resposta do controle. O controlador PI-Neural demonstrou maior eficiência se comparado ao controlador PI identificado e sintonizado por métodos convencionais.

A implementação do controle de rede neural artificial resultou em melhorias significativas na resposta do sistema. Foi observada uma otimização dos dados, com uma redução de aproximadamente 15% no tempo de estabilidade. Além disso, foi evidente uma notável melhoria na linearidade do sistema em comparação com o controle proporcional-integral (PI).

Cabe ainda ressaltar os resultados satisfatórios, não apresentando máximos sobressinal, demonstrando menor tempo de subida após a aplicação de distúrbio, menor tempo de assentamento e menor erro estacionário. Isso demonstrou que sistemas inteligentes baseados em redes neurais são uma alternativa para sistemas de controle para os quais não é possível obter a função de transferência que descreve precisamente o comportamento do sistema.

REFERÊNCIAS

CAMPOS, M. C. M. M. DE; TEIXEIRA, H. C. G. **Controles típicos de equipamentos e processos industriais.** [s.l.] Editora Blucher, 2010.

FACCIN, F. Abordagem inovadora no projeto de controladores PID. 2004.

FERREIRA, M. H.; DE MOARES, M. A. REDES NEURAS ARTIFICIAIS: PRINCÍPIOS BÁSICOS. v. 1, n. 13, 2016.

FISCHER ABATI, G. **SIMULAÇÃO E VALIDAÇÃO EXPERIMENTAL DE CONTROLE PID E LQR EM UM SISTEMA SUB-ATUADO COM PÊNDULO INVERTIDO.** ENGENHEIRO MECÂNICO—Rio de Janeiro, Brazil: PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO, 2020.

GARCIA, C. **Controle de processos industriais: estratégias convencionais.** [s.l.] Editora Blucher, 2021.

GOMIDE, F. A. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 23, p. 649–652, out. 2012.

HAYKIN, S. **Redes Neurais: Princípios e Prática.** [s.l.] Bookman Editora, 2001.

JUNIOR, V. A. F; VARGAS, A. N.; GOEDTEL, A. Uma Abordagem PI-Neural Aplicado ao Controle de um Servo-Mecanismo. Simpósio Brasileiro de Automação – SBAI, 2013.

OLIVEIRA, R. M. DE. **Aplicação de controle PID não linear com ganhos baseados em perfil gaussiano aplicado a um conversor Buck.** masterThesis—[s.l.] Universidade Tecnológica Federal do Paraná, 29 ago. 2014.

SARAIVA, 2011. MÉTODOS DE SINTONIA EM CONTROLADORES PID. [s.d.].

SILVA, W. J. DA. APLICAÇÃO DE MALHA FECHADA EM UM SISTEMA DE FRENAGEM INDUSTRIAL TÊXTIL. 29 nov. 2021.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artliber, 2010.

YU, C.-C. **Autotuning of PID Controllers: Relay Feedback Approach.** [s.l.] Springer Science & Business Media, 2013.