
Identificação de sistema e implementação de controlador PID utilizando algoritmo de otimização por enxame de partículas (PSO) planta de nível.

*GUIMARÃES, Anapaula Pacheco*¹
Centro Universitário Academia - UniAcademia
*CARDOSO, Dalmo da Silva*²
Centro Universitário Academia - UniAcademia

RESUMO

Este trabalho trata do desenvolvimento de um método de otimização aplicado a identificação de sistemas e a sintonia de parâmetros de controladores PID. Para isso, foi utilizado como base um modelo computacional que trabalha aperfeiçoando resoluções de problemas, a Otimização por Enxame de Partículas. Essa metodologia se baseia em modelar o comportamento social de um bando de pássaros e com isso, traduzir, analiticamente, como eles se organizam em suas revoadas. Em outras palavras, o método procura uma solução ótima em um espaço de busca por meio de trocas de informações entre indivíduos do mesmo bando, determinando assim qual a melhor trajetória a ser seguida por cada um deles até que o melhor indivíduo seja encontrado. O indivíduo é uma possível solução que carrega consigo valores de K e τ , em conjunto. O objetivo da pesquisa é investigar a potencialidade desse artifício para a identificação de sistemas e sintonia de controladores PID, utilizando o software MATLAB. Os resultados obtidos demonstram que a técnica é eficiente, tanto na identificação de sistemas quanto na sintonia do controlador PID.

Palavras-chave: Otimização de processos. Controle de Nível. Controladores PID. Otimização por Enxames de Partículas. MATLAB.

1. INTRODUÇÃO

A eficiência de processos automatizados tornou-se ao longo do tempo um dos maiores objetivos da indústria mundial. Nesse ambiente, sistemas de controle de nível são facilmente encontrados, por exemplo, na administração de um reservatório cujo

¹ Graduanda em Engenharia Elétrica pelo Centro Universitário Academia - UniAcademia.

² Professor do curso de Engenharia Elétrica do Centro Universitário Academia - UniAcademia.

volume de fluido não pode estar abaixo de um nível predeterminado ou até no controle de misturas entre substâncias distintas.

Uma das principais justificativas que motivam o aprimoramento das metodologias já utilizadas é a possibilidade de redução de dispêndio industrial. O sucesso econômico desse tipo de procedimento é resultado de um gerenciamento empresarial eficiente, principalmente, no que diz respeito ao uso consciente de recursos com máxima relação custo-benefício. Quando estes são subutilizados, perde-se tempo de produção e por conseguinte, lucro. Quando superutilizados, perde-se tempo de vida útil. Para alcançar o aproveitamento máximo desses recursos, frequentemente são empregados malhas e algoritmos de controle, visando garantir que o sistema opere explorando seus limites (ALPI, 2016).

Ainda hoje, nesse cenário, os controladores PID (Proporcional-Integral-Derivativo) apesar de sua estrutura relativamente simples, são suficientes para o controle de diversos processos, além de serem os mais utilizados na indústria (BAZARELLA, 2005). Entretanto, em algumas situações, essa metodologia não apresenta um comportamento completamente satisfatório, podendo implicar em respostas com sobressinal, tempo de assentamento alto e/ou oscilações (OGATA, 2005).

Apesar das ineficiências mencionadas, o controlador PID ainda é, majoritariamente, utilizado no controle e automatização de processos. Em sistemas de nível, por exemplo, ele trabalha garantindo que não haja alteração no nível do recipiente, ou seja, a vazão de entrada precisa ser igual a vazão de saída. Isso quer dizer que, quando acontece uma variação na vazão de saída ou de entrada, o controlador atua de modo que ambas variem na mesma proporção (TEIXEIRA, 2010).

Métodos tradicionais são muito utilizados com a finalidade de encontrar uma resposta mais satisfatória. As regras de Ziegler-Nichols, por exemplo, procuram ajustar os valores de ganhos proporcional, integral e derivativo, baseadas na resposta experimental ao degrau (OGATA, 2005). Além deste, existem outros como o lugar geométrico das raízes, método de Cohen e Coon, diagrama de resposta em frequência, etc. Entretanto, essas técnicas ditas de controle clássico, geralmente, não atingem excelência em prestabilidade além de serem dependentes do conhecimento

do processo por parte do projetista para um posterior ajuste fino dos ganhos (OGATA, 2005).

Atualmente, existem diversos estudos que analisam a possibilidade de ganhos ótimos para a sintonia de controladores através de algoritmos de otimização, isso devido a sua estrutura simples, velocidade de resposta e possibilidade de obtenção de melhores resultados. Eles podem ser utilizados como uma ferramenta vital no projeto de controladores clássicos. Na literatura, são apresentadas diversas sintonias de controladores PID para sistemas de uma entrada e uma saída (SISO), utilizando algoritmos evolucionários como otimização por enxame de partículas, algoritmos genéticos, otimização de colônia de formigas, otimização em espiral, entre outros (RIBEIRO, 2016).

Este trabalho tem por objetivo a aplicação de um método de otimização conhecido como Particle Swarm Optimization (PSO) em sistemas de controle de nível, neste caso, na sintonia do controlador PID obtendo os ganhos proporcional, integral e derivativo para o ajuste fino do sistema em malha fechada. Além disso, o controlador criado foi aplicado diretamente à planta real do sistema e também à função de transferência simulada pelo método PSO. O objetivo desse processo é comparar as respostas e examinar a possibilidade de utilização deste controlador em plantas de nível reais.

2. REFERENCIAL TEÓRICO

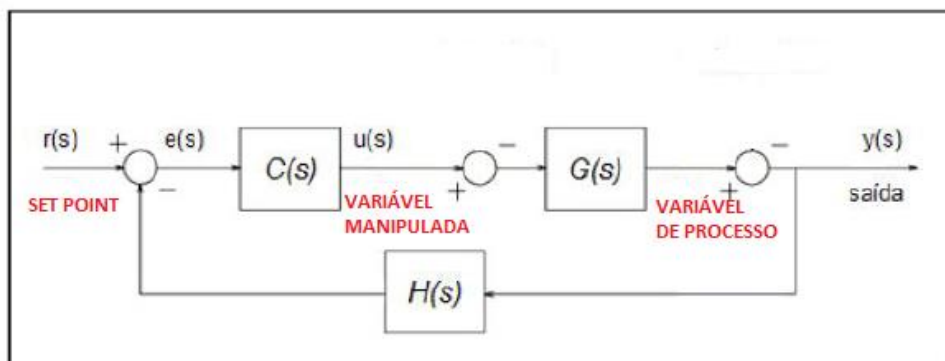
Na indústria, um sistema a ser controlado é denominado processo ou planta. De acordo com Bazella (2005), a entrada é o meio pelo qual é possível controlar a planta e denomina-se variável manipulada, pois seu valor pode ser operacionalizado. Em um sistema de nível, a variável manipulada é a vazão de entrada $u(s)$. O sinal de saída $y(s)$ é chamado de variável controlada e é aquela que se deseja gerenciar o comportamento. Para tornar possível o alcance da máxima eficiência esperada, é necessário o uso de um controlador $G(s)$. Neste caso, foi utilizado o Proporcional-Integral-Derivativo na entrada do processo, visando garantir o sinal de saída pretendido. O sinal aplicado em sua entrada denomina-se valor de referência $r(s)$ ou SetPoint (SP). O controlador PID une as ações proporcional, integral e derivativa, visando gerar um único sinal de controle. A ação de controle gerada pelo modo

proporcional faz com que o sistema atue sobre o erro vigente, garantindo uma reação imediata às perturbações do valor de referência. Já a ação integral, elimina o erro de regime permanente, sendo proporcional à integral do sinal do erro no domínio do tempo. Por fim, a derivativa estima a tendência de aumento ou diminuição do erro futuro, podendo aumentar a rapidez na correção do processo, atuando de forma antecipatória (SHIRAHIGE, 2007).

Um sistema sem realimentação na saída configura um sistema em malha aberta, o que quer dizer que a saída não tem efeito na ação do controle, porém neste trabalho, serão abordados apenas sistemas realimentados, ou seja, em malha fechada. Isso quer dizer que um sensor $H(s)$ converte o sinal de saída $y(s)$ para a mesma unidade do sinal de referência $r(s)$ e realiza uma comparação entre eles. Esse processo gera um sinal de erro $e(s)$ e produz mecanismos que tentam reduzir essa falha tornando-a ínfima ou nula. A variável $C(s)$ diz respeito ao controlador aplicado.

A partir da Figura 1, é possível analisar mais detalhadamente a metodologia apresentada.

Figura 1 – Sistema de Controle em Malha Fechada



Fonte: Elaborado pelo Autor.

Um sistema que opera em malha fechada garante mais eficácia em seu comportamento, como por exemplo, maior precisão de controle e rejeição de distúrbios sobre a variável de processo, garantindo aumento da robustez do sistema.

Neste trabalho, foi utilizado o controle de plantas por Equação Diferencial de Primeira Ordem, elas são chamadas de Sistemas de Primeira Ordem (SPOs) e possuem a dinâmica de saída $y(t)$ representada por meio de uma EDO.

Se considerarmos as condições iniciais de $y(0) = 0$ e $a_0 \neq 0$, é possível descrever a formulação de um SPO, conforme em (1) e (2).

$$a_1 \frac{dy}{dt} + a_0 y = b u, \quad y(0) = 0$$

(1 Erro!
 Nenhuma
 sequência foi
 especificada.)

$$\frac{a_1}{a_0} \frac{dy}{dt} + y = \frac{b}{a_0} u, \quad y(0) = 0 \quad (2)$$

O padrão de representação de uma SPO é obtido substituindo-se o valor das constantes por $\tau = \frac{a_1}{a_0}$ e $K = \frac{b}{a_0}$, sendo τ a constante que indica a rapidez que a resposta do sistema reage a uma variação da entrada e K o ganho do processo, ou seja, a razão entre os valores finais da resposta e a entrada observada. A partir das modificações realizadas, obtém-se:

$$\tau \frac{dy}{dt} + y = K u, \quad y(0) = 0 \quad (3)$$

É importante considerar que a equação da SPO é dada no domínio da frequência (s). Portanto, aplicando-se a Transformada de Laplace em ambos os lados da EDO é possível obter o formato esperado, de acordo com (4), (5) e (6).

$$\tau s Y(s) + Y(s) = K U(s) \quad (4)$$

$$(\tau s + 1) Y(s) = K U(s) \quad (5)$$

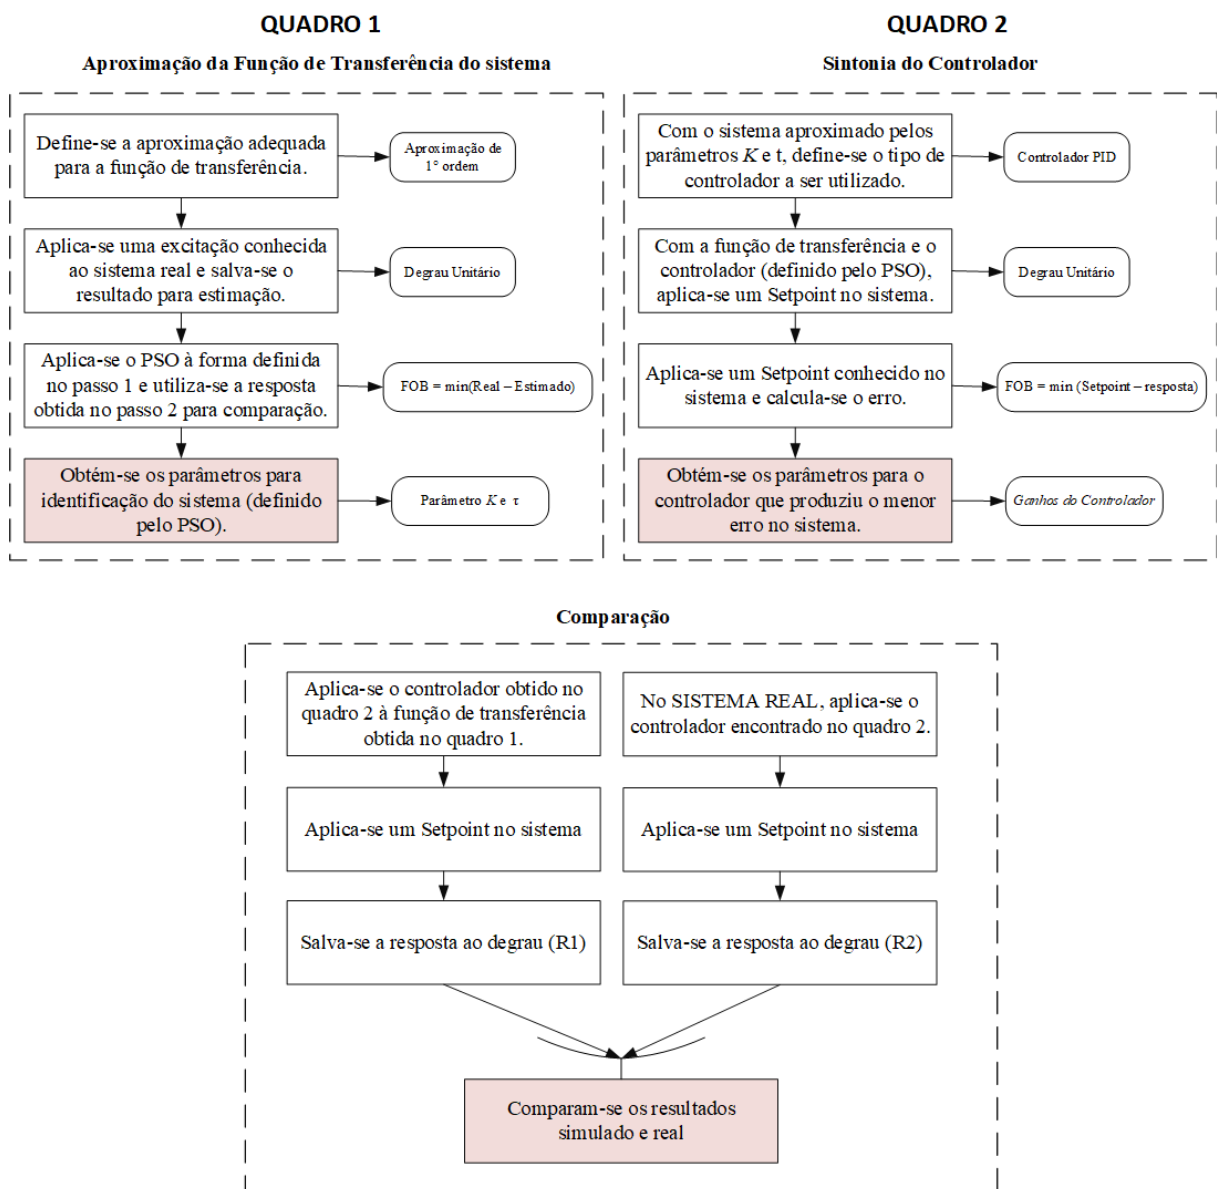
$$G(s) = \frac{Y(s)}{U(s)} = \frac{K}{\tau s + 1} \quad (6)$$

Neste trabalho, uma função de transferência de primeira ordem obtida por meio do algoritmo PSO, será submetida às ações de um controlador PID otimizado pelo mesmo método. Este método se trata de um algoritmo heurístico que se baseia no comportamento social de um bando de pássaros e tem como objetivo encontrar uma solução ótima por meio de trocas de informações que ocorrem entre os indivíduos de uma população a fim de determinar qual trajetória cada um deles deverá tomar em um espaço de busca pré-estabelecido.

Para fins de comparação, o resultado obtido por meio da aplicação do controlador otimizado na planta simulada, será confrontado com o mesmo controlador

aplicado à resposta real da planta. Assim, será possível garantir a eficiência do método apresentado. É importante destacar que toda a programação proposta para elaboração do trabalho foi feita no software interativo MATLAB. Na Figura 2 é possível identificar o passo a passo para a execução do trabalho.

Figura 2 – Fluxograma de representação do trabalho



Fonte: Elaborado pelo Autor.

3. METODOLOGIA

Para que fosse possível realizar o comparativo proposto, foi necessário

encontrar a função de transferência de um modelo real de planta de nível. O mesmo foi retirado de um trabalho de conclusão de curso no qual a proposta era otimizar um controlador PI aplicado a planta didática de nível SMAR³, através do algoritmo inteligente representado pelo modelo de colônia de formigas (GONÇALVES, 2016). Após a coleta de todos os dados, foi possível identificar a função de transferência de primeira ordem do modelo experimental, onde $K = 0,85048$ e $\tau = 152,1026$. Através dos resultados obtidos e sabendo que a função de transferência é de primeira ordem, sua representação pode ser dada por meio da equação a seguir:

$$G(s) = \frac{0,85048}{152,1026s + 1} \quad (7)$$


onde 0,85048 é o ganho e 152,1026 representa o tempo de resposta do sistema.

3.1 ESTIMAÇÃO ANALÍTICA APLICADA À RESPOSTA DO SISTEMA REAL

A resposta ao degrau da função de transferência do sistema real foi utilizada como parâmetro para a estimação analítica da função de transferência simulada. Essa estimação realizada a partir de ensaios, verifica se os valores obtidos após a simulação são próximos ou não dos reais. Os dados obtidos diretamente da planta garantem a aproximação da função de transferência. A partir deles é possível medir a constante de tempo, isto é, o tempo para a amplitude atingir 63% de seu valor final (como ilustra a Figura 3). Para obter K , verifica-se que a resposta forçada atinge um valor em regime permanente correspondente a K/a , sendo $a = 1/\tau$. A partir dessas informações é possível encontrar a função de transferência do sistema.

³ SMAR é uma fornecedora de Plantas Didáticas e Kits Didáticos para automação industrial e instrumentação

Figura 3 – Resposta de sistema de primeira ordem a um degrau unitário



Fonte: Control Systems Engineering, 2012.

3.2.ALGORITMO DE ENXAME DE PARTÍCULAS

No PSO, cada indivíduo representa uma solução do sistema, sendo assim, se a solução possui N parâmetros, cada indivíduo será representado também por N parâmetros.

Esses parâmetros são assumidos como posição em um sistema N-dimensional, e essa posição é atualizada através de velocidades. Para compor essa velocidade, é assumido que cada indivíduo possui sua experiência própria e também a experiência coletiva. Esses dois parâmetros são a base desse algoritmo (MEDIEROS, 2005).

Como cada indivíduo representa uma solução possível para o sistema, no PSO os parâmetros individuais e coletivos são obtidos através da avaliação da Função Objetivo (FOB). Quanto melhor a FOB de um indivíduo, mais experiente é este indivíduo, e conseqüentemente, mais influência tem no grupo.

Como citado, o algoritmo depende de dois parâmetros: o conhecimento global, que possui a melhor avaliação de toda população e o conhecimento individual, que possui a melhor avaliação de cada indivíduo, ambas calculadas a partir da FOB.

A primeira etapa no processo de otimização diz respeito à definição da população do algoritmo (em analogia, seria a quantidade de pássaros que compõem o bando). Além disso, cada indivíduo começa com uma velocidade inicial nula. A cada iteração, a velocidade atual é somada a um componente cognitivo multiplicado pela diferença entre a melhor posição individual e a posição atual, e a um componente social multiplicado pela diferença entre a melhor posição global e a posição do indivíduo em questão. O componente cognitivo e o componente social são valores entre 0 e 1 e influenciam na taxa de convergência do sistema (MEDIEROS, 2005).

Após os cálculos já mencionados, obtém-se um novo ponto de localização de cada indivíduo, acrescido da velocidade encontrada. Como todos os indivíduos sofrem interferência do melhor global, todos tendem a seguir o mesmo ponto, encontrando frequentemente máximos ou mínimos locais, o que não é o ideal, pois se isso ocorrer, a partícula influenciará todas as outras para um mesmo ponto. Com isso, o algoritmo terá uma convergência prematura, atrapalhando seu desempenho. Para tentar alcançar o máximo ou mínimo global, são inseridos indivíduos alterados de forma aleatória com o intuito de fazer com que surjam partículas melhores.

A partir deste momento, o ciclo se repete até que o sistema atinja a condição de parada. O Quadro 1 apresenta um pseudocódigo do PSO.

Quadro 1 - Pseudocódigo algoritmo Enxame de Partículas.

```

Definir um valor para o componente cognitivo ( $\Phi_1$ )
Definir um valor para o componente social ( $\Phi_2$ )
Definir constante de aproveitamento ( $\omega$ ):
Definir velocidade máxima das partículas ( $V_{max}$ )
Definir velocidade mínima das partículas ( $V_{min}$ )
Gerar matriz velocidade nula ( $V$ )
Definir o número de iterações
Criar população inicial
Avaliar população inicial
Seleciona melhor posição individual ( $P_{best}$ )
Selecionar melhor indivíduo ( $G_{best}$ )
PARA  $i$  DE 1 ATE iteração FAÇA:
    PARA  $k$  DE 1 ATE número de indivíduos FAÇA:
         $V_k = \omega * V_k + \Phi_1 * rand * (P_{best_k} - P_k) + \Phi_2 * rand * (G_{best} - P_k)$ 
        SE  $V_k > V_{max}$  FAÇA:
             $V_k = V_{max}$ 
        FIMSE
        SE  $V_k < V_{min}$  FAÇA:
             $V_k = V_{min}$ 
        FIMSE
         $P_k = P_k + V_k$ 
        SE  $P_k >$  máximo limite FAÇA:
             $P_k =$  máximo limite
        FIMSE
        SE  $P_k <$  mínimo limite FAÇA:
             $P_k =$  mínimo limite
        FIMSE
         $F = FOB(P_k)$ 
        SE  $P_k$  melhor que  $P_{best_k}$  FAÇA:
             $P_{best_k} = P_k$ 
            SE  $P_k$  melhor que  $G_{best}$ 
                 $G_{best} = P_k$ 
            FIMSE
        FIMSE
    FIMPARA
FIMPARA
RETORNA  $G_{best}$ 

```

Fonte: Elaborado pelo Autor.

No trabalho em questão, o objetivo traçado em termos de otimização é o de minimizar os erros a fim de obter os parâmetros que aproximam o sistema. Para isso, os pássaros (ou partículas), exploram uma região visando encontrar uma solução para o problema. A FOB é determinada de acordo com a necessidade de avaliação do programador. Neste caso, foi utilizado para avaliação de desempenho

o erro IAE (Integral Absoluta do Erro) descrito pela equação a seguir:

$$IAE = \sum |Desejado - Obtido| \quad (8)$$


Desta maneira, a FOB deve minimizar o somatório do erro entre a saída do sistema real e a saída do sistema estimado, como mostrado em (9). Assim, quanto menor o erro, mais próximo ao sistema real estará a função de transferência estimada.

$$FOB = \text{minimizar} \left(\sum |Desejado - Obtido| \right) \quad (9)$$

O algoritmo do PSO atualiza a velocidade e a posição de cada partícula. Esse processo requer algumas informações do programador, como número de iterações, população, coeficiente de inércia, coeficiente de aceleração individual e coletivo. Normalmente, o PSO apresenta rápida convergência nas primeiras iterações mas demonstra estagnação nas iterações finais. O coeficiente de inércia ω possui grande influência sobre esse comportamento. Maiores valores de ω contribuem para uma busca global e para a exploração de novas áreas do espaço de solução, enquanto valores menores ω favorecem a busca local, o que é interessante quando as partículas estão próximas de uma boa solução.

A Figura 4 elucidada o que foi dito, porém, exemplificando um problema de maximização. A posição da melhor partícula da população será a melhor posição individual. O pássaro azul é a partícula de solução ótima.

Figura 4 – Analogia de um bando de pássaros em um espaço de busca em 3D.



Fonte: < <http://computacaointeligente.com.br/algoritmos/otimizacao-por-enxame-de-particulas/> Acesso em 18 de novembro de 2020.

3.3 CONTROLADOR PID POR OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

Agora, o PSO é utilizado a fim de contribuir para uma resposta mais eficaz para o sistema, encontrando os ganhos do controlador PID (K_p , K_i e K_d), o que torna as partículas tridimensionais. Neste caso, cada indivíduo será representado por 3 parâmetros (K_p , K_i e K_d), visto que estamos fazendo analogia a posição das partículas. O objetivo do código continua sendo minimizar os erros e alcançar os melhores ganhos. Portanto, a função objetivo permanece sendo a minimização do erro IAE. Porém neste caso, a minimização será entre o erro da resposta controlada do sistema e a entrada em degrau unitário.

Após todas as simulações e assim que o algoritmo atinge os critérios de parada, é encontrado o ponto ótimo da simulação. Esse ponto, analogamente ao processo natural ditado pelas metodologias do PSO, diz respeito ao pássaro que chegou mais próximo do destino estabelecido, ou então sistemicamente, seria a partícula que obteve os melhores ganhos K_p , K_i e K_d do controlador. Se comprovado que o controlador obtido proporciona uma resposta igual quando aplicado na função de transferência real e simulada, significa que o mesmo poderá ser utilizado diretamente na planta física.

3.4 CONTROLADOR APLICADO AOS SISTEMAS REAL E SIMULADO E COMPARAÇÃO DOS RESULTADOS

Após a obtenção dos ganhos de K_p , K_i e K_d , os valores são ajustados e normalizados no domínio da frequência para obtenção do controlador, por intermédio da equação a seguir:

$$G(s) = \frac{U(s)}{E(s)} = K_p + \frac{K_i}{s} + K_d s \quad (10)$$

Após a definição do controlador, o mesmo é inserido diretamente à função de transferência que representa a planta real, bem como, à função de transferência estimada pelo algoritmo PSO, em ambos os casos, em malha fechada.

O procedimento realizado, tem a intenção de comparar os resultados e verificar a eficiência do controlador em plantas reais. O processo, mais uma vez, contou com a aplicação do erro IAE que, desta vez, compara a resposta do sistema controlado real controlado com a resposta do sistema simulado também controlado. Se as respostas forem iguais ou aproximadas, significa que o controlador encontrado pelo algoritmo PSO é eficiente. A seguir, serão descritos os resultados obtidos.

4. RESULTADOS E DISCUSSÃO

O estudo se propôs a analisar a possibilidade de implementação de um controlador PID por meio da utilização do algoritmo de otimização por enxame de partículas, que será aplicado a função de uma planta de nível simulada, obtida pelo mesmo algoritmo. O processo será comparado a aplicação deste controlador a um sinal coletado da planta real.

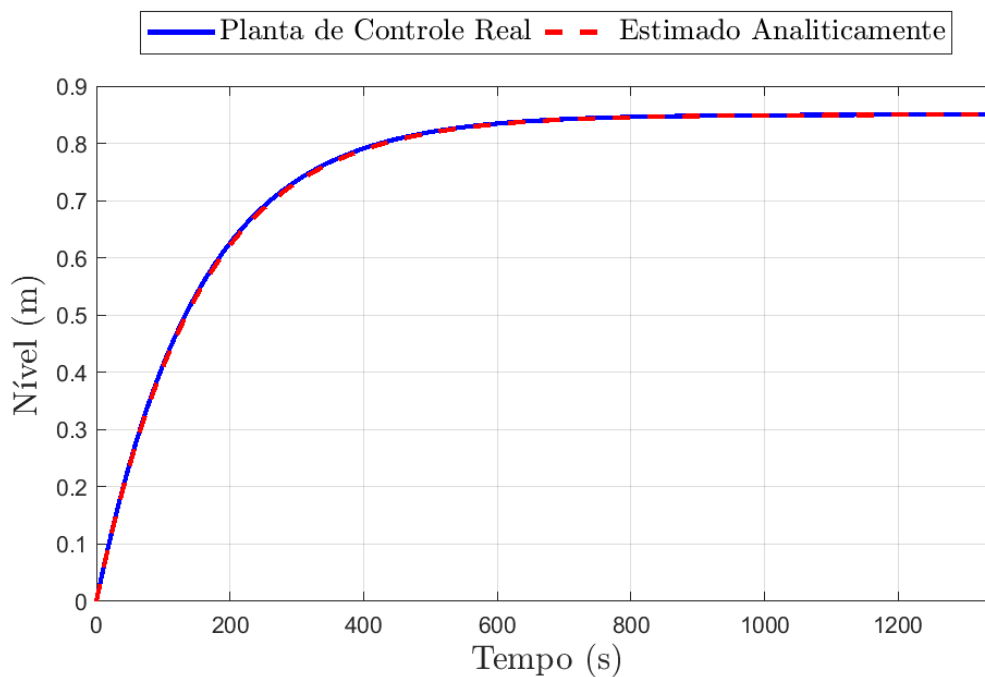
Das informações citadas, a ideia se apresenta em forma de sugestão para aplicação de controladores simulados com competência para serem aplicados em plantas reais de sistemas de nível.

Todo o processo de simulação foi realizado no software MATLAB, que se trata de um software iterativo de alta performance voltado para cálculos numéricos. Os resultados obtidos serão exibidos nas próximas seções.

4.1 ESTIMAÇÃO ANALÍTICA DA FUNÇÃO DE TRANSFERÊNCIA

Utilizando a estimação descrita na Seção 3.1, os valores obtidos para K e τ foram respectivamente 0,8504 e 152,1. A Figura 5 apresenta a comparação da resposta do sistema real e do sistema obtido analiticamente. Nível é a altura em que a substância do recipiente deverá ser mantida.

Figura 5 – Gráfico da resposta ao degrau da função de transferência por estimação analítica



Fonte: Elaborado pelo Autor.

Portanto, comparando-se com o sistema real, vê-se eficiência na utilização de estimação analítica para aproximação da função de transferência.

Entretanto, como deseja-se um sistema simulado o mais fiel possível ao real, os valores de K e τ obtidos serão utilizados como pontos iniciais para a otimização por enxame de partículas, o que irá otimizar ainda mais os resultados, como veremos nas próximas seções.

4.2 RESULTADOS DA OTIMIZAÇÃO DA FUNÇÃO DE TRANSFERÊNCIA

Como já mencionado, a estimação analítica da função de transferência foi usada como artifício para refinar a resposta simulada. Os valores de $K = 0,8504$ e $\tau =$

152,1 obtidos, serviram como ponto de partida para a otimização do sistema. Desta forma, foi possível reduzir a possibilidade de parada em mínimos locais, já que o valor final estará bem próximo do que foi encontrado analiticamente.

O algoritmo foi executado com 20 partículas e 100 iterações e os valores de K e τ obtidos neste processo são apresentados da Tabela 1:

Tabela 1 – Estimação do PSO para a função de transferência

Parâmetro	Valor
K	0,8514
τ	149,9

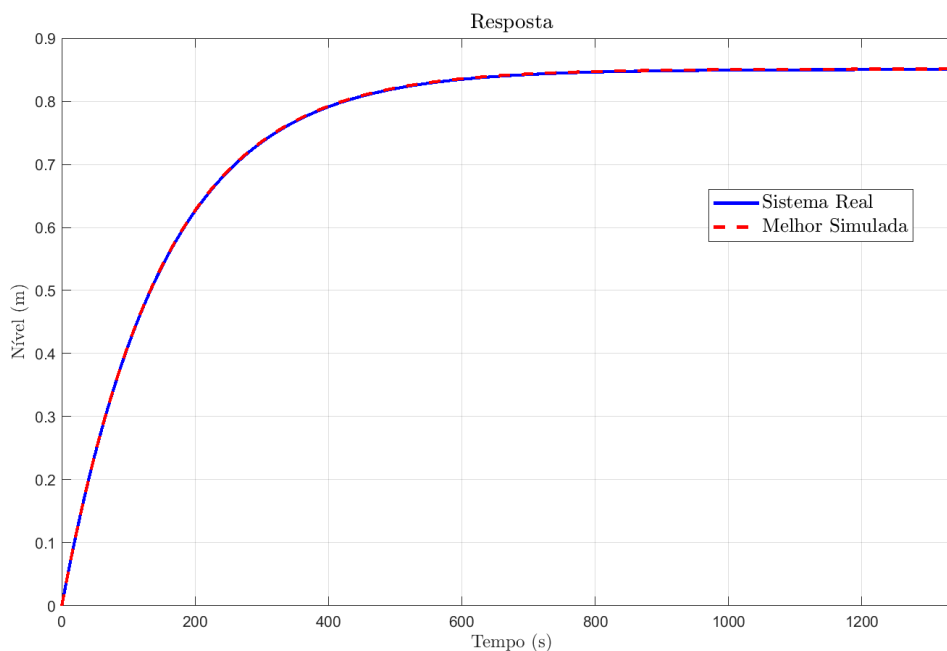
Fonte: Elaborado pelo Autor

Assim, a função de transferência encontrada pelo PSO pode ser escrita como:

$$G(s) = \frac{0,8514}{149,9s + 1} \quad (11)$$

A Figura 6 apresenta a resposta ao degrau do sistema real em comparação com a resposta do sistema estimado pelo PSO, já na Figura 7, pode ser visto também o ponto encontrado na ultima iteração do PSO.

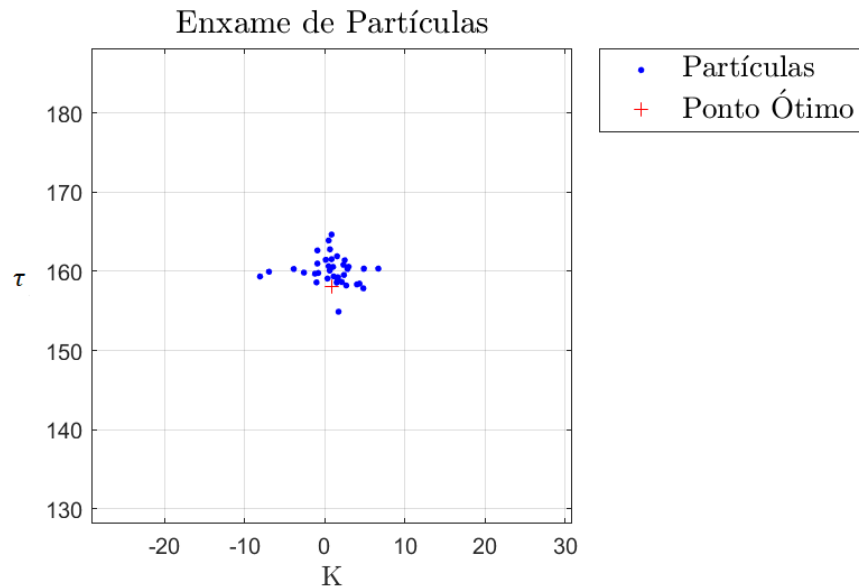
Figura 6 – Resposta ao degrau das funções de transferência



Fonte: Elaborado pelo Autor.

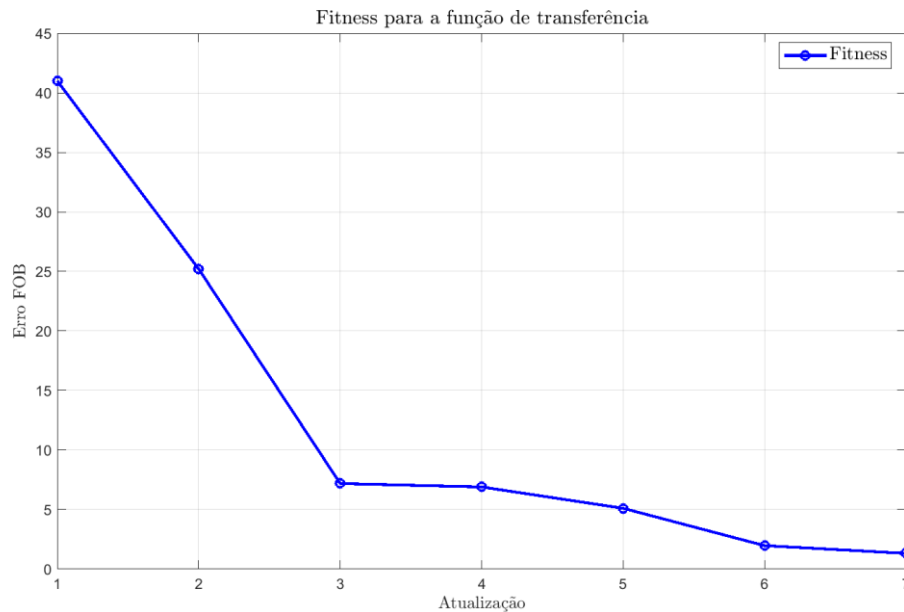
A resposta apresentada confirma que o algoritmo bioinspirado utilizado é capaz de reproduzir perfeitamente o sinal da planta de nível real.

Figura 7 – Melhor sinal da simulação realizada



Fonte: Elaborado pelo Autor.

A Figura 8 ilustra a função de avaliação de minimização do erro do sistema, também conhecida como função de fitness e tem como objetivo apresentar o gráfico que exibe a redução do erro IAE do algoritmo a cada atualização do mesmo.

Figura 8 – Função de Avaliação do Sistema (Fitness)


Fonte: Elaborado pelo Autor

4.3 RESULTADOS DA IMPLEMENTAÇÃO DO CONTROLADOR PID

Após a obtenção da função de transferência estimada pelo PSO, o algoritmo de otimização foi utilizado para otimizar o controlador PID. Sua finalidade é encontrar ganhos K_p , K_i e K_d para serem aplicados ao sistema real e estimado a fim de verificar se o mesmo poderá ser utilizado em sistemas reais.

Assim como na obtenção da função de transferência, o algoritmo foi executado com 20 partículas e 100 iterações. O controlador obtido é apresentado na Tabela 2.

Tabela 2 – Estimação do PSO para o controlador PID.

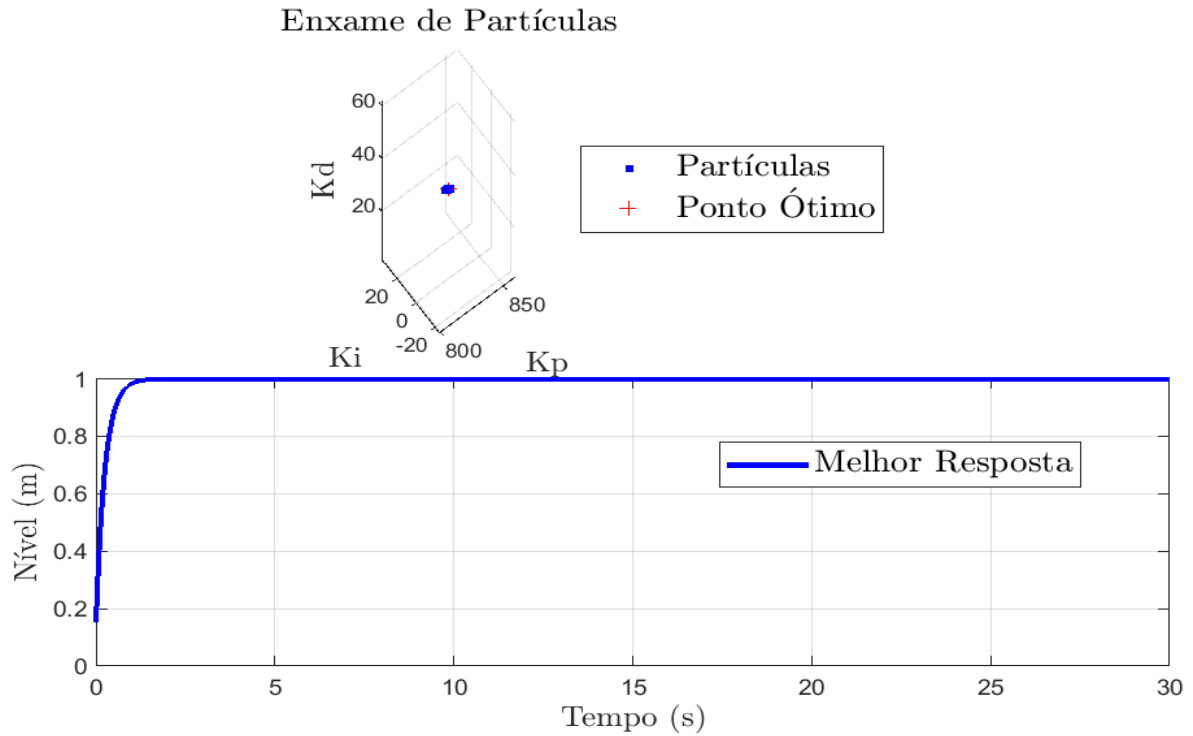
Ganho	Valor
K_p	829,3325
K_i	5,4463
K_d	31,5718

Fonte: Elaborado pelo Autor

A Figura 9 representa a última iteração do enxame de partículas, onde o melhor ponto encontrado é mostrado em vermelho e as demais partículas apresentadas em azul. A resposta ao degrau do melhor indivíduo também é apresentada na Figura 9,

onde pode-se perceber que o sistema respondeu rapidamente ao SP e não apresentou erro de estado estacionário.


Figura 9 – Melhor resposta para os ganhos do controlador.



Fonte: Elaborado pelo Autor

O fitness para a otimização do controlador pode ser visto na Figura 10.

Figura 10 – Função de Avaliação do Sistema (Fitness)



Fonte: Elaborado pelo Autor

Pode-se perceber que, mais uma vez, o erro foi diminuindo ao longo do processo. É perceptível também que nesta otimização foram obtidas mais atualizações de melhores do grupo ao longo das iterações bem como em uma mesma iteração obteve-se mais de uma partícula assumindo a liderança do grupo, visto que o número máximo de iterações é 100 e foram obtidas 124 atualizações de melhor do grupo.

Após a obtenção dos ganhos do controlador PID, pode-se aplica-lo no sistema real. O objetivo desta etapa é identificar a resposta ao degrau gerada em ambos os casos (simulado e real) e compará-las. Dessa forma, será possível verificar se o controlador encontrado será eficiente no sistema real da planta de nível.

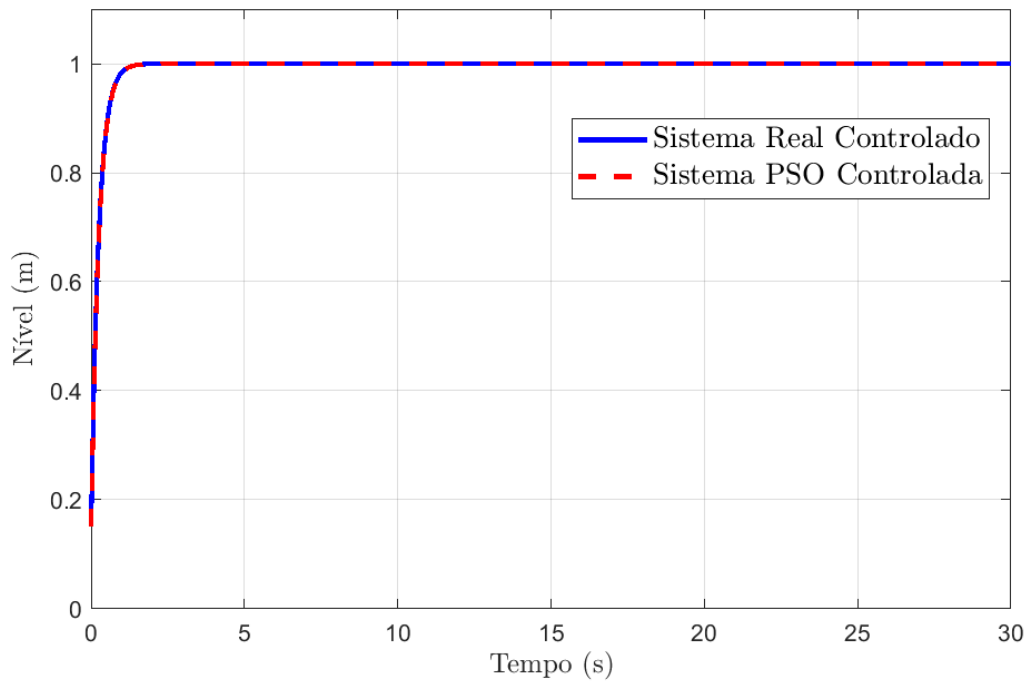
4.4 COMPARAÇÃO ENTRE OS SISTEMAS CONTROLADOS

Para verificar a confiabilidade das estimações desenvolvidas pelo PSO, optou-se por comparar a resposta do sistema controlado simulado, com a resposta do sistema real também controlado.

Ambos os sistemas utilizaram o controlador PID encontrado neste trabalho. Desta maneira, pode-se concluir que este controlador bem como a função de transferência, retratam a real dinâmica do sistema. Para uma comparação justa, será aplicado em ambos os sistemas um SP em degrau unitário, e então comparadas as saídas controladas de ambos.

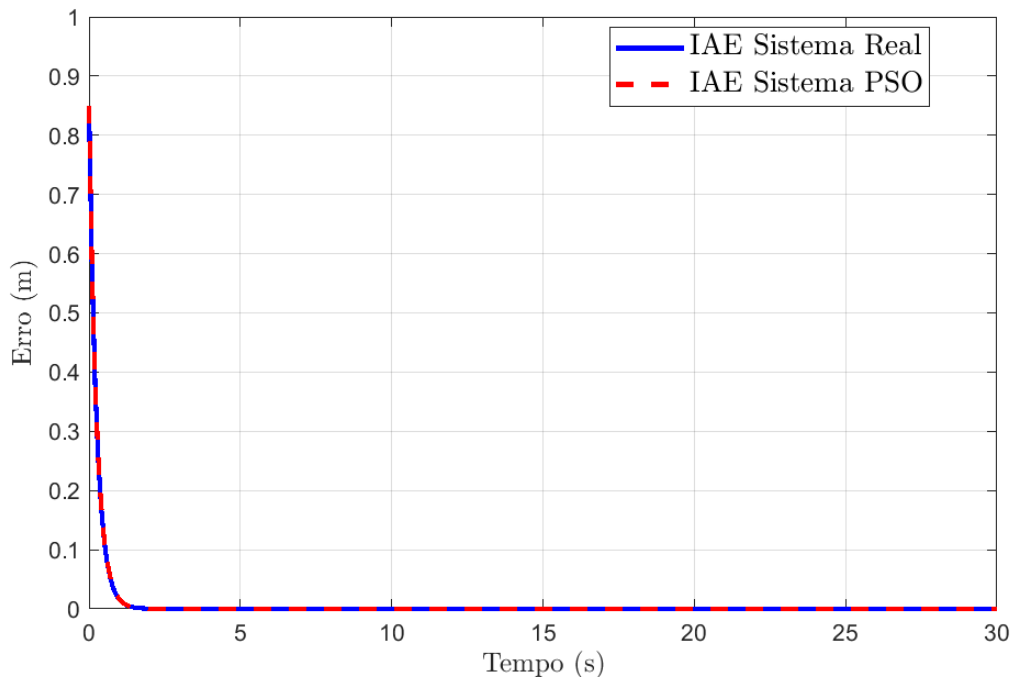
A Figura 11 apresenta a resposta ao degrau para ambos os sistemas controlados.

Figura 11 – Resposta ao degrau dos sistemas real e simulado controlados.



Fonte: Elaborado pelo Autor.

Pode-se perceber que o sistema real controlado (em azul) obteve o mesmo comportamento do sistema controlado completamente estimado pelo PSO. A Figura 12 apresenta o erro de controle de ambos os sistemas, que é uma outra maneira de verificar a similaridades entre eles.

Figura 12 – Erro dos sistemas controlados.


Fonte: Elaborado pelo Autor

Para obter uma métrica quantitativa de similaridade entre os sistemas, utilizou-se mais uma vez o erro IAE em ambas as saídas. O objetivo aqui é comparar tanto a amplitude como a forma de ambas as respostas, visto que se as mesmas forem iguais, o índice tenderá a zero. Assim, a Tabela 3 apresenta o erro IAE entre a resposta do sistema simulado controlado e a resposta do sistema real controlado.

Tabela 3 – Estimação do PSO para o controlador PID.

Índice	Valor
<i>IAE</i>	0,003

Fonte: Elaborado pelo Autor

Pode-se observar que, assim como o esperado, o índice IAE é praticamente nulo, provando quantitativamente a similaridade das respostas.

5. CONCLUSÃO

A proposta deste trabalho teve por fator norteador a proposição de um projeto de um controlador PID capaz de ser utilizado em plantas de nível reais. Foi realizada a estruturação computacional de todo o sistema por meio de simulações realizadas com auxílio do software MATLAB, a fim de garantir a aplicabilidade do método.

De modo geral, o projeto possui uma complexibilidade considerável, mas se fragmentado, fica intuitivo o seu desenvolvimento. Dividindo em três partes, foi possível estruturar uma lógica em sua organização. O primeiro passo do projeto foi desenvolver computacionalmente, por meio de um algoritmo de otimização (PSO), uma função de transferência que represente fielmente uma planta de nível. Para isso, foi usado como parâmetro de comparação, o sinal coletado de uma planta real. O segundo passo deste trabalho foi encontrar os ganhos do controlador PID utilizando o mesmo algoritmo de otimização. A obtenção dos ganhos tornou viável a implementação do controlador. Por fim, o mesmo foi aplicado à função de transferência da planta real e simulada. O intuito deste último passo foi identificar a resposta deste processo e verificar a capacidade de utilização do controlador em plantas reais. O que indica a eficiência do processo é a semelhança entre as curvas que identificam os sistemas e a análise do erro IAE aplicado aos mesmos.

O desenlace de toda essa dinâmica foi assertivo, levando em consideração que o erro IAE encontrado foi de apenas 0,003.

Portanto, pode-se concluir que o algoritmo de enxame de partículas pode ser utilizado para diferentes aplicações e se mostra uma opção de relativamente baixa complexidade de implementação, porém de resultado altamente eficiente.

De modo geral, a experiência foi positiva, sendo factível a obtenção de um controle satisfatório e dentro das especificações desejadas.

ABSTRACT

This work deals with the development of an optimization method applied to the identification of systems and the tuning of parameters of PID controllers. For that, it was used as a base, a computational model that works to improve problem solving, Particle Swarm Optimization. This methodology is based on modeling the social behavior of a flock of birds and with this, translating analytically how they are organized in their flocks. In other words, the method seeks an optimal solution in a search space through the exchange of information between individuals in the same group, thus determining which is the best path to be followed by each one of them until the best individual is found. The objective of the research is to investigate the potential of this device for the identification of systems and tuning of PID controllers, using the Matlab software. The results obtained demonstrate that the technique is efficient, both in the identification of systems and in the tuning of the PID controller.

Keywords: Process optimization. Level Control. PID controllers. Particle Swarm Optimization. Matlab.

REFERÊNCIAS

GONÇALVES, L. C. **Implementação de um controlador PI através de um algoritmo de otimização por colônia de formigas aplicado a planta didática de nível SMAR.** Trabalho de Conclusão de Curso. Centro Federal de Educação Tecnológica de Minas Gerais. Leopoldina,2016.

SHIRAHIGE, A.B. **Metodologia para aferição da ação de controle proporcional integral derivativa implementada em controladores industriais.** Dissertação de mestrado. Universidade de São Paulo. São Paulo,2007.

BAZANELLA, A. S. **Sistemas de Controle: princípios e métodos de projeto.** Editora UFRGS, 2005.

ALPI, L. **Desenvolvimento de uma Planta Didática para o Controle de Nível de Tanques Acoplados.** Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Sul. Porto Alegre,2016.

OGATA, K. **Engenharia de Controle Moderno**. Editora Pearson, 2005.

TEIXEIRA, H. C. G. **Controles Típicos de Equipamentos e Processos Industriais**. Editora Blucher, 2010.

RIBEIRO, J. **Algoritmos de Busca Aplicados a Controle de Sistemas de Tanque de Nível de uma Planta Didática Smar**. Trabalho de Conclusão de Curso. Centro Federal de Educação Tecnológica de Minas Gerais. Leopoldina, 2016.

NISE, NORMAN S. **Control Systems Engineering**. Editora. Editora LTDA, 2013.

MEDIEROS, J. A. C. C. **Enxame de Partículas como ferramenta de otimização em problemas complexos de engenharia nuclear**. Tese de Doutorado. Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2005.