



Ramires Fórmulo Grätsch

**APLICAÇÃO DE ALGORITMO GENÉTICO NA OTIMIZAÇÃO DOS PARÂMETROS
DE CONTROLADORES PID**

Horizontina - RS

2025

Ramires F6rmulo Gr6atsch

**Aplicação de algoritmo genético na otimização dos parâmetros de
controladores PID**

Trabalho Final de Curso apresentado como
requisito parcial para a obtenção do título de
bacharel em Engenharia de Controle e Automação
na Faculdade Horizontina, sob a orientação do
Prof. Dr. Douglas de Castro Karnikowski

Horizontina - RS

2025

FAHOR - FACULDADE HORIZONTINA
CURSO DE ENGENHARIA DE CONTROLE E AUTOMAÇÃO

A Comissão Examinadora, abaixo assinada, aprova o trabalho final de curso

“Aplicação de algoritmo genético na otimização dos parâmetros de controladores PID”

**Elaborada por:
Ramires Fórmula Grätsch**

Como requisito parcial para a obtenção do grau de Bacharel em
Engenharia de Controle e Automação

Aprovado em: 11/12/2025
Pela Comissão Examinadora

Prof. Dr. Douglas de Castro Karnikowski
Presidente da Comissão Examinadora - Orientador

Prof. Me. Rodrigo Bastos
FAHOR – Faculdade Horizontina

Prof. Esp. João Michel Machado de Oliveira
FAHOR – Faculdade Horizontina

**Horizontina - RS
2025**

Dedico esse trabalho a todos que me inspiraram e me incentivaram a trilhar esse caminho. Mãe, obrigado por me ensinar o que é amor e coragem. Irmão, obrigado por me inspirar a ser mais eu mesmo. A todos que já se foram, fiz isso por vocês também.

AGRADECIMENTO

Ao prof. Dr. Douglas Karnikowski, por me guiar não só durante este trabalho, mas durante toda a graduação, meu muito obrigado. Aos meus amigos e professores, obrigado por me inspirarem.

“A felicidade pode ser encontrada mesmo nas horas mais difíceis, se você lembrar de acender a luz”.

Alvo Dumbledore

RESUMO

Este trabalho objetivou investigar o uso de algoritmo genético (AG) para otimização dos parâmetros de controlador PID. A pesquisa foi realizada exclusivamente em ambiente simulado, utilizando sistemas disponíveis na literatura, onde foi possível comparar o desempenho do método proposto com outros métodos também utilizados na literatura. A ampla utilização de controladores PID na indústria e a dificuldade inerente na escolha dos parâmetros do controlador justificam a busca por métodos de otimização eficientes, sendo a utilização de AGs para tal fim sendo explorada no presente trabalho. A coleta de dados foi realizada através das simulações, utilizando diferentes funções de custo. As análises foram feitas submetendo os sistemas controlados a uma entrada unitária, onde índices de desempenho foram coletados em cada uma das simulações e foi realizada comparação gráfica dos resultados. Ao fim, foi possível verificar que os controles otimizados com o AG apresentam melhor desempenho quando comparado com métodos tradicionais, sendo possível inferir a importância da correta escolha dos parâmetros do AG e do impacto que os diferentes parâmetros causam no resultado final.

Palavras-chave: Controle PID. Algoritmo genético. Otimização.

LISTA DE FIGURAS

Figura 1 - Curva de resposta em degrau unitário.....	17
Figura 2 - Diagrama controlador PID	17
Figura 3 - Diagrama ilustrando a evolução em um algoritmo genético.	19
Figura 4 - Diagrama de blocos para ajuste e reajuste de parâmetros PID usando AG	22
Figura 5 - Representação genérica do sistema de controle	25
Figura 6 - Reposta ao degrau unitário com parâmetros PID otimizados.....	28
Figura 7 - Evolução dos Parâmetros PID por Função de Custo	29
Figura 8 - Comparação da convergência de cada função de custo	30
Figura 9 - Comparação das Respostas ao Degrau	32
Figura 10 - Evolução dos parâmetros PID do segundo sistema	33
Figura 11 - Comparação do custo das funções	34
Figura 12 - Comparação com os resultados encontrados na literatura.....	35
Figura 13 - Reposta ao degrau do terceiro sistema com parâmetros otimizados	38
Figura 14 - Evolução dos parâmetros PID no terceiro sistema	39
Figura 15 - Evolução do valor das funções de custo do terceiro sistema	40
Figura 16 - Comparação da resposta ao degrau unitário.....	42

LISTA DE TABELAS

Tabela 1 - Funções de custo	20
Tabela 2 - Parâmetros do Algoritmo Genético	27
Tabela 3 - Índices de desempenho do sistema controlado.	28
Tabela 4 - Parâmetros do Algoritmo Genético	31
Tabela 5 - Índices de desempenho do segundo sistema	32
Tabela 6 - Comparação das Respostas ao Degrau	35
Tabela 7 - Parâmetros utilizados no algoritmo	37
Tabela 8 - Índices de desempenho para o terceiro sistema	37
Tabela 9 - Comparação dos parâmetros adquiridos com o trabalho original .	42

SUMÁRIO

1	INTRODUÇÃO	12
1.1	TEMA	13
1.2	DELIMITAÇÃO DO TEMA	13
1.3	PROBLEMA DE PESQUISA	13
1.4	HIPÓTESES	13
1.5	JUSTIFICATIVA	13
1.6	OBJETIVOS	15
1.6.1	Objetivo geral	15
1.6.2	Objetivos específicos	15
2	REVISÃO DA LITERATURA	16
2.1	Controle de sistemas	16
2.2	Controle PID	17
2.3	Algoritmo Genético	18
2.4	Função de custo	20
2.5	Parâmetros do Algoritmo Genético	21
2.6	AG aplicado ao controle PID	22
2.7	Função transferência	23
3	METODOLOGIA	24
3.1	MÉTODOS E TÉCNICAS UTILIZADOS	24
3.1.1	Métodos de abordagem	25
3.1.2	Métodos de procedimento	25
3.1.3	Técnica de coleta de dados	26
3.1.4	Análise de dados	26
3.2	MATERIAIS E EQUIPAMENTOS	26
4	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	27
4.1	PRIMEIRO SISTEMA	27

4.2	SEGUNDO SISTEMA	31
4.3	TERCEIRO SISTEMA	36
	CONCLUSÃO	44
	REFERÊNCIAS	47

1 INTRODUÇÃO

O estudo e a prática da manipulação de sistemas dinâmicos é conhecido como teoria de controle e é um dos campos de maior sucesso no elo entre matemática aplicada e engenharia prática (Brunton; Kutz, 2022). Embora algoritmos complexos e mais robustos existam, o controle PID (*proportional-integral-derivative*), menos sofisticado, é utilizado em cerca de 90% da indústria, principalmente por ser simples, o significado físico dos parâmetros de controle ser claro e o conhecimento do operador poder ser utilizado no projeto do controlador (Patel; Chaphekar, 2012; Nouman; Asim; Qasim, 2018).

A configuração dos parâmetros PID, se feito utilizando somente a prática, é difícil, geralmente não apresenta bom resultado e o desempenho é ruim (Chen; Ma; Yun, 2013). Recentemente, técnicas de *machine learning* vêm sendo aplicadas em sistemas de controle, especialmente para lidar com sistemas não lineares e incertos e, entre as possibilidades, algoritmos evolucionários têm se mostrado uma alternativa popular entre os pesquisadores (Ahmadi; Esfanjani, 2025; Fleming; Purshouse, 2002).

O algoritmo genético (AG) é um dos primeiros e mais simples algoritmos evolucionários, baseado em princípios de otimização através de seleção natural e aptidão (Brunton; Kutz, 2022). O AG é uma metodologia robusta de busca e otimização, capaz de lidar com domínios de sistemas complexos, que apresentam características como multimodalidade, descontinuidade, variação no tempo, aleatoriedade e ruído (Fleming; Purshouse, 2002). Permite, segundo Fleming e Purshouse (2002), um nível notável de flexibilidade em relação à avaliação de desempenho e à definição de especificações de projeto.

O presente trabalho aborda a aplicação de AG na otimização dos parâmetros de controladores PID, com o objetivo de melhorar o desempenho de sistemas sob diferentes condições dinâmicas. Considerando a ampla utilização dos controladores PID na indústria, a correta definição de seus parâmetros é fundamental para garantir a estabilidade, a precisão e a eficiência dos processos controlados (M. Zahir et al., 2018).

A pesquisa desenvolvida concentra-se na análise e comparação do desempenho de controladores PID ajustados por meio de AG, utilizando como ambiente de testes a simulação computacional de diferentes plantas. Como critérios

de avaliação, foram considerados o sobressinal, o tempo de acomodação e o erro em regime permanente frente a uma entrada de referência unitária.

O objetivo principal deste estudo consiste na construção de um controlador PID associado a um algoritmo genético capaz de realizar a otimização de seus parâmetros. Além disso, busca-se compreender como os diferentes parâmetros internos do AG, como tamanho da população, taxa de mutação e taxa de cruzamento, impactam diretamente no desempenho final do sistema controlado.

1.1 TEMA

Aplicação de algoritmos genéticos no ajuste de controladores PID.

1.2 DELIMITAÇÃO DO TEMA

Este trabalho delimita-se na aplicação de AG no ajuste de controladores PID em ambiente de simulação exclusivamente computacional, com foco em sistemas que possuam funções de transferência instáveis.

1.3 PROBLEMA DE PESQUISA

Como a aplicação de algoritmos genéticos pode contribuir para o ajuste dos parâmetros de controladores PID, visando melhorar o desempenho de sistemas dinâmicos (estabilidade, tempo de resposta e precisão) em simulações computacionais?

1.4 HIPÓTESES

Para o presente estudo, as hipóteses levantadas foram:

1. Utilizar o algoritmo genético para otimização dos parâmetros melhora o desempenho do controlador PID.
2. Verificar se, utilizando o AG, é possível encontrar os valores ótimos para plantas com diferentes graus de complexidade.
3. Avaliar a influência dos parâmetros utilizados no algoritmo genético no resultado da otimização.

1.5 JUSTIFICATIVA

Os sistemas de controle PID são os blocos de construção fundamentais dos sistemas de controle clássicos e modernos (Wang, 2020). Segundo a autora, têm sido utilizados na maioria das aplicações industriais, desde controle de processos

químicos, mecânicos e eletromecânicos, sendo utilizados, também, em controle de veículos aéreos, controle de acionamentos elétricos e conversores de potência. Sua parametrização, entretanto, é extremamente complexa e muitas vezes apresenta péssimo desempenho (Chen; Ma; Yun, 2013). Métodos tradicionais, como Ziegler-Nichols, geralmente apresentam bom desempenho em resposta e rejeição de perturbações, mas produzem uma resposta oscilatória e geram um alto percentual de sobressinal (M. Zahir et al., 2018).

Para alcançar o melhor desempenho em termos de estabilidade e precisão, a melhor solução de projeto de controle para ajustar um sistema controlado por um PID permanece uma questão em aberto em muitas aplicações (Somefun; Akingbade; Dahunsi, 2021). Uma das razões, os autores explicam, é a ausência de modelos perfeitos para descrever sistemas do mundo real, que são sistemas inerentemente incertos.

Profissionais de engenharia de controle estão cada vez mais lidando com problemas para os quais a teoria e a prática de controle existentes não estão preparadas, que normalmente requerem a consideração de múltiplos critérios de desempenho e variáveis de controle não mensuráveis, por isso, tem se considerado cada vez mais o uso de técnicas não convencionais a fim de encontrar uma solução satisfatória (Fleming; Purshouse, 2002). Como o *machine learning* abrange uma ampla gama de técnicas de otimização de alta dimensão, possivelmente não lineares, é natural aplicar o aprendizado de máquina ao controle de sistemas complexos e não lineares (Brunton; Kutz, 2022). Muitos desses algoritmos são baseados em sistemas biológicos, os autores explicam, como o algoritmo genético.

O algoritmo genético de otimização permite controlar processos e sistemas de comportamento descontínuo, variante no tempo e suscetíveis a aleatoriedades e ruídos (Fleming; Purshouse, 2002). Esses autores afirmam que o método permite um nível notável de flexibilidade em relação à avaliação de desempenho e à especificação de projeto.

Dada a necessidade de um ajuste fino dos parâmetros de um controlador PID para garantir a estabilidade e desempenho do sistema em condições diversas e a dificuldade dessa tarefa utilizando os métodos tradicionais, a aplicação do algoritmo genético surge como uma alternativa na busca pela otimização de comportamento em sistemas dinâmicos.

1.6 OBJETIVOS

O presente estudo sobre parâmetros de controlador PID, otimizados através de algoritmo genético, tem como objetivo geral e específicos:

1.6.1 Objetivo geral

Analisar a contribuição de algoritmos genéticos no ajuste de parâmetros de controladores PID para melhorar o desempenho de sistemas dinâmicos em simulações computacionais.

1.6.2 Objetivos específicos

1. Realizar simulações para analisar o desempenho de controladores PID ajustados por algoritmos genéticos em diferentes plantas.
2. Avaliar o impacto de parâmetros como população, mutação e cruzamento no desempenho dos algoritmos.
3. Comparar funções de avaliação (fitness) utilizadas na otimização.

2 REVISÃO DA LITERATURA

Esta seção trata dos conceitos necessários para o entendimento do trabalho, compreendendo a definição do sistema de controle utilizado, apresentação do AG, bem como os parâmetros que o compõem, definição matemática das funções de custo utilizadas e implementação do algoritmo de otimização.

2.1 CONTROLE DE SISTEMAS

A engenharia de controle baseia-se nos fundamentos da teoria de feedback e da análise de sistemas lineares e integra os conceitos da teoria de redes e da teoria de comunicação (Dorf; Bishop, 2017). Não se limitando, os autores explicam, a nenhuma disciplina de engenharia, sendo igualmente aplicável à engenharia aeronáutica, química, mecânica, ambiental, civil e elétrica.


Existem diversas maneiras de manipular o comportamento de sistemas passivamente, por exemplo um semáforo, ou ativamente, que é dividida em duas categorias, baseadas em se o sistema utiliza ou não sensores, sendo denominados sistema de malha aberta e sistema de malha fechada, respectivamente (Brunton; Kutz, 2022).

No sistema de malha aberta a saída não influencia o controle, ele atua com base apenas na entrada de referência, normalmente por tempo, como em uma máquina de lavar ou semáforo temporizado, enquanto o sistema de malha fechada compara a saída com a entrada de referência e usa o erro resultante para corrigir o sistema, como em um termostato (Ogata, 2010).

Os índices de desempenho de um sistema são utilizados, normalmente, para determinar a qualidade da resposta (Brunton; Kutz, 2022). Em Ogata (2010), o autor define, que, na prática, a resposta transitória de um sistema apresenta oscilações amortecidas antes de atingir o regime permanente.

De acordo com a característica da curva da resposta no tempo, podem ser obtidos os índices de desempenho (Figura 1), onde é comum definir:

- a) Tempo de atraso, t_d
- b) Tempo de subida, t_r
- c) Tempo de pico, t_p
- d) Máximo sobressinal, M_p
- e) Tempo de acomodação, t_s


Figura 1 - Curva de resposta em degrau unitário

Fonte: Ogata (2010)

2.2 CONTROLE PID

Atualmente, grande parte dos controladores industriais em operação baseia-se em estratégias de controle do tipo PID ou em variações modificadas desse modelo. A ampla aplicabilidade do controle PID se destaca especialmente em sistemas nos quais o modelo matemático do sistema é desconhecido, inviabilizando o uso de métodos analíticos convencionais (Ogata, 2010).

Em uma das configurações, o PID possui um mecanismo de controle em malha fechada (Bharat et al., 2019). O autor explica que o sistema calcula continuamente o erro, que é a diferença entre a saída da variável de processo e a sua referência, aplicando então uma correção baseada na ação do proporcional, integral e derivativo. Um diagrama de controle PID pode ser visto na Figura 2.

Figura 2 - Diagrama controlador PID

Fonte: Adaptado de Brunton e Kutz, 2022

O diagrama da Figura 2 mostra a estrutura de operação do PID, no qual w_r representa o sinal de referência e ϵ , o sinal de erro. A ação de controle é executada pelos operadores proporcional, integrador e diferenciador (K_p , K_i e K_d). O controlador busca reduzir o erro ajustando continuamente a variável de controle u (Brunton; Kutz, 2022).

Quando a referência w_r mudar, o erro ϵ entre o valor definido e o resultado real é recalculado. O termo ϵ é utilizado para os parâmetros K_p , K_i e K_d , com os sinais respectivos pesados e somados para constituir o sinal u de controle aplicado ao modelo do sistema, também chamado de planta. O sinal y é o resultado obtido (Joseph et al., 2022).

Conforme apresentado em Wang et al. (1999), pode-se utilizar um controlador $K(s)$, definido matematicamente por Equação 1, para o acionamento do processo.

$$K(s) = K_p + \frac{K_i}{s} + K_d s \quad (1)$$

O objetivo da sintonia do PID é determinar os parâmetros de modo que o controlador apresente elevado desempenho e comportamento consistente para uma ampla classe de processos lineares, que podem apresentar dinâmicas bastante distintas, desde sistemas de baixa ou alta ordem, com atraso pequeno ou significativo, até respostas monótonas ou oscilatórias (Wang et al., 1999).

2.3 ALGORITMO GENÉTICO

Algoritmos genéticos (AGs) trabalham com uma população de potenciais soluções para um problema, onde cada indivíduo representa uma solução única (Fleming; Purshouse, 2002). Dentro dos algoritmos evolucionários, os autores seguem, o algoritmo genético é frequentemente utilizado para sintonizar os parâmetros de um controlador PID. Em um AG, uma população composta por diversas realizações do sistema, cada uma com diferentes valores de parâmetros, compete para minimizar uma determinada função de custo, onde valores de parâmetros bem-sucedidos são propagados para futuras gerações através de regras genéticas (Brunton; Kutz, 2022).


As etapas de um algoritmo genético podem ser visualizadas na Figura 3. Nessa abordagem, os indivíduos são gerados aleatoriamente na geração k , avaliados e classificados conforme sua função de custo, que, por sua vez, é inversamente proporcional à probabilidade de seleção para as operações genéticas. Os indivíduos são então escolhidos para avançar para a próxima geração $k+1$ através de quatro operações: elitismo, replicação, *crossover* e mutação, formando então a nova geração $k+1$. Essas operações são repetidas até que o valor de custo convirja para um ponto ou outro critério de parada seja atendido (Brunton; Kutz, 2022).

Segundo (Brunton; Kutz, 2022), indivíduos bem-sucedidos (baixo custo), possuem maior probabilidade de serem selecionados para avançar para as próximas gerações, através das operações genéticas:

- Elitismo: O conjunto de indivíduos mais aptos são diretamente selecionados para avançar para a próxima geração.
- Replicação: Indivíduos selecionados em (a) avançam para a próxima geração sem sofrer mudanças.
- Crossover*: Indivíduos são selecionados em pares e trocam uma parte de seus “códigos genéticos” e então avançam para a próxima geração.
- Mutação: Um conjunto de indivíduos é selecionado para ter uma parte de seu código genético modificado. A mutação promove a diversidade e serve para aumentar a exploração do espaço do parâmetro.

Para as operações de replicação, *crossover* e mutação os indivíduos são aleatoriamente selecionados. A probabilidade desses eventos são parâmetros que devem ser definidos na construção do modelo.

Figura 3 - Diagrama ilustrando a evolução em um algoritmo genético.



Fonte: Adaptado de Brunton e Kutz (2022)

Um algoritmo genético buscar maximizar a aptidão média de sua população através de iterações de operadores genéticos. Custo é um termo comumente associado com problemas de otimização e representa métrica de desempenho (Fleming; Purshouse, 2002).

2.4 FUNÇÃO DE CUSTO

Joseph et al. (2022) apresenta seis (6) funções de custo comumente utilizadas. No presente trabalho, quatro (4) funções de custo foram utilizadas (Tabela 1), seguindo como orientação os trabalhos de Rajinikanth e Latha (2012), M. Zahir et al. (2018) e Eltayeb et al. (2024).

Tabela 1 - Funções de custo

$IAE = \int_0^{\tau} e(t) $	<i>Integral Absolute Error (IAE)</i>
$ISE = \int_0^{\tau} e(t) ^2$	<i>Integral Square Error (ISE)</i>
$ITAE = \int_0^{\tau} t e(t) $	<i>Integral Time Absolute Error (ITAE)</i>
$ITSE = \int_0^{\tau} t e(t) ^2$	<i>Integral Time Square Error (ITSE)</i>

Fonte: Adaptado de Joseph et al. (2022)

As funções de custo utilizadas na otimização de controladores PID definem matematicamente o critério de desempenho a ser minimizado pelo algoritmo genético, influenciando diretamente a forma da resposta do sistema. As quatro funções consideradas diferem na maneira como penalizam o erro ao longo do tempo. Enquanto o IAE integra o erro absoluto sem qualquer ponderação, resultando em respostas mais suaves, porém potencialmente mais lentas, o ISE penaliza quadraticamente o erro, aumentando sua sensibilidade a desvios de maior magnitude e promovendo correções mais agressivas, ainda que às custas de maior sobressinal (Joseph et al., 2022).

Por outro lado, o autor segue, as funções temporais ITAE e ITSE acrescentam um fator de ponderação no tempo, fazendo com que erros tardios sejam penalizados

de forma mais intensa. O ITAE penaliza o erro absoluto ponderado pelo tempo e tende a produzir respostas rápidas com eliminação eficiente do erro estacionário, mas pode gerar oscilações iniciais. Já o ITSE combina penalização temporal e quadrática, reforçando ainda mais a correção de erros persistentes e de grande amplitude, frequentemente resultando em um equilíbrio adequado entre estabilidade, rapidez e precisão.

2.5 PARÂMETROS DO ALGORITMO GENÉTICO

O parâmetro de seleção indica a forma com a qual o algoritmo escolherá os pais da próxima geração. No presente trabalho, foi utilizada a seleção por torneio, que seleciona um número n de indivíduos de maneira aleatória. Utilizando como critério o valor do custo de cada indivíduo, o mais apto (menor valor), é selecionado para ser um dos genitores da próxima geração (MathWorks, 2025).

Segundo MathWorks (2025), as opções de *crossover* especificam a maneira com a qual o algoritmo combinará dois indivíduos selecionados, a fim de formar um novo indivíduo na próxima geração. No presente trabalho foi utilizada “*crossoverintermediate*”, opção padrão do MATLAB, que gera novos indivíduos (filhos) a partir de uma combinação ponderada dos pais, conforme Equação 2.

$$child = parent_1 + rand * Ratio * (parent_2 - parent_1) \quad (2)$$

A expressão Eq. 2 representa a geração de um novo indivíduo (*child*) a partir de dois pais ($parent_1$ e $parent_2$) por meio de uma combinação linear. O termo $(parent_2 - parent_1)$ define a direção entre os pais, enquanto o fator aleatório *rand* (entre 0 e 1) e o parâmetro *Ratio*, determinam o quanto o filho se aproxima de um ou outro pai. Dessa forma, o novo indivíduo é criado em uma posição intermediária, promovendo diversidade genética e explorando o espaço de busca de forma controlada (MathWorks, 2025). O valor utilizado para *Ratio* foi o padrão do *software*, um vetor composto inteiramente por 1's.


O parâmetro *MaxStallGenerations* define o número máximo de gerações consecutivas (no presente trabalho, 20 gerações) em que o algoritmo genético pode permanecer sem apresentar melhora significativa no valor da função de custo. O algoritmo é interrompido quando a variação média relativa do melhor valor da função

de custo, ao longo das últimas gerações, não exceder o limite definido (MathWorks, 2025). A variação média foi definida como a padrão do MATLAB ($1e - 6$).

2.6 AG APLICADO AO CONTROLE PID

A Figura 4 apresenta o diagrama de blocos que descreve a arquitetura funcional do sistema de controle PID otimizado por AGs. Esse diagrama integra uma estrutura clássica de controle em malha fechada com um mecanismo externo de otimização, responsável por ajustar continuamente os parâmetros do controlador. O objetivo central é garantir que o sistema atenda aos requisitos de desempenho especificados, mesmo diante de variações dinâmicas do processo ou da necessidade de reconfiguração dos ganhos (Rajinikanth; Latha, 2012).

Figura 4 - Diagrama de blocos para ajuste e reajuste de parâmetros PID usando AG



Fonte: Adaptado de Rajinikanth; Latha, (2012)

No diagrama, o sinal de referência $R(s)$ é comparado com a saída do processo $Y(s)$, produzindo o erro $e(t)$, que alimenta o controlador PID. Os ganhos K_p , K_i e K_d são fornecidos pelo algoritmo genético, que avalia o desempenho do sistema a partir da resposta temporal do processo e do critério de desempenho definido. A partir dessa avaliação, o AG gera novos conjuntos de parâmetros, buscando minimizar o erro de controle e otimizar a resposta dinâmica. O processo opera em malha fechada, com realimentação contínua do sinal de saída e reavaliação dos parâmetros sempre que necessário (Rajinikanth; Latha, 2012).

2.7 FUNÇÃO TRANSFERÊNCIA

Na teoria de controle, as funções de transferência são empregadas para representar as relações de entrada e de saída de componentes ou de sistemas que podem ser descritos por equações diferenciais lineares invariantes no tempo (Ogata, 2010). As funções de transferência se aplicam apenas a sistemas lineares e invariantes no tempo, com as condições iniciais assumidas como zero (Dorf; Bishop, 2017; Ogata, 2010).

Para um sistema linear, invariante no tempo, a função de transferência $G(s)$, definida em Equação 3:

$$G(s) = \frac{Y(s)}{X(s)} \quad (3)$$

onde $X(s)$ representa a transformada de Laplace da entrada e $Y(s)$ representa a transformada de Laplace da saída. A função de transferência evidencia a influência dos polos e zeros na resposta temporal do sistema, sendo os polos responsáveis pela dinâmica natural e os zeros por efeitos diretos na forma do sinal de saída. Além disso, a análise de $G(s)$ possibilita a aplicação de técnicas fundamentais, como projeto de controladores PID, lugar das raízes, análise de resposta em frequência e critérios de estabilidade, tais como os de Routh-Hurwitz e Nyquist (Ogata, 2010).

Segundo Ogata (2010), outra propriedade importante é que a representação por funções de transferência permite a composição modular de sistemas complexos por meio de diagramas de blocos e álgebra de blocos, facilitando a modelagem de sistemas de controle em malha aberta e malha fechada. A partir de $G(s)$, é possível prever o comportamento da planta frente a perturbações, analisar sensibilidade e projetar compensadores que atendam requisitos específicos de desempenho, como tempo de acomodação, sobressinal e erro em regime permanente. Dessa forma, o uso de funções de transferência constitui uma das bases conceituais mais importantes da engenharia de controle moderna.

3 METODOLOGIA

3.1 MÉTODOS E TÉCNICAS UTILIZADOS

Como índices de desempenho foram utilizados apenas máximo de sobressinal, tempo de acomodação e erro em regime permanente, tendo em vista que são as principais informações utilizadas no projeto de controladores, como visto em M. Zahir et al., (2018) e Chen, Ma e Yun, (2013).

Para garantir a reprodutibilidade dos resultados obtidos pelo GA, foi fixada a semente do gerador de números aleatórios utilizando o comando `rng(1, 'twister')` no MATLAB. Assim, todos os experimentos puderam ser repetidos sob as mesmas condições iniciais. O passo de tempo utilizado nas simulações foi de 0,001s. As métricas foram extraídas com um tempo de simulação de 10 segundos.


As funções de custo foram implementadas por meio do cálculo numérico da integral correspondente, utilizando o operador `trapz()` do MATLAB. Esse operador aplica a regra do trapézio para realizar a integração numérica de vetores discretos, o que permite estimar a integral contínua do erro com base nos dados simulados da resposta temporal.

Para o cálculo do tempo de acomodação e do erro em regime permanente, adotou-se o critério de 2%. Nesse critério, considera-se que a resposta do sistema está acomodada quando permanece de forma contínua dentro de uma banda de $\pm 2\%$ em torno do valor final da saída. Assim, o tempo de acomodação corresponde ao instante em que a resposta entra nessa faixa e não mais a ultrapassa até o final da simulação.

Da mesma forma, o erro em regime permanente foi obtido avaliando-se a diferença absoluta entre o valor final da resposta e o valor de referência (degrau unitário). Como o regime permanente deve ocorrer após o amortecimento das oscilações transitórias, o erro foi calculado considerando o valor final da simulação.

Todos os sistemas de controle foram projetados de maneira semelhante, conforme Figura 5.

Figura 5 - Representação genérica do sistema de controle



Fonte: Autor, 2025

O sistema opera em malha fechada, uma vez que o AG necessita da informação do erro (diferença entre a entrada de referência e a saída do sistema) para ajustar os parâmetros do controlador. A estrutura é composta por uma entrada unitária, um somador que calcula o erro, um controlador PID ideal responsável pelo processamento desse erro, e a função de transferência $G(s)$, cuja resposta produz a saída do sistema.

3.1.1 MÉTODOS DE ABORDAGEM

A presente pesquisa configura-se como aplicada, uma vez que busca gerar conhecimentos voltados à resolução de problemas concretos relacionados ao desempenho de controladores PID. Trata-se de uma abordagem de natureza quantitativa, pois se fundamenta na mensuração de variáveis numéricas e na aplicação de métodos computacionais de simulação para a análise do comportamento dos sistemas controlados.

Quanto aos objetivos, o estudo é classificado como uma pesquisa experimental, pois envolve a manipulação deliberada de variáveis independentes, como os parâmetros do algoritmo genético (tamanho da população, taxa de mutação e *crossover*), com o propósito de observar seus efeitos sobre variáveis dependentes, como tempo de resposta, erro em regime permanente e estabilidade do sistema (GIL, 2008).

3.1.2 MÉTODOS DE PROCEDIMENTO

Quanto aos procedimentos metodológicos, trata-se de uma pesquisa experimental. Foram manipulados propositalmente os parâmetros do algoritmo genético para verificar seus efeitos sobre o desempenho do sistema controlado. A experimentação ocorreu em ambiente de simulação, respeitando critérios de controle e repetibilidade, conforme orientações de Gil (2008).

3.1.3 TÉCNICA DE COLETA DE DADOS

A coleta de dados foi realizada por meio de simulações computacionais no ambiente MATLAB, utilizando modelos matemáticos de sistemas dinâmicos representativos de processos industriais. A cada simulação, foram coletados indicadores de desempenho do sistema controlado, como sobressinal, tempo de acomodação e erro em regime permanente. As funções de custo utilizadas foram discutidas no subcapítulo 2.4.

3.1.4 ANÁLISE DE DADOS

Os dados obtidos nas simulações foram analisados por meio de estatística descritiva e comparação gráfica. A análise baseou-se na comparação de desempenho entre diferentes configurações do algoritmo genético aplicadas a controladores PID. Essa análise permitiu verificar a hipótese de influência dos parâmetros do algoritmo na capacidade de otimização dos parâmetros de controle, como demonstrado nos estudos de Brunton e Kutz (2022) e Chen, Ma e Yun (2013).

3.2 MATERIAIS E EQUIPAMENTOS

Foram utilizados os seguintes materiais e equipamentos para a realização do trabalho:

- Software MATLAB R2018b: ambiente computacional utilizado para desenvolver os modelos de simulação e implementar os algoritmos de controle e otimização.
- Computador com processador Intel i5, 16 GB de RAM e sistema operacional Windows 10: equipamento necessário para suportar a execução das simulações com desempenho adequado.
- Modelos matemáticos de sistemas: utilizados para representar os sistemas sob controle.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

As simulações foram feitas utilizando funções de transferência disponíveis na literatura, tendo em vista que o presente trabalho objetiva apenas a utilização do algoritmo genético como forma de encontrar os valores das constantes de controle.

4.1 PRIMEIRO SISTEMA

A primeira função escolhida foi a Equação 4, que representa um sistema subamortecido de terceira ordem e pode ser encontrada em Ogata (2010), p. 525, Figura 8.6.

$$G(s) = \frac{1}{s(s+1)(s+5)} \quad (4)$$

Os parâmetros utilizados no GA para o primeiro sistema seguem na Tabela 2.

Tabela 2 - Parâmetros do Algoritmo Genético

População	30
Máx. de Gerações	100
Limite inferior	[0 0 0]
Limite superior	[25 30 10]
Função de seleção	Seleção por torneio
Tamanho Torneio	4
Função <i>Crossover</i>	<i>Crossoverintermediate</i>
Taxa de elitismo	0,1
Critério de parada	20 gerações

Fonte: Autor, 2025

Os valores de limite superior foram decididos com base na regra de sintonia Ziegler-Nichols, encontrado em Ogata (2010), p. 526. Os valores de limite superior e inferior são cruciais para reduzir o tempo de execução do algoritmo, pois limitam o espaço de busca.

Uma vez executado o algoritmo, os resultados, para cada uma das funções de custo, podem ser vistos na Tabela 3.


Tabela 3 - Índices de desempenho do sistema controlado.

Função de custo	K_p	K_i	K_d	Custo mín.	Máx. Sobressinal (%)	Acomodação (s)	Erro em regime permanente	Gerações
IAE	9,930	0,000274	10,00	0,526	1,588	1,170	1,34E-05	100
ISE	14,827	0,000130	10,00	0,341	12,411	2,458	2,96E-06	73
ITAE	19,016	8,008971	10,00	0,865	33,265	2,981	9,80E-05	48
ITSE	11,323	0,001533	10,00	0,081	4,859	2,265	6,05E-05	68
Z-N	18	12,811	6,3223	NA	61,873	NaN	0,02104	NA

Fonte: Autor, 2025

Na Tabela 3 foram adicionados os índices de desempenho utilizando o método de Ziegler-Nichols (Z-N), a fim de comparação. Os resultados do mesmo foram obtidos através do MATLAB, com os parâmetros PID fornecidos por Ogata (2010), p. 526.

A resposta ao degrau unitário, para cada uma das funções de custo, pode ser vista na Figura 6.

Figura 6 - Reposta ao degrau unitário com parâmetros PID otimizados.

Fonte: Autor, 2025

Ao analisar a Tabela 3 e Figura 6, observa-se que todos os controladores obtidos por meio do algoritmo genético apresentaram desempenho significativamente superior ao método empírico de Ziegler–Nichols, o qual resultou em uma resposta com máximo sobressinal de 61,87% e comportamento altamente oscilatório, não apresentando estabilização nos dez segundos de simulação.


Entre as funções de custo, o IAE apresentou o melhor desempenho global, com sobressinal máximo de apenas 1,588%, tempo de acomodação de 1,17s e erro em

regime permanente praticamente nulo ($1,34 \times 10^{-5}$). Esses resultados evidenciam que o critério IAE promoveu uma resposta rápida e bem amortecida, com mínima oscilação e alta estabilidade.

O ISE obteve o menor erro em regime permanente ($2,96 \times 10^{-6}$), entretanto, com um sobressinal maior que o IAE (12,411%) e um tempo de acomodação mais longo (2,458s). O ITAE obteve 33,265% de sobressinal e tempo de acomodação de 2,981s, os maiores entre as funções analisadas. O ITSE obteve desempenho intermediário, com sobressinal de 4,859% e tempo de acomodação de 2,265s. Todas as funções de custo obtiveram valores em regime permanente próximos a zero.

A evolução dos valores dos parâmetros PID pode ser vista na Figura 7.

Figura 7 - Evolução dos Parâmetros PID por Função de Custo



Fonte: Autor, 2025


Através da Figura 7, observa-se que o ganho proporcional (Figura 7a), para IAE, ISE e ITSE, apresenta uma tendência decrescente ao longo das gerações, contrários a tendência crescente de ITAE. O IAE apresentou uma convergência mais lenta, com a simulação atingindo o máximo de gerações, com valor de 9,930. ISE atingiu o valor 14,827, com o valor convergindo em 73 gerações. ITAE apresentou o maior valor para a constante proporcional (19,016) e o menor tempo de simulação,

com o valor convergindo em 48 gerações. ITSE atingiu o valor de convergência (11,323) em 68 gerações.

O ganho integral (Figura 7b), por sua vez, apresenta uma rápida convergência para valores muito baixos em quase todas as funções de custo, exceto no ITAE, que manteve um valor de 8,008971. As demais funções tenderam a ganhos integrais muito pequenos, o que indica um controle mais dependente da ação proporcional e derivativa. Já o ganho derivativo (Figura 7c) apresenta comportamento mais estável, convergindo rapidamente para o valor máximo de 10, em todos os casos.

A evolução do valor de custo, para cada uma das funções de custo pode ser visto na Figura 8.

Figura 8 - Comparação da convergência de cada função de custo



Fonte: Autor, 2025

Observa-se na Figura 8 que todas as funções apresentaram tendência de redução do valor de custo nas primeiras gerações, indicando uma fase inicial de exploração do espaço de busca. Após esse período, o algoritmo entra em regime de convergência estável, caracterizado por pequenas variações no valor da função de custo.

A função ITSE foi a que apresentou melhor desempenho global, atingindo o menor valor de custo ($\approx 0,081$) e estabilizando rapidamente, por volta da 20ª geração. Esse comportamento evidencia que o ITSE proporcionou uma otimização eficiente, resultando em respostas com bom equilíbrio entre tempo de acomodação e sobressinal.

Em seguida, a função ISE também demonstrou estabilidade e convergência consistente, embora com valor final de custo mais elevado ($\approx 0,341$). A função IAE, por outro lado, apresentou uma convergência mais lenta e gradual, com redução progressiva do custo até estabilizar em torno de 0,526 após aproximadamente 60 gerações.

A função ITAE apresentou valor de custo relativamente alto ($\approx 0,865$), além de convergir mais rapidamente (cerca da 40ª geração) o que pode ser indícios de que atingiu uma máxima local prematuramente.

4.2 SEGUNDO SISTEMA

Como segunda função de transferência foi escolhida a Equação 5, uma planta linear de quinta ordem, com comportamento multimodal e potencialmente subamortecido. Sua escolha se deriva do fato dos autores também utilizarem algoritmos otimização evolucionários (Particle Swarm Optimization – PSO e Algoritmo Genético) possibilitando assim uma comparação de desempenho, em paralelo com a comparação com o método de Ziegler-Nichols. A função de transferência pode ser encontrada em Samakwong e Assawinchaichote, (2016).

$$G(s) = \frac{25,28s^2 + 22,20s + 3}{s^5 + 16,6s^4 + 25,41s^3 + 17,2s^2 + 12s + 1} \quad (5)$$

Os parâmetros utilizados no sistema seguem na Tabela 4.

Tabela 4 - Parâmetros do Algoritmo Genético

População	30
Máx. de Gerações	100
Limite inferior	[0 0 0]
Limite superior	[6 10 7]
Função de seleção	Seleção por torneio
Tamanho Torneio	4
Função Crossover	Crossoverintermediate
Taxa de elitismo	0,1
Crítério de parada	20 gerações

Fonte: Autor, 2025

Os valores para limites superiores foram definidos com base nos parâmetros disponibilizados pelos autores Samakwong e Assawinchaichote (2016).

Com os parâmetros definidos, a otimização através do AG levou à Tabela 5.


Tabela 5 - Índices de desempenho do segundo sistema

Função de custo	K_p	K_i	K_d	Custo mín.	Máx. Sobressinal (%)	Acomodação (s)	Erro em regime permanente	Gerações
IAE	2,694	4,389	7,000	0,154	9,074	0,666	0,0035	63
ISE	3,020	4,523	7,000	0,077	9,552	0,632	0,0035	49
ITAE	2,531	4,432	7,000	0,278	8,854	0,677	0,0036	50
ITSE	2,452	4,353	6,998	0,005	8,724	0,689	0,0034	36

Fonte: Autor, 2025

Com os valores dos parâmetros PID otimizados, os resultados à uma entrada unitária, para cada uma das funções de custo podem ser vistos na Figura 9.

Figura 9 - Comparação das Respostas ao Degrau




Fonte: Autor, 2025.

A resposta ao degrau foi similar para todas as funções de custo. Os valores de sobressinal foram próximos uns dos outros, na ordem de 9%, com destaque para ITSE, que teve o menor valor registrado (8,724%) e ISE, com 9,552%, sendo o maior dentre os analisados. No quesito tempo de acomodação, a função ISE apresentou o menor valor, com 0,632 s, vale ressaltar, no entanto, que todas as funções de custo analisadas obtiveram valores entre 0,6 e 0,7 segundos. O erro em regime permanente foi praticamente nulo em todos os casos, com valores na ordem de 0,003, sendo ITSE o que apresentou o menor valor (0,0034).

O número de gerações até a convergência apresentou maior variedade em relação aos outros índices de desempenho, sendo que nenhuma função atingiu o valor máximo de gerações (100). O ITSE convergiu com 36 gerações, menor valor registrado, seguido do ISE (49), ITAE (50) e IAE (63).

Figura 10 - Evolução dos parâmetros PID do segundo sistema



Fonte: Autor, 2025.

Através da Figura 10, observa-se que o comportamento dos parâmetros apresenta padrões distintos ao longo das gerações em função da métrica utilizada no algoritmo genético.


No caso do ganho proporcional (Figura 10a), nota-se que as funções de custo IAE, ISE e ITSE exibem uma tendência predominantemente decrescente, ajustando-se gradualmente até atingir a convergência em torno de valores similares após a 20ª geração. A função ITAE, por outro lado, demonstra um comportamento oposto, iniciando com valores menores e apresentando uma tendência crescente até estabilizar. Além disso, observa-se que o IAE apresenta a convergência mais lenta, alcançando o valor final apenas após atingir o limite máximo de gerações. Já o ISE converge para seu valor final em aproximadamente 73 gerações, enquanto o ITSE estabiliza em torno da 68ª geração. O ITAE apresenta a convergência mais rápida entre as quatro métricas, estabilizando ainda na faixa de 48 gerações.

Em relação ao ganho integral (Figura 10b), verifica-se uma convergência muito rápida para valores próximos de quatro em praticamente todas as funções de custo.

O parâmetro (Figura 10c) apresenta o comportamento mais estável entre os três parâmetros, mostrando uma rápida ascensão inicial seguida de convergência para valores próximos ao máximo permitido (7). Essa tendência é observada consistentemente para todas as funções de custo avaliadas, indicando que a ação derivativa desempenha um papel relevante no desempenho ótimo identificado pelo algoritmo genético, independentemente da métrica utilizada.

A Figura 11 apresenta a comparação direta da evolução do custo ao longo das gerações para as quatro funções de custo aplicadas no processo de otimização por algoritmo genético. Observa-se que cada métrica apresenta uma dinâmica distinta de convergência, refletindo diferentes prioridades no processo de minimização do erro.

Figura 11 - Comparação do custo das funções



Fonte: Autor, 2025

A função ITSE apresenta o menor valor de custo ao longo de toda a simulação, convergindo rapidamente já nos primeiros instantes e mantendo-se praticamente estável até o final. A função ISE, por sua vez, apresenta um custo intermediário e relativamente estável, com leve redução nas primeiras gerações antes de atingir a convergência.

Já a função IAE exibe uma redução mais lenta do valor de custo, apresentando uma curva gradualmente decrescente até aproximadamente a 20ª geração, quando então estabiliza. Por fim, o ITAE apresenta o maior valor de custo dentre as quatro funções, embora demonstre também uma tendência clara de convergência. A curva

inicia com um valor significativamente mais alto e apresenta uma redução gradativa até estabilizar.

A fim de comparar a otimização do presente trabalho com o trabalho de Samakwong e Assawinchaichote (2016), optou-se por traçar o gráfico apenas com a função de custo que apresentou os melhores índices de desempenho. Dado o exposto anteriormente, a função de custo escolhida para ser comparada foi a ITSE, que apresentou os menores valores de custo, sobressinal e erro em regime permanente. A Tabela 6 apresenta a comparação da mesma com os valores do trabalho original.


Tabela 6 - Comparação das Respostas ao Degrau

Método	K_p	K_i	K_d	Máx. Sobressinal (%)	Acomodação (s)	Erro em regime permanente
ITSE	2,452	4,353	6,998	8,724	0,689	0,0034
PSO	2,2573	2,2573	2,2573	1,241	4,6262	0,0093
AG – Lit.	5,9179	5,9179	5,9179	13,067	1,4749	0,0011
Z-N	3,9563	3,9563	3,9563	58,429	NaN	NaN

Fonte: Autor, 2025

Tendo em vista a falta de informações referentes a simulação no trabalho de referência, foram aplicados aos parâmetros encontrados pelos autores as condições de análise do presente estudo, a fim de garantir uma comparação justa. A resposta ao degrau pode ser vista na Figura 12. A fim de facilitar o entendimento, as respostas do algoritmo genético utilizado no trabalho de Samakwong e Assawinchaichote (2016) será referenciado como “AG – Literatura” ou simplesmente “AG – Lit.”.

Figura 12 - Comparação com os resultados encontrados na literatura



Fonte: Autor, 2025

Utilizando como base os resultados da Tabela 6 e Figura 12, a comparação das respostas ao degrau revela diferenças significativas entre os métodos de sintonia considerados. O método PSO apresentou o melhor desempenho geral, com o menor valor de sobressinal (1,241%) entre os quatro avaliados. O método ITSE exibiu o segundo menor sobressinal (8,724%), mostrando uma resposta extremamente bem amortecida em comparação aos demais. Já o controlador obtido por AG – Lit. apresentou um sobressinal moderado, de 13,067%, enquanto o método de Ziegler–Nichols apresentou o maior valor dentre todos, com 58,429%, evidenciando sua característica conhecida de respostas mais agressivas e com maior oscilação.

No quesito tempo de acomodação, observou-se vantagem para o ITSE, que apresentou o menor valor registrado (0,689 s). O método AG – Lit. também obteve um resultado satisfatório, com tempo de 1,4749 s, enquanto o PSO apresentou o maior tempo entre os controladores estáveis (4,6262 s). O método de Ziegler–Nichols não atingiu acomodação dentro dos limites de 2%, resultando em valor não definido (NaN), o que reforça seu comportamento oscilatório para a planta em questão.

Quanto ao erro em regime permanente, todos os métodos que estabilizaram o sistema apresentaram valores muito pequenos, na ordem de milésimos. O menor valor foi obtido pelo AG – Lit. (0,0011), seguido por ITSE (0,0034) e PSO (0,0093). O método Ziegler–Nichols não apresentou erro de regime permanente válido devido à falta de acomodação dentro da janela especificada.

4.3 TERCEIRO SISTEMA

Para o terceiro sistema, foi escolhido como trabalho de referência M. Zahir et al., (2018). A função de transferência representa um sistema de segunda ordem e representa um motor de corrente contínua (Equação 6).

$$G(s) = \frac{104,9}{s^2 + 103,5s + 2617} \quad (6)$$

A presença de um termo proporcional s (com coeficiente 103,5) e de um termo constante (2617) indica que o sistema apresenta amortecimento elevado, podendo situar-se na região de sobre amortecimento ou amortecimento crítico.

A escolha do trabalho de referência se dá, também, pois os autores sugerem uma função de custo modificada, com o objetivo de aumentar a eficiência e resposta do

algoritmo genético e disponibilizam os parâmetros utilizados no algoritmo, possibilitando assim uma comparação precisa com o proposto no presente trabalho.

Os parâmetros utilizados no GA para o terceiro sistema seguem na Tabela 7.

Tabela 7 - Parâmetros utilizados no algoritmo

População	30
Máx. de Gerações	100
Limite inferior	[0 0 0]
Limite superior	[210 19000 2]
Função de seleção	Seleção por torneio
Tamanho Torneio	4
Função <i>Crossover</i>	<i>Crossoverintermediate</i>
Taxa de elitismo	0,1
Critério de parada	20 gerações
Tempo de simulação	0,2 segundos

Fonte: Autor, 2025

Os valores de limite superior foram baseados no algoritmo de Ziegler-Nichols, disponível no trabalho de referência. A mudança no tempo de simulação se dá devido ao sistema apresentar uma rápida resposta, tornando desnecessário o uso de um tempo mais elevado.


Uma vez aplicado o algoritmo, os índices de desempenho podem ser vistos na Tabela 8.

Tabela 8 - Índices de desempenho para o terceiro sistema

Função de custo	K_p	K_i	K_d	Custo mín.	Máx. Sobres-sinal (%)	Acomodação (s)	Erro em regime permanente	Gerações
IAE	203,722	5057,387	1,930	0,00493	0,000	0,017	9,17E-07	59
ISE	209,901	8886,584	1,955	0,00274	4,310	0,052	2,33E-05	22
ITAE	209,728	5452,763	1,853	0,00002	0,063	0,014	5,29E-07	21
ITSE	198,077	7013,468	1,960	0,00001	2,259	0,046	2,09E-06	21

Fonte: Autor, 2025

Com os valores dos parâmetros PID otimizados, os resultados à uma entrada unitária, para cada uma das funções de custo podem ser vistos na Figura 13.

Figura 13 - Reposta ao degrau do terceiro sistema com parâmetros otimizados

Fonte: Autor, 2025

Entre os controladores avaliados, observa-se que o critério ITSE apresentou o melhor desempenho global, alcançando o menor valor de custo mínimo (0,00001). Esse resultado indica elevada eficiência do algoritmo para esse tipo de função de penalização. O controlador resultante apresenta um sobressinal moderado (2,259%) e um tempo de acomodação reduzido (0,046 s), revelando comportamento transitório rápido e bem amortecido. Além disso, o erro em regime permanente ($2,09 \times 10^{-6}$) é extremamente pequeno, demonstrando excelente precisão. O número de gerações necessárias para a convergência (21) evidencia que o método encontra soluções de alta qualidade de forma eficiente.


O critério ITAE destacou-se como o segundo melhor método, alcançando um custo mínimo igualmente baixo (0,00002). O sobressinal obtido é o menor dentre todos os controladores analisados (0,063%), o que caracteriza um comportamento bastante suave e altamente amortecido, conforme esperado para esse tipo de função de custo, que penaliza fortemente erros persistentes. O tempo de acomodação também é o menor do grupo (0,014 s), indicando resposta extremamente rápida. O erro estacionário ($5,29 \times 10^{-7}$) é praticamente nulo, reforçando a elevada precisão do controlador.

O controlador otimizado pelo critério IAE apresentou desempenho intermediário, com custo final de 0,00493. Esse método resultou em um sobressinal totalmente suprimido (0%), característica típica de soluções mais conservadoras, que privilegiam estabilidade e robustez em detrimento de agressividade. O tempo de acomodação (0,017 s) é bastante reduzido e compatível com um sistema altamente amortecido. O

erro em regime permanente ($9,17 \times 10^{-7}$) permanece próximo de zero, evidenciando excelente precisão. O método demandou 59 gerações para convergir, o maior entre os quatro, sugerindo maior complexidade ou superfície de solução menos favorável para esse critério específico.

Por fim, o critério ISE apresentou o comportamento menos satisfatório dentre os avaliados, apesar de alcançar um custo mínimo significativamente baixo (0,00274). Esse método gerou o controlador mais agressivo, exibindo o maior sobressinal (4,310%) e um tempo de acomodação superior aos demais (0,052 s). Esses valores refletem a tendência do critério ISE de penalizar fortemente erros de grande magnitude, mas permitir oscilações transitórias. O erro estacionário ($2,33 \times 10^{-5}$), embora baixo, é maior do que o observado nos outros métodos. A convergência em 22 gerações demonstra eficiência computacional, mas não se traduziu em melhor desempenho dinâmico. A evolução dos parâmetros pode ser vista na Figura 14.

Figura 14 - Evolução dos parâmetros PID no terceiro sistema



Fonte: Autor, 2025

Na evolução do ganho proporcional, Figura 14a, nota-se que todas as funções de custo iniciam o processo com uma breve região de variação nas primeiras gerações, apresentando oscilações moderadas antes de atingir estabilidade. Após essa fase inicial, as curvas convergem de forma progressiva para valores próximos entre si, estabilizando-se por volta da 20ª geração. As métricas exibem trajetórias


muito similares, com diferenças pequenas tanto no valor final quanto no ritmo de aproximação.

Em relação ao ganho integral (Figura 14b), observa-se um comportamento marcadamente distinto. Todas as métricas apresentam valores iniciais bastante elevados, seguidos por uma queda acentuada ao longo das primeiras gerações. Essa redução ocorre de forma rápida e relativamente uniforme, levando as curvas a convergirem antes da 15ª geração. A partir desse ponto, os valores permanecem praticamente constantes até o fim das iterações, indicando forte consenso entre os diferentes critérios de desempenho.

Por fim, a evolução do ganho derivativo (Figura 14c) mostra-se como a mais estável e uniforme entre os três parâmetros. Todas as funções de custo exibem um crescimento suave nas primeiras gerações, seguido por um processo de estabilização gradual. As curvas convergem para valores próximos de 1,5 a 2,0, com pouquíssimas oscilações ao longo da evolução. A proximidade entre as curvas indica que a ação derivativa exerce influência moderada, porém consistente no processo de otimização. Esse comportamento reforça a ideia de que, para o terceiro sistema, o impacto do termo derivativo é bem capturado pelo algoritmo genético e não provoca divergências significativas entre as funções de custo, garantindo estabilidade no ajuste final.

A evolução dos valores das funções de custo pode ser vista na Figura 15.

Figura 15 - Evolução do valor das funções de custo do terceiro sistema



Fonte: Autor, 2025

Na análise da evolução das funções de custo para o terceiro sistema, observa-se inicialmente que a métrica IAE apresenta o maior valor de custo entre as quatro funções avaliadas. Sua trajetória caracteriza-se por uma queda lenta e progressiva, sem variações abruptas. Apesar de exibir uma tendência de redução contínua, a convergência ocorre apenas de forma tardia, estabilizando-se próximo da 35ª geração. Esse comportamento indica que o IAE responde de maneira menos sensível às melhorias introduzidas pelo algoritmo genético, demandando um número maior de gerações para atingir uma região de mínimo relativamente estável.

A função ISE, por sua vez, apresenta um comportamento mais eficiente. Após uma pequena queda inicial, estabiliza-se rapidamente, mantendo um valor praticamente constante a partir das primeiras 10 gerações. Embora o custo final obtido pelo ISE seja inferior ao do IAE, sua curva demonstra pouca variação depois da estabilização, sugerindo que o algoritmo encontra o mínimo local de forma precoce, sem grandes ajustes posteriores. Ainda assim, seu desempenho permanece intermediário quando comparado às funções ITAE e ITSE.

A métrica ITAE destaca-se por uma redução mais pronunciada nas gerações iniciais. Sua curva apresenta a queda percentual mais significativa entre as quatro funções, atingindo um patamar estável por volta da 15ª geração. Apesar de apresentar um valor de custo superior ao do ITSE, a estabilização rápida e a expressiva resposta inicial indicam uma boa capacidade de captura do comportamento dinâmico do sistema, conferindo ao ITAE um desempenho satisfatório em termos de otimização.

Por fim, a função ITAE evidencia o melhor desempenho global. Desde as primeiras gerações, apresenta o menor valor absoluto de custo, além de convergir de forma extremamente rápida e praticamente sem oscilações. Uma vez estabilizada, a curva mantém-se praticamente inalterada, refletindo alta eficiência na minimização do erro ponderado no tempo. Esse comportamento indica que o ITAE é especialmente sensível às melhorias do algoritmo genético e se adequa com grande eficácia ao processo de otimização do terceiro sistema.

De forma geral, a comparação entre as funções de custo revela que o ITAE se destaca como a métrica mais eficiente, oferecendo não apenas o menor valor de custo final, mas também a convergência mais rápida e estável. Essa característica o torna o critério mais adequado para análises de desempenho subsequentes no estudo.

De maneira similar ao segundo sistema (pág. 31), a fim de comparar a otimização do presente trabalho com o trabalho de referência, optou-se por utilizar apenas a

função de custo que apresentou os melhores índices de desempenho. Dado o exposto anteriormente, a função de custo escolhida para ser comparada foi a ITAE. A Figura 9 apresenta a comparação da mesma com os valores do trabalho original.


Tabela 9 - Comparação dos parâmetros adquiridos com o trabalho original

Método	K_p	K_i	K_d	Máx. Sobressinal (%)	Acomodação (s)	Erro em regime permanente
Z-N	203,01	18545,0	0,5558	47,371	0,1240	0,0021
ITAEU	116,96	2999,40	1,0786	0,0000	0,0327	0,0024
ITAEM	549,45	7890,00	4,6080	0,0000	0,0071	0,0041
ITAE	209,728	5452,763	1,853	0,063	0,014	5,29E-07

Fonte: Autor, 2025

Onde Z-N, ITAE não modificado (ITAE *Unmodified*) e ITAE modificado (ITAE *Modified*) são provenientes do trabalho de M. Zahir et al., (2018) e ITAE representa os valores adquiridos no presente trabalho. A resposta do sistema controlado frente a uma entrada unitária pode ser vista na Figura 16.

Figura 16 - Comparação da resposta ao degrau unitário



Fonte: Autor, 2025

No que diz respeito ao máximo sobressinal, os métodos ITAEU e ITAEM se destacam, ambos apresentando sobressinal nulo (0%), evidenciando respostas totalmente amortecidas e sem oscilações. O método ITAE também obteve um desempenho bastante satisfatório, com sobressinal extremamente baixo (0,063%), indicando elevada suavidade na transição ao regime estacionário. Em contraste, o método de Ziegler–Nichols apresentou um sobressinal significativamente maior (47,371%), refletindo seu comportamento tipicamente agressivo e oscilatório.

Considerando o tempo de acomodação, novamente é possível observar vantagens nos métodos derivados de critérios integrais. O método ITAEM obteve o menor valor (0,0071 s), indicando uma resposta extremamente rápida e estável. Em seguida, aparece o ITAEU (0,0327 s) e o ITAE (0,014 s), ambos garantindo acomodação rápida e eficiente. O método Ziegler–Nichols apresentou o pior desempenho neste critério (0,1240 s), reforçando sua tendência a respostas mais lentas e oscilatórias quando comparado aos demais.

Quanto ao erro em regime permanente, todos os métodos forneceram resultados satisfatórios, com valores muito reduzidos. O melhor desempenho foi obtido pelo ITAE, que apresentou erro praticamente nulo ($5,29 \times 10^{-7}$), seguido pelos métodos ZN (0,0021), ITAEU (0,0024) e ITAEM (0,0041). As diferenças, embora pequenas, indicam que os métodos baseados em critérios integrais tendem a oferecer maior precisão, especialmente o ITAE.

CONCLUSÃO

O presente trabalho investigou a aplicação de AG na otimização de controladores PID em três sistemas dinâmicos distintos, todos analisados em ambiente de simulação. Os resultados obtidos permitem afirmar que o AG é uma técnica altamente eficaz para sintonia de controladores, atendendo plenamente aos objetivos propostos.

Em todos os sistemas testados o desempenho do controle PID, otimizado com o AG, apresentou desempenho superior quando comparado com o método de Ziegler-Nichols. Simultaneamente, nos três sistemas testados, o parâmetro derivativo (K_d) atingiu valores próximos, se não iguais, ao máximo definido pelo limite superior. Esse comportamento deriva do fato das funções de custo favorecerem a minimização do erro em regime permanente (todas são compostas por variações do somatório do erro em cada instante de tempo) e, uma vez que o um maior valor para K_d diminui o tempo de subida o controle, por consequência, faz com o que sistema atinja a estabilidade mais rapidamente, entretanto, observa-se que uma rápida resposta aumenta significativamente o sobressinal.

No primeiro sistema, o valor para K_i foi praticamente nulo para quase todos os casos, isso se deve ao sistema possuir o termo

$$\frac{1}{s}$$

o que dá ao sistema o comportamento do parâmetro integrador do controlador PID (Equação 1), tornando desnecessária a atuação do mesmo.

Observou-se também que o comportamento da convergência dos parâmetros do controlador (K_p , K_i , K_d) varia significativamente entre os sistemas analisados. No primeiro sistema, os valores de K_d convergiram rapidamente para o limite superior permitido (Figura 8). Já no terceiro sistema, o comportamento foi distinto: os valores de K_i apresentaram queda rápida e estabilização precoce.

No primeiro sistema o método Z–N apresentou um sobressinal de 61,87% e comportamento altamente oscilatório (Tabela 3), enquanto todas as funções de custo otimizadas via AG apresentaram respostas amortecidas e erros praticamente nulos. Assim, confirma-se a primeira hipótese: utilizar o AG como método de otimização dos parâmetros melhora o desempenho de um controlador PID.

No segundo sistema, mesmo com comportamento multimodal, o algoritmo convergiu rapidamente e produziu respostas com sobressinal inferior a 10% para

todas as funções de custo (Tabela 5). Além disso, a comparação com os resultados da literatura (Tabela 6) demonstrou que o método ITSE implementado no presente trabalho superou o algoritmo genético utilizado pelos autores originais, confirmando que o AG consegue encontrar soluções de alta qualidade mesmo em sistemas complexos. Isso reforça a segunda hipótese do trabalho. A diferença de desempenho pode ser explicada considerando uma diferente parametrização do AG, como valores diferentes de população, taxa de mutação, método de seleção, etc.

A influência dos parâmetros do AG pode ser visto no terceiro sistema, onde os autores do trabalho original não geraram a população inicial de forma aleatória, mas criaram uma população com genes igualmente espaçados entre os limites mínimo e máximo, aumentando assim artificialmente a diversidade genética. Simultaneamente, os autores utilizaram uma variação de ITAE (ITAEM), onde a implementação realizada apresentou menor erro em regime permanente e melhor equilíbrio entre sobressinal e tempo de acomodação (Tabela 9).

Outro resultado importante diz respeito ao papel da função de custo na característica da resposta final. No primeiro sistema, por exemplo, funções como ITAE e ITSE penalizaram de forma mais intensa erros persistentes, resultando em respostas mais rápidas, porém com maiores sobressinais. Já o IAE, ao penalizar apenas o erro absoluto, produziu respostas mais suaves.

A literatura também demonstra que essas funções podem ser modificadas para atender requisitos específicos do processo. Um exemplo disso é o trabalho de M. Zahir et al. (2018), que propôs versões modificadas da função ITAE para melhorar o desempenho do algoritmo genético, conforme discutido e comparado no terceiro sistema (4.3) deste trabalho.

Outro aspecto observado foi a relação entre o espaço de busca e a eficiência da otimização. No primeiro sistema, limites superiores definidos com base no método de Ziegler–Nichols permitiram ao AG focar em uma região de parâmetros fisicamente coerente e evitar buscas desnecessárias. Já no terceiro sistema, onde os limites superiores eram muito amplos devido aos valores elevados de K_i reportados na literatura, observou-se um aumento na variabilidade inicial dos parâmetros.

Adicionalmente, a comparação com os métodos da literatura mostrou que, mesmo ao adotar configurações semelhantes, o desempenho do AG pode variar significativamente. No segundo sistema, por exemplo, os resultados obtidos com ITSE foram superiores aos do AG implementado pelos autores de referência, mesmo

ambos utilizando limites de busca semelhantes. Isso demonstra que fatores como a semente do gerador aleatório, a implementação específica do cruzamento e mutação, e a resolução temporal da simulação possuem papel direto no resultado final.

De forma geral, conclui-se que o algoritmo genético é uma ferramenta robusta, flexível e altamente eficaz para a otimização de controladores PID, especialmente em sistemas onde métodos tradicionais apresentam limitações. A capacidade do AG de explorar espaços multimodais, escapar de mínimos locais e adaptar-se a diferentes perfis dinâmicos torna-o particularmente adequado para plantas reais sujeitas a incertezas.

REFERÊNCIAS

AHMADI, Aghil; ESFANJANI, Reza Mahboobi. Improved Machine Learning based Approach for Autotuning PID Controller using Genetic Algorithms and Parallel Processing: IMPROVED MACHINE LEARNING APPROACH FOR AUTOTUNING PID. **Journal of Scientific & Industrial Research (JSIR)**, v. 84, n. 03, p. 269–277, 11 mar. 2025.

BHARAT, Sangram *et al.* A Review on Tuning Methods for PID Controller. **Asian Journal For Convergence In Technology (AJCT) ISSN -2350-1146**, 11 abr. 2019.

BRUNTON, Steven L.; KUTZ, J. Nathan. **Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control**. Disponível em: <<https://www.cambridge.org/highereducation/books/data-driven-science-and-engineering/6F9A730B7A9A9F43F68CF21A24BEC339>>, 2022. Acesso em: 5 jun. 2025.

CHEN, Ying; MA, Yong-jie; YUN, Wen-xia. Application of Improved Genetic Algorithm in PID Controller Parameters Optimization. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 11, n. 3, p. 1524–1530, 1 mar. 2013.

DORF, Richard C.; BISHOP, Robert H. **Modern Control Systems**. [S.l.]: Pearson International, 2017.

ELTAYEB, Ahmed *et al.* Comparative Analysis: Fractional PID vs. PID Controllers for Robotic Arm Using Genetic Algorithm Optimization. **Automation**, v. 5, n. 3, p. 230–245, set. 2024.

FLEMING, P. J.; PURSHOUSE, R. C. Evolutionary algorithms in control systems engineering: a survey. **Control Engineering Practice**, v. 10, n. 11, p. 1223–1241, 1 nov. 2002.

JOSEPH, Stephen Bassi *et al.* Metaheuristic algorithms for PID controller parameters tuning: review, approaches and open problems. **Heliyon**, v. 8, n. 5, 1 maio 2022.

MATHWORKS. *Genetic algorithm options*. Disponível em: <https://www.mathworks.com/help/gads/genetic-algorithm-options.html#f7820>. Acesso em: 31 out. 2025.

ZAHIR, M. A. A. *et al.* Genetic Algorithm Optimization of PID Controller for Brushed DC Motor. *In*: HASSAN, Mohd Hasnun Arif (org.). Singapore: Springer, 2018.

NOUMAN, Khan; ASIM, Zaman; QASIM, Khan. Comprehensive Study on Performance of PID Controller and its Applications. *In*: 2018 2ND IEEE ADVANCED INFORMATION MANAGEMENT, COMMUNICATES, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (IMCEC). **2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control**

Conference (IMCEC). maio 2018. Disponível em:
<<https://ieeexplore.ieee.org/abstract/document/8469267>>. Acesso em: 5 jun. 2025

OGATA, Katsuhiko. **Engenharia de controle moderno**. 5. ed. São Paulo: Pearson Prentice Hall, 2010. ISBN 8576058103.

PATEL, H. B.; CHAPHEKAR, Mrs S. N. Developments in PID Controllers: Literature Survey. **IJEIR**, v. 1, n. 5, p. 425–430, 2012.

SAMAKWONG, Tanasak; ASSAWINCHAICHOTE, Wudhichai. PID Controller Design for Electro-hydraulic Servo Valve System with Genetic Algorithm. **Procedia Computer Science**, 2016 International Electrical Engineering Congress, iEECON2016, 2-4 March 2016, Chiang Mai, Thailand. v. 86, p. 91–94, 1 jan. 2016.

SOMEFUN, Oluwasegun Ayokunle; AKINGBADE, Kayode; DAHUNSI, Folasade. The dilemma of PID tuning. **Annual Reviews in Control**, v. 52, p. 65–74, 1 jan. 2021.

WANG, Liuping. **PID Control System Design and Automatic Tuning using MATLAB/Simulink**. 1. ed. [S.l.]: Wiley, 2020.

WANG, Qing-Guo *et al.* PID tuning for improved performance. **IEEE Transactions on Control Systems Technology**, v. 7, n. 4, p. 457–465, jul. 1999.