

Uso de Metaheurísticas para projeto de controladores industriais PID em sistema de controle de velocidade

Lucas L. C. Batista¹, Lucas M. Rufini¹, José M. A. Junior¹

¹Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal do Piauí (UFPI)
CEP: 64049-550 – Teresina – PI – Brazil

archerfh@ufpi.edu.br, lucasmourarufini@gmail.com, jmjuniior@ufpi.edu.br

Abstract. *Metaheuristics are optimization algorithms able to find suboptimal solutions in a short time, applicable in Power Systems, Communications and Industrial Systems' Control. This paper presents the performance of the metaheuristics Particle Swarm Optimization (PSO), its accelerated variant (APSO) and Firefly Algorithm (FA) applied to optimize the design of a PID controller in a didactic speed control industrial process. The PID controllers tuned by metaheuristics were compared to classic controllers, and had better results than classic control algorithms.*

Resumo. *Metaheurísticas são algoritmos de otimização capazes de encontrar soluções sub-ótimas em pouco tempo, com aplicações em Potência, Comunicações e Controle de processos industriais. Este trabalho apresenta o desempenho de metaheurísticas do tipo Algoritmo de Enxame de Partículas (PSO), sua variante acelerada (APSO) e Algoritmo Firefly (FA) aplicados na otimização do projeto dos parâmetros de um controlador PID utilizado em um processo industrial didático de controle de velocidade. Os controladores PID projetados por metaheurísticas foram comparados a controladores clássicos e obtiveram melhores resultados que algoritmos de controle clássicos.*

1. Introdução

Problemas de otimização são problemas matemáticos que envolvem minimizar ou maximizar funções objetivo. Para resolver problemas de otimização, são necessárias técnicas de busca eficientes como as metaheurísticas, que são algoritmos estocásticos modernos inspirados na natureza que utilizam uma combinação de busca local e movimento randômico para encontrar soluções sub-ótimas com base em uma função objetivo, com menor custo computacional e em pouco tempo [Yang, 2011].

As metaheurísticas utilizam conceitos de algoritmos populacionais, que utilizam agentes múltiplos para interagir e encontrar trajetórias para soluções ótimas [Yang, 2011], como também associam elementos de heurísticas, que são estratégias para produzir soluções aceitáveis para problemas complexos em tempo razoável ([Rao, 2009] apud [Vidal et al., 2016]). As metaheurísticas podem ser consideradas estratégias que guiam e modificam heurísticas para produzir soluções superiores às normalmente obtidas em buscas locais ([Glover et al., 1997] apud [Yang, 2011]).

A pesquisa bibliográfica de Hussain et al. [2019] sobre publicações científicas correlacionadas aos algoritmos metaheurísticos reuniu 1222 artigos entre o período de 1983 a 2016, e apresenta aplicações das metaheurísticas em mineração de dados, geração

e distribuição de energia, eletrônica e prototipagem, alocação de recursos, comunicações, elaboração de rotas, engenharia aeronáutica e naval, computação em nuvem e engenharia de controle de processos industriais.

Em relação a esta última área citada, o controle de processos industriais é essencial para campos da engenharia, como sistemas robóticos, aeroespaciais, térmicos, de vazão e de pressão [Ogata, 2011]. Um de seus principais componentes é o controlador Proporcional Integrativo Derivativo (PID), que é o mais popular na indústria devido a sua estrutura simples e facilidade de implementação em equipamentos modernos [Astrom, 1995]. Esse controlador utiliza o sinal de erro, relativo ao valor desejado da resposta do sistema, para melhorar características do processo industrial como velocidade, erro em regime permanente e robustez a ruído [Bhullar et al., 2020].

Os controladores PID têm seu desempenho atrelado a seus ganhos, que devem ser projetados para garantir eficiência em processos industriais. O projeto do controlador pode ser visto, em alguns casos, como um problema de otimização à medida que se utilizam funções objetivo para minimizar valores como o erro absoluto da resposta e sobressinal. Dessa forma, é pertinente utilizar de metaheurísticas para otimização dos ganhos do controlador PID, devido à facilidade de incorporar ao problema de otimização características como descontinuidades, efeitos não lineares e restrições [Oliveira, 2020].

A literatura possui diversos casos de projeto automático de controladores por metaheurísticas. O trabalho de Dhieb et al. [2019] utilizou a metaheurística Ant Colony Optimization (ACO) para otimizar os ganhos de controladores PID aplicados em um modelo de um motor de indução industrial. Em comparação com um controlador PID tradicional, o desempenho do controlador otimizado pelo algoritmo ACO foi superior.

A pesquisa de Guelfi et al. [2020] analisou a eficácia da metaheurística Evolução diferencial (DE) para projeto dos parâmetros de controladores PID aplicados em modelos matemáticos de processos industriais. O trabalho explorou a eficiência de variantes do algoritmo DE original para projeto de controladores, com variantes definidas pelos método de mutação e de cruzamento. Foi observado que a mutação Best produziu melhores resultados de aptidão, e o cruzamento binário apresentou menor tempo de processamento, enquanto o cruzamento exponencial obteve melhores resultados de aptidão.

Neste trabalho foram utilizados algoritmos metaheurísticos para melhorar o desempenho de processos industriais por meio da teoria de engenharia de controle. Desse modo, o objetivo deste trabalho foi analisar a eficiência de metaheurísticas populacionais dos tipos Algoritmo de Enxame de Partículas (PSO), sua variação acelerada (APSO) e Algoritmo Firefly (FA) utilizados para projetar, de forma otimizada, os ganhos de controladores de processos industriais do tipo PID, aplicados em um processo industrial didático de controle de velocidade. Estes controladores configurados por metaheurísticas foram obtidos por meio de uma função de aptidão que penaliza o erro e o sobressinal da resposta do sistema. O desempenho obtido pelos controladores PID otimizados por metaheurísticas foi comparado a algoritmos tradicionais de controle PID.

Este artigo está organizado em seções. A segunda seção aborda as metaheurísticas utilizadas no trabalho. A terceira seção traz uma introdução sobre controle de processos industriais, com foco para o controle PID e suas equações principais. A quarta seção explica a metodologia adotada neste trabalho, desde o sistema real utilizado para estudo

de caso, a função de aptidão adotada e o projeto dos controladores PID tradicionais e otimizados por metaheurísticas. A quinta seção apresenta os resultados da aplicação dos controladores, seguida pelas conclusões na sexta seção.

2. Metaheurísticas

As metaheurísticas são algoritmos de otimização numéricos do tipo heurísticos, que sempre produzem resultados distintos a cada execução [Nesmachnow, 2014]. Em comparação a outras técnicas de otimização, os algoritmos metaheurísticos apresentam como vantagem a busca baseada em simulação, que dispensa modelos matemáticos detalhados e expressões complexas [Viaro et al., 2024]. Outras vantagens das metaheurísticas incluem a não exigência de uma função objetivo diferenciável no espaço de busca, assim como a estocasticidade na busca de soluções ótimas, que permite evitar pontos mínimos locais [Oliveira, 2020].

Neste trabalho, foram utilizadas três metaheurísticas de enxame: o algoritmo de Enxame de partículas (PSO), sua variante acelerada (APSO) e o algoritmo Firefly (FA). Os algoritmos de enxame foram utilizados devido a sua estrutura baseada em cooperação por comportamento coletivo de agentes, similar a de sistemas auto-organizáveis, combinando busca local e interação com outras soluções [Nesmachnow, 2014].

2.1. Algoritmo de Enxame de Partículas (PSO)

O algoritmo de Enxame de Partículas (PSO) se baseia no comportamento de enxames na natureza, explorando o espaço de uma função objetivo por meio do ajuste das trajetórias de agentes individuais, chamados partículas. Cada partícula é simultaneamente atraída para a posição do melhor global G_{best} e para sua melhor posição pessoal P_{best} , enquanto também apresenta uma tendência a se mover aleatoriamente [Van den Bergh and Engelbrecht, 2002]. As melhores posições são determinadas com base em uma função objetivo, definida em um espaço de busca limitado. O equacionamento do algoritmo PSO é formulado a partir de um vetor posição atual \mathbf{x}_i^t e o vetor velocidade \mathbf{v}_i^t para a partícula i . O novo vetor velocidade no instante seguinte \mathbf{v}_i^{t+1} é determinado pela Equação (1).

$$\mathbf{v}_i^{t+1} = w \cdot \mathbf{v}_i^t + c_1 r_1 \cdot (P_{Best} - \mathbf{x}_i^t) + c_2 r_2 \cdot (G_{best} - \mathbf{x}_i^t) \quad (1)$$

Nesta equação, r_1 e r_2 são dois números aleatórios entre 0 e 1, e c_1 e c_2 são os parâmetros de aprendizagem ou constantes de aceleração do algoritmo. A constante de inércia w pondera a influência da velocidade atual, com efeito de uma massa virtual para estabilizar o movimento das partículas, de modo a auxiliar na convergência do algoritmo [Van den Bergh and Engelbrecht, 2002]. A próxima posição das partículas é então determinada conforme a Equação (2).

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \mathbf{v}_i^{t+1} \quad (2)$$

2.2. PSO Acelerado (APSO)

O algoritmo clássico do PSO é amplamente reconhecido por sua eficiência em obter soluções ótimas com rápida convergência. A literatura contém diversos estudos que buscam aprimorar o desempenho do PSO, a exemplo do algoritmo PSO Acelerado

(Accelerated PSO, APSO) que visa melhorar o processo de otimização e o tempo de execução do algoritmo.

O PSO padrão utiliza a melhor partícula global atual (G_{best}) e a melhor partícula pessoal (P_{best}) na determinação do movimento dos membros da população. Uma versão simplificada, que pode acelerar a convergência do algoritmo, consiste de utilizar apenas o melhor global [Rajendran and Srinivasan, 2016]. Esse método é conhecido como APSO, onde o vetor velocidade é determinado pela Equação (3).

$$\mathbf{v}_i^{t+1} = \mathbf{v}_i^t + c_1 \cdot \varepsilon + c_2 \cdot (G_{best} - \mathbf{x}_i^t) \quad (3)$$

Nesta equação acima, a variável ε é um número aleatório pertencente ao intervalo [0,1]. Portanto, substituindo a Equação (3) na Equação 2, têm-se que a atualização da posição do algoritmo APSO é dada pela Equação (4).

$$\mathbf{x}_i^{t+1} = (1 - c_2) \cdot \mathbf{x}_i^t + c_2 \cdot G_{best} + c_1 \cdot \varepsilon \quad (4)$$

Portanto, esta variante do algoritmo PSO possui maior simplicidade quando comparado ao original e permite maior velocidade de convergência [Rajendran and Srinivasan, 2016].

2.3. Algoritmo Firefly (FA)

O algoritmo Firefly (FA) é uma metaheurística biopopulacional inspirada no movimento de vaga-lumes na natureza. Proposto em Yang [2009], o algoritmo tem inspiração em vaga-lumes e seu processo de bioluminescência, utilizado para atrair parceiros em função da distância do vaga-lume emissor de luz. As soluções do algoritmo Firefly são avaliadas com base em sua aptidão, denominada brilho. As soluções com maior brilho atraem outras soluções do espaço de busca, de modo a conduzir a busca por pontos de mínimo próximos a soluções ótimas iniciais [Kochenderfer and Wheeler, 2019].

O algoritmo Firefly depende de três parâmetros de projeto para regular seu funcionamento, bem como das equações de atração entre membros da população e do movimento de vaga-lumes. Os parâmetros que definem a velocidade de convergência são β , γ e α . O parâmetro β é a componente de atração entre dois membros da população, sendo que seu valor é tipicamente $\beta = 1$. A variável γ é o peso da distância entre vaga-lumes, de modo que quanto maior for γ , maior o movimento em direção ao vaga-lume de maior aptidão. Já a variável α é o peso do termo randômico no movimento do vaga-lume, similar a um fator de mutação do indivíduo. Os parâmetros tipicamente ficam no alcance [0,1].

A equação que representa a atração por brilho entre membros da população é determinada pela Equação (5), em função da distância r entre dois indivíduos A e B , e do parâmetro γ .

$$I(\gamma, r(A, B)) = e^{-\gamma \cdot (r(A, B))^2} \quad (5)$$

A equação de movimento dos vaga-lumes presente na Equação (6) depende da posição A e B de dois membros da população. O movimento se dá em direção a posição de maior aptidão, B , de modo que o indivíduo na posição A é deslocado pela atração entre os indivíduos ponderado por β , com o acréscimo de um movimento randômico ponderado por α e dentro de uma distribuição normal de variância σ_v especificada no projeto.

$$A = A + \beta \cdot I(\gamma, r(A, B)) \cdot (B - A) + \alpha \cdot N(0, \sigma_v) \quad (6)$$

3. Controle de Processos Industriais

O controle de processos industriais é essencial para garantir o desempenho ótimo de sistemas relevantes para a indústria, a exemplo de sistemas térmicos, de potência, hídricos e fluídicos [Ogata, 2011]. Neste campo, o controlador Proporcional Integrativo Derivativo, ou PID, é um dos controladores mais utilizados em processos industriais, e a maioria dos controladores modernos são baseados em algum tipo de controle PID [Ibrahim, 2006]. Nesse tipo de controle, a ação de controle é calculada com base no erro da resposta do sistema em relação ao valor de referência definido. Um exemplo de malha industrial com controlador PID está presente na Figura 1.




Figura 1. Malha de controle com controlador PID. Fonte: Ogata [2011].

No controle PID, tem-se a junção de três tipos de ações: a ação proporcional, integral e derivativa. A ação proporcional do controlador, representada por K_p , multiplica o valor do erro, análogo a um amplificador de ganho ajustável. A ação derivativa expressa por T_d avança o efeito da ação proporcional e contribui com a velocidade da resposta [Ogata, 2011]. A ação integrativa expressa por T_i contribui com a redução do valor do erro em regime permanente [Ibrahim, 2006]. Para aplicar controladores PID em processos digitais, é necessário converter o controlador para sua forma discreta. A ação do controlador PID em sua forma discretizada está presente na Equação (7).

$$u(kT) = u(T(k-1)) + g_0 \cdot e(kT) + g_1 \cdot e(T(k-1)) + g_2 \cdot e(T(k-2)) \quad (7)$$

Onde as variáveis g_0, g_1, g_2 representam os termos da equação do controlador PID em tempo discreto e dependem da taxa de amostragem T_s do sistema. Estes termos g_0, g_1, g_2 estão dispostos nas Equações (8), (9) e (10).

$$g_0 = K_p \cdot \left(1 + \frac{T_d}{T_s} + \frac{T_s}{T_i}\right) \quad (8)$$

$$g_1 = K_p \cdot \left(-1 - 2 \cdot \frac{T_d}{T_s}\right) \quad (9)$$

$$g_2 = K_p \cdot \left(\frac{T_d}{T_s}\right) \quad (10)$$

Neste trabalho, os termos discretizados do controlador PID foram otimizados pelas metaheurísticas analisadas, de modo que cada membro de uma população representa um controlador PID discreto. Os ganhos do controlador PID utilizados neste trabalho foram definidos pelo Primeiro método de Ziegler-Nichols, descrito em Ibrahim [2006].

4. Metodologia

Nesta seção foram apresentados o processo industrial didático em que foi realizado o estudo de caso deste trabalho, bem como a função de aptidão utilizada para analisar o desempenho dos controladores de processos industriais, como também os parâmetros das metaheurísticas para a otimização de projeto de controladores PID.

4.1. Estudo de caso: Sistema Industrial Didático de Controle de Velocidade

Neste trabalho, foi utilizado como estudo de caso um processo industrial didático de controle de velocidade baseado em um motor de corrente contínua, desenvolvido e apresentado em Soares et al. [2019] e presente na Figura 2. O sistema apresentado é composto por um microcontrolador do tipo PIC18F2550, um circuito de alimentação, um circuito para acionamento de um cooler 12 V via modulação de largura de pulso (PWM) e um sensor óptico reflexivo TCRT5000 para detecção da velocidade de rotação do cooler. Para enviar e receber informações do microcontrolador do sistema de velocidade, é utilizada comunicação serial cabeada. O acionamento do sistema se dá por meio de códigos no software MATLAB, com auxílio da biblioteca SerPIC.




Figura 2. Sistema de controle de velocidade, com descrições das unidades que o compõem. Fonte: Soares et al. [2019].

4.2. Função de Aptidão

Neste trabalho, as metaheurísticas foram utilizadas para otimizar o projeto dos ganhos de controladores PID. Para avaliar a qualidade de controladores numericamente, foi utilizada uma função de aptidão que combina o valor da Integral do erro absoluto (IAE) da resposta do sistema, com o valor do sobressinal da resposta do sistema. Dessa forma, os controladores obtidos pelas metaheurísticas apresentam menor erro em sua resposta e menor sobressinal. A Integral Absoluta do Erro (IAE) pode ser expressa pela Equação (11), que expressa a integral discreta do vetor de erros $e(k)$ ao longo de N amostras. A função de aptidão está expressa na Equação (12), e é composto pela soma do índice IAE com o valor máximo da resposta do processo industrial $y(k)$, ponderado pelo escalar 10.

$$IAE = \sum_{k=1}^N |e(k)| \quad (11)$$

$$Aptidão = IAE + 10 \cdot \max(y(k)) \quad (12)$$

4.3. Metaheurísticas para Projeto de Controladores PID

Os algoritmos metaheurísticos PSO, APSO e FA analisados neste trabalho foram utilizados para otimizar o projeto dos ganhos de controladores PID a fim de melhorar a resposta de um sistema industrial didático. Para isso, é preciso definir os hiperparâmetros das metaheurísticas utilizadas, bem como definir valores iniciais e valores limite para o espaço de busca desses algoritmos.

As metaheurísticas foram configuradas com os parâmetros de população = 20, gerações = 10 e critério de parada de atingir as gerações máximas. A metaheurística PSO e APSO teve seus hiperparâmetros definidos para coeficiente de inércia $w = 1$ e constantes de aceleração $c_1 = 1$ e $c_2 = 2$. A metaheurística FA teve seus parâmetros configurados como $\alpha = 0.4$, $\beta = 1$, $\gamma = 0.45$. O peso do movimento randômico, α , decai a cada geração para 90% de seu valor atual, como forma de reduzir a aleatoriedade ao longo das gerações.

Os valores iniciais utilizados nas metaheurísticas para os ganhos de controladores PID foram definidos com base no Primeiro método de Ziegler-Nichols. Foi realizado um ensaio em malha aberta do sistema industrial com entrada de 70% da potência da fonte para obter as constantes do sistema $T = 1.8$, $L = 0.4$ e $K = 0.328$. Com base em Ibrahim [2006], os ganhos do controlador PID são $K_p = 16.4348$, $T_d = 0.1$ e $T_i = 0.8$. Estes valores foram substituídos nas Equações (8), (9) e (10) e o período de amostragem $T_s = 0.1s$, são obtidos os termos do controlador digital $g_0 = 34.9239$, $g_1 = -49.3043$ e $g_2 = 16.4348$.

Após aplicação do controlador PID no estudo de caso, foi observado que o controlador digital projetado pelo Primeiro método de Ziegler-Nichols resultou em uma ação de controle agressiva, com resposta do processo industrial com muita oscilação. Com base nisso, foi realizado um reajuste do controlador digital, de modo que o ganho proporcional K_p foi reduzido para 50% de seu valor calculado. O novo controlador PID digital, de acordo com a ressonância realizada e as Equações (8), (9) e (10), os termos do novo controlador digital foram $g_0 = 17.462$, $g_1 = -24.652$ e $g_2 = 8.217$. Ambos o controlador calculado e o resintonizado foram utilizados na etapa de resultados para fins de *benchmarking*.

Os termos g_0, g_1 e g_2 do controlador PID resintonizado foram utilizados para definir os valores iniciais e valores limite para o espaço de busca das metaheurísticas, de modo que os controladores PID tiveram seus valores limitados em 10% do valor calculado no limite superior, e até 60% do valor calculado no limite inferior.

5. Resultados

Nesta seção, foram apresentados os resultados referentes às metaheurísticas PSO, APSO e FA aplicadas na otimização de projeto de controladores PID. Estes controladores foram comparados a controladores projetados pelo Primeiro método de Ziegler-Nichols, dispostos na Subseção 4.3 e nomeados como PID ZN e PID resintonizado, sendo este último referente ao controlador PID com reajuste nos ganhos. Os controladores foram avaliados segundo os índices Integral Absoluta do Erro (IAE), descrito na Equação (11) e Índice de Goodhart (IG), exposto em mais detalhes em Bruni et al. [1974].

Os ganhos dos controladores PID utilizados para obter os resultados da resposta do sistema industrial didático foram dispostos na Tabela 1. Os ganhos exibidos na ta-

bela referem-se aos ganhos contínuos do controlador PID, os ganhos proporcional K_p , integrativo $K_i = \frac{K_p}{T_i}$ e derivativo $K_d = K_p \cdot T_d$. Os controladores sintonizados por metaheurística foram denominados pela sigla do algoritmo correspondente, de modo que controlador PID sintonizado por PSO foi nomeado PID-PSO para melhor exibição. Pela tabela, pode-se observar que os ganhos do controlador PID ZN são bem maiores que os ganhos dos demais controladores.

Tabela 1. Ganhos dos controladores PID analisados neste trabalho.

Controlador	K_p	K_i	K_d
PID ZN	16.4348	20.5435	1.6435
PID ressintonizado	8.2174	10.2717	0.8217
PID-PSO	8.5835	15.3220	0.3498
PID-APSO	9.1478	19.1780	0.4271
PID-FA	7.1392	14.4620	0.3338

Para obter os resultados da resposta do processo industrial didático para os controladores analisados, foi aplicado um sinal de referência no sistema real em malha fechada com $N = 200$ amostras. Os resultados desta análise estão apresentados na Tabela 2, para os índices IAE e Goodhart. Para formar uma análise estatística dos dados da resposta do sistema de velocidade, foram coletados dados da resposta do sistema com controlador e ação do controlador durante 10 realizações, o que permite obter dados sobre os valores médios, mínimos e máximos dos índices de desempenho de controladores.

Tabela 2. Índices de desempenho para a resposta dos controladores analisados para 10 realizações.

Controlador	IAE			Goodhart		
	Mean	Min	Max	Mean	Min	Max
PID ZN	263.15	248.6	276.4	432.79	383.11	503.39
PID ressintonizado	250.70	225.72	269.77	239.01	224.56	260.87
PID-PSO	159.44	149.64	170.84	218.31	207.25	225.52
PID-APSO	161.01	152.1	171.7	227.11	217.15	247.2
PID-FA	159.02	143.96	168.41	214.82	204.746	222.218

É possível observar pela Tabela 2 que, segundo o erro absoluto, os controladores com metaheurísticas apresentam desempenho similar entre si, com médias de valor muito próximo, e pequenas diferenças nos valores mínimos e máximos. Comparado aos controladores tradicionais, os controladores projetados por PSO, APSO e FA apresentam redução no erro absoluto médio de até 39.5%.

Referente ao índice de Goodhart, os controladores sintonizados por metaheurísticas apresentaram amplitude média próxima, com o PID-APSO ligeiramente inferior ao PID-PSO e PID-FA, possivelmente devido a convergência acelerada do algoritmo. O PID ressintonizado apresenta resultados próximos dos controladores com metaheurísticas, o que evidencia a eficácia do ajuste proposto comparado ao PID ZN. Desse modo, o uso de metaheurísticas permitiu redução de até 50% no valor do índice de Goodhart, comparado ao controlador PID ZN.

Os resultados para a resposta do sistema e para a ação dos controladores foram apresentados nas Figuras 3 e 4, feitos extraíndo apenas o intervalo de t de 0 a 16 segundos

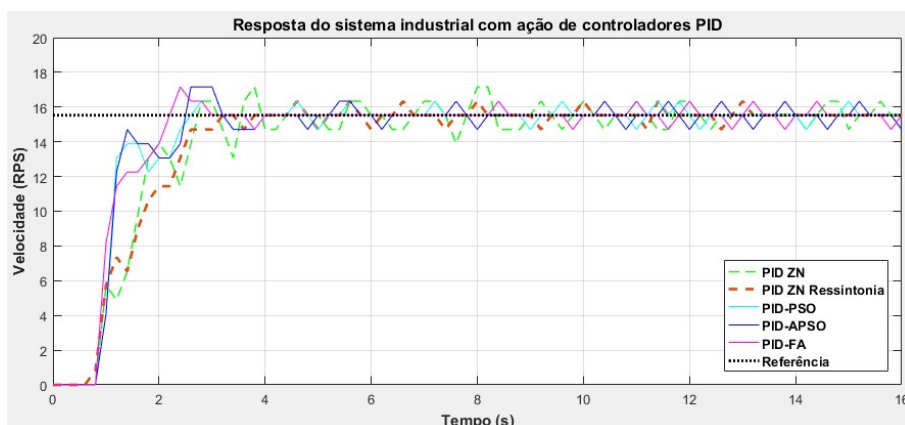


Figura 3. Resposta do sistema industrial didático para os controladores analisados. Fonte: Autoria própria.

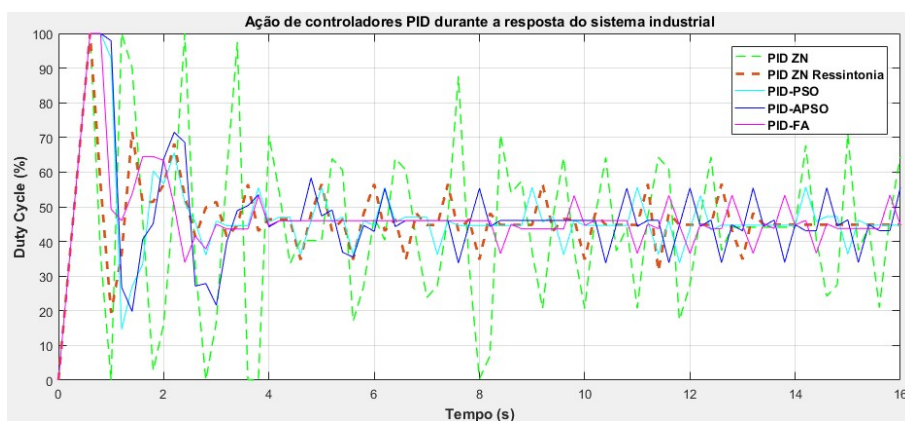


Figura 4. Ação de controladores aplicados no sistema industrial didático. Fonte: Autoria própria.

para observar com mais detalhes o desempenho dos controladores. Relativo à resposta do sistema, é possível constatar que os controlador PID ZN apresentaram resposta mais lenta comparada aos controladores projetados por metaheurísticas, o que resultou em maior índice IAE. Os controladores PID-PSO, PID-APSO e PID-FA obtiveram desempenho similar. Relacionado à ação de controle, pode-se observar a presença de diversos picos de amplitude para o controlador ZN, o que justifica seu alto índice de Goodhart. A ação de controle para os demais controladores apresenta picos de amplitude menores, com atuação apenas para corrigir ruídos na medição do sistema.

6. Conclusões e Trabalhos futuros

Este trabalho analisou o desempenho de controladores PID sintonizados por metaheurísticas aplicados a um sistema industrial didático de controle de velocidade. As metaheurísticas populacionais utilizadas foram Enxame de partículas (PSO), sua variação acelerada (APSO) e Firefly (FA). Os resultados comprovam a eficiência do projeto de controladores de processos industriais por meio de metaheurísticas, apresentando em relação a métodos de projeto tradicionais, uma redução de até 39.5% do valor do erro absoluto e de 50% relativo ao índice de Goodhart, atestando uma melhora significativa ao utilizar metaheurísticas para otimizar controladores industriais PID em relação ao erro da resposta

do sistema e da magnitude do sinal de controle comparado a métodos tradicionais. Em trabalhos futuros, devem-se explorar outros algoritmos de otimização para realizar o projeto de controladores, como metaheurísticas multiobjetivo, associadas ou não a técnicas inteligentes de controle como sistemas *Fuzzy*.

Referências

- K. J. Astrom. Pid controllers: theory, design, and tuning. *The international society of measurement and control*, 1995.
- A. K. Bhullar, R. Kaur, and S. Sondhi. Enhanced crow search algorithm for avr optimization. *Soft Computing*, 24(16):11957–11987, 2020.
- C. Bruni, G. Dipillo, and G. Koch. Bilinear systems: An appealing class of “nearly linear” systems in theory and applications. *IEEE Transactions on automatic control*, 19(4):334–348, 1974.
- Y. Dhieb, M. Yaich, A. Guermazi, M. Ghariani, et al. Pid controller tuning using ant colony optimization for induction motor. *Journal of Electrical Systems*, 15(1):133–141, 2019.
- F. Glover, M. Laguna, F. Glover, and M. Laguna. Tabu search principles. *Tabu Search*, pages 125–151, 1997.
- M. A. Guelfi, P. R. S. S. Oliveira, A. A. Carniato, and L. A. Carniato. Estudo comparativo entre variações de evolução diferencial para a sintonia de controladores pid. *Revista Sinergia*, 22(1), 2020.
- K. Hussain, M. N. Mohd Salleh, S. Cheng, and Y. Shi. Metaheuristic research: a comprehensive survey. *Artificial intelligence review*, 52:2191–2233, 2019.
- D. Ibrahim. *Microcontroller based applied digital control*. John Wiley, 2006.
- M. J. Kochenderfer and T. A. Wheeler. *Algorithms for optimization*. Mit Press, 2019.
- S. Nesmachnow. An overview of metaheuristics: accurate and efficient methods for optimisation. *International Journal of Metaheuristics*, 3(4):320–347, 2014.
- K. Ogata. *Engenharia de controle moderno*. 5^a. São Paulo: Pearson, 2011.
- P. W. d. Oliveira. Contribuições ao problema de sintonia ótima de controladores pid de ordens inteira e fracionária via otimização metaheurística. 2020.
- S. Rajendran and H. Srinivasan. Simplified accelerated particle swarm optimisation algorithm for efficient maximum power point tracking in partially shaded photovoltaic systems. *IET Renewable Power Generation*, 10(9):1340–1347, 2016.
- S. S. Rao. *Engineering optimization: theory and practice*. John Wiley & Sons, 2009.
- G. F. Soares, J. B. d. C. Neto, L. G. d. Oliveira, and O. d. M. Almeida. Desenvolvimento de hardware didático para ensino de controle digital, 2019.
- F. Van den Bergh and A. P. Engelbrecht. A new locally convergent particle swarm optimiser. In *IEEE International conference on systems, man and cybernetics*, volume 3, pages 6–pp. IEEE, 2002.
- R. U. Viaro, L. C. Borin, R. Medke, E. Mattos, C. R. D. Osório, and V. F. Montagner. Otimização de controladores baseada em meta-heurística aplicada a conversores cc-cc com validação em hardware-in-the-loop. *Eletrônica de Potência*, 29, 2024.
- J. F. Vidal et al. Metaheurísticas populacionais: estudo comparativo na sintonia de parâmetros de controladores clássicos. 2016.
- X.-S. Yang. Firefly algorithms for multimodal optimization. In *International symposium on stochastic algorithms*, pages 169–178. Springer, 2009.
- X.-S. Yang. Metaheuristic Optimization. *Scholarpedia*, 6(8):11472, 2011. doi: 10.4249/scholarpedia.11472. revision #91488.