

Controlador IHMPC aplicado a digestor contínuo de celulose: Sintonia por enxame de partículas e validação em simulador comercial

Gabriel Cardoso Alves^{a,*}, Raony Maia Fontes^a, Márcio André Fernandes Martins^a

^a Universidade Federal da Bahia, Programa de Pós-Graduação em Mecatrônica, Salvador-BA, Brasil

*g.cardoso@ufba.br

RESUMO

Este trabalho propõe a aplicação de um controlador preditivo baseado em modelo com horizonte de predição infinito (IHMPC) com tratamento de tempo morto e garantia de estabilidade nominal ao controle de um digestor contínuo de celulose Kraft. A sintonia do controlador foi realizada por uma metodologia offline com PSO para ajustar os elementos da matriz de supressão de movimento R , com base no ISE e na variação dos movimentos de controle, a solução final é definida pelo menor valor de função objetivo encontrada. O controlador foi sintonizado e validado em um simulador rigoroso sob condição de *mismatch*. Nos testes, manteve as três saídas em seus valores de referência, com sobressinal de aproximadamente 10% no número Kappa durante os transitórios.

Palavras-chave: OPOM, IHMPC, Digestor contínuo de celulose, Sintonia de controladores.

1 Introdução

A indústria de produção de papel e celulose é um segmento que tem aumentado sua capacidade produtiva em todo o mundo, apesar do declínio da produção de papel para impressão. Há uma crescente utilização da celulose para *tissue* e embalagens, que deverão sustentar o incremento de produção (Rahman et al., 2020), o que intensifica a busca por maior eficiência. O digestor contínuo Kraft é o principal método de polpação da atualidade (Larraín et al., 2020). No processo Kraft, a qualidade da polpa é expressa pelo número Kappa, cujo controle apresenta elevado grau de dificuldade devido a tempos mortos da ordem de 4 a 6 horas, forte acoplamento entre variáveis, dinâmicas não lineares, variabilidade na composição dos cavacos de madeira e medições com baixa frequência do número Kappa (Alexandridis et al., 2003; Rahman et al., 2020; Wisniewski e Doyle, 1996). Em virtude dessas dificuldades, o controle preditivo baseado em modelo (MPC) tem sido objeto de investigação no contexto de digestores contínuos, constituindo a abordagem mais explorada pela comunidade científica e industrial (Rahman et al., 2020).

Em um dos trabalhos pioneiros, Wisniewski e Doyle (1996) empregaram um MPC linear e um não-linear (NMPC) baseado no modelo de Purdue, com estimador de estado, demonstrando desempenho superior do NMPC em relação ao MPC linear. A partir desse estudo, a literatura da área evoluiu nas décadas seguintes, passando a investigar diversas outras variantes de controle preditivo. Entre elas, destacam-se: MPC linear com modelagem de subespaço (Kayihan, 1998; Wisniewski e Doyle, 2001), controle preditivo baseado em programação dinâmica matricial (DMC) (Al-Awami et al., 1999), MPC adaptativo com redes neurais de função de base radial (Alexandridis et al., 2003), MPC com modelo PLS (Alexandridis et al., 2004) e MPC com antecipação da medição de lignina por espectroscopia NIR (Rahman et al., 2019). Gilbert e Allison (2024) apresentaram uma aplicação industrial de GPC SiSo em um digestor contínuo no Canadá, obtendo redução de desvio no número Kappa. Contudo, a aplicação de um controlador IHMPC com tratamento explícito de tempo morto, baseado na formulação de Santoro e Odloak (2012), ao controle de um digestor contínuo de celulose não foi identificada na literatura consultada. Essa formulação oferece garantia de estabilidade nominal e viabilidade de solução.

Apesar das vantagens na implementação do MPC em um processo como o digestor, a sintonia para esse processo é pouco explorada na literatura, dadas a variedade de formulações de controlador e a complexidade do processo. Nesse contexto, a utilização de métodos de otimização meta-heurísticos surge como uma abordagem viável para sintonizar controladores MPC, sendo a otimização por enxame de partículas (PSO) adequada para esta tarefa, por se tratar de um método de busca global que não utiliza o cálculo de gradientes, tornando-o uma opção para funções objetivo complexas, não convexas e não analíticas (Suzuki et al., 2012).

Diante dessas considerações, este trabalho apresenta duas contribuições principais: (i) a aplicação de um

controlador IHMPC com tratamento de tempo morto ao digestor contínuo de celulose, configuração não identificada na literatura consultada; e (ii) uma metodologia de sintonia automática offline da matriz de supressão de movimento **R** por meio de PSO. Para validação, o IHMPC sintonizado irá controlar um digestor simulado no IDEAS™ simulador rigoroso de grande aceitação no mercado de produção de celulose. O artigo está organizado da seguinte forma: a Seção 2 descreve o processo do digestor contínuo de celulose e as variáveis do sistema; a Seção 3 apresenta a formulação do controlador IHMPC e o modelo utilizado; a Seção 4 descreve a metodologia de sintonia via PSO; a Seção 5 apresenta os resultados e discussão; e a Seção 6 contém as conclusões.


2 O Digestor Contínuo e a Simulação no IDEAS

O processo de conversão de madeira em celulose inicia-se no digestor, seu principal objetivo é extrair a lignina da madeira preservando ao máximo o rendimento e a qualidade das fibras celulósicas. O simulador utilizado neste trabalho representa um digestor contínuo Kraft do tipo Lo-Solids™ desenvolvido pela Andritz, cuja característica principal é a renovação de parte do meio aquoso durante o processo de deslignificação. Por meio do sistema de alimentação, os cavacos são transportados ao topo do digestor junto com o licor branco, que é uma solução de hidróxido de sódio (NaOH) e sulfeto de sódio (Na₂S). Nessa fase ocorre o processo de impregnação, que consiste na penetração e difusão do licor nos cavacos. Ao final dessa fase, é realizada a primeira retirada de líquido do processo. Na zona de cozimento, é adicionada energia para início da deslignificação. Logo após, encontra-se a zona de lavagem, onde é realizada a segunda extração. Essa zona é responsável por parar a reação de deslignificação e remover parte da lignina dissolvida na polpa. Por fim, na zona de descarga, a polpa é enviada para outras etapas do processo produtivo de celulose. Para compensar variações no ritmo de produção e na qualidade do licor branco, costuma-se utilizar a carga alcalina, definida como a razão entre massa de álcali e a massa de madeira que é adicionada ao digestor, como pode ser visto na Equação (1).

$$F = \frac{\dot{m}_{mad} \cdot CA}{C_{LB}} \quad (1)$$

onde F é a vazão de licor branco calculada em m^3/s , $\dot{m}_{mad}$ é a vazão mássica de madeira seca em kg/s , a carga é CA em % e C_{LB} é a concentração do licor branco em g/L .

Figura 1: Diagrama de processo do digestor.



A Figura 1 representa uma visão simplificada das informações contidas no IDEAS, onde é possível visualizar a real localização das variáveis manipuladas carga alcalina para o topo (U1), carga alcalina para a zona de cozimento (U2) e temperatura da recirculação de cozimento (U3), e as variáveis controladas residual de álcali na extração superior (Y1), residual de álcali na extração inferior (Y2) e número Kappa (Y3).

A integração entre o controlador desenvolvido em Python e o simulador é realizada por meio de comunicação OPC-DA, que permite a leitura e escrita de variáveis de processo em tempo real.

3 Modelagem do Processo e Controlador IHMPC

3.1 Modelagem do Processo

As variáveis controladas Y1, Y2 e Y3 e manipuladas U1, U2 e U3 foram escolhidas por serem citadas na literatura como variáveis chave no controle do digestor. Por se tratar de um ambiente de simulação considera-se que todas as variáveis controladas, incluindo o número Kappa, fornecem informação em tempo real.

Após a definição das variáveis, realizou-se a etapa de identificação dos modelos lineares pelo método de curva de reação. Esse método consiste em aplicar perturbações do tipo degrau nas variáveis manipuladas e identificar o modelo a partir da resposta das variáveis controladas.

Com os dados de entrada e saída foi utilizada a estrutura Box-Jenkins, implementada no Matlab™ para obtenção de modelos, cuja matriz de função de transferência é dada por:

$$G(s) = \begin{bmatrix} \frac{4.7e^{-6}s+9.5e^{-6}}{s^2+8.4e^{-3}s+1.2e^{-5}} \cdot e^{-240s} & 0 & 0 \\ \frac{2.8e^{-9}s^2+8.5e^{-9}s+8.5e^{-9}}{s^3+3.2e^{-3}s^2+5.7e^{-6}s+4.4e^{-9}} \cdot e^{-2320s} & \frac{2.9e^{-6}s+5.8e^{-6}}{s^2+2.0e^{-3}s+2.1e^{-6}} \cdot e^{-1620s} & \frac{-6.8e^{-5}}{s+7.9e^{-4}} \cdot e^{-3060s} \\ \frac{-5.9e^{-6}s-1.1e^{-5}}{s^2+1.6e^{-3}s+1.5e^{-6}} \cdot e^{-3840s} & \frac{-1.8e^{-5}s-3.6e^{-5}}{s^2+2.4e^{-3}s+3.1e^{-6}} \cdot e^{-1440s} & \frac{-2.5e^{-6}s-5.1e^{-6}}{s^2+2.3e^{-3}s+3.2e^{-6}} \cdot e^{-2820s} \end{bmatrix}$$

4 Modelagem do Processo e Controlador IHMPC

4.1 Modelo OPOM

O modelo do processo utilizado no controlador é baseado na formulação OPOM (*Output Prediction Oriented Model*) proposta por Santoro e Odloak (2012), que permite representar sistemas MIMO estáveis com tempos mortos distintos entre cada par entrada-saída. Considera-se um sistema com n_u entradas e n_y saídas, onde a função de transferência de cada par (y_i, u_j) é dada por:

$$G_{i,j}(s) = \frac{b_{i,j,0} + \dots + b_{i,j,n_b} s^{n_b}}{(s - r_{i,j,1}) \dots (s - r_{i,j,n_a})} \cdot e^{-\theta_{i,j}s} \quad (2)$$

em que $r_{i,j,p}$ são os polos estáveis distintos ($n_b < n_a$ e $\theta_{i,j}$ é o tempo morto associado ao par (y_i, u_j)). A resposta ao degrau discretizada com período Δt é:

$$S_{i,j}(k\Delta t) = \begin{cases} d_{i,j}^0 + \sum_{p=1}^{n_a} d_{i,j,p} e^{r_{i,j,p}(k\Delta t - \theta_{i,j})}, & \text{se } k\Delta t > \theta_{i,j} \\ 0, & \text{se } k\Delta t \leq \theta_{i,j} \end{cases} \quad (3)$$

em que $d_{i,j}^0$ é o ganho estático e $d_{i,j,p}^d$ são os resíduos dos modos estáveis, obtidos por frações parciais de $G_{i,j}(s)/s$.

A partir de (3), o modelo em espaço de estados na forma incremental conforme Santoro e Odloak (2012):

$$\mathbf{x}(k+1) = \mathbf{A}\mathbf{x}(k) + \mathbf{B}\Delta\mathbf{u}(k) \quad (4)$$

$$\mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) \quad (5)$$

em que $\mathbf{x} = [\mathbf{x}^s \mathbf{x}^d \mathbf{z}_1^T \dots \mathbf{z}_{\theta_{\max}}^T]^T \in \mathbb{R}^{n_x}$ com $n_x = n_y + n_d + n_u \theta_{\max}$, $\mathbf{x}^s \in \mathbb{R}^{n_y}$ corresponde aos estados integradores introduzidos pela forma incremental, $\mathbf{x}^d \in \mathbb{C}^{n_d}$ aos modos estáveis do sistema ($n_d = n_y \cdot n_u \cdot n_a$) e $\theta_{\max} = \max_{i,j} \theta_{i,j}$ é o maior tempo morto do sistema. A matriz estendida $\mathbf{A} \in \mathbb{R}^{n_x \times n_x}$ é composta por: $\mathbf{I}_{n_y}$ na posição diagonal correspondente a $\mathbf{x}^s$, $\mathbf{F} = \text{diag}(e^{r_{i,j,p}\Delta t})$ na posição diagonal correspondente a $\mathbf{x}^d$, e uma cadeia de deslocamento na região dos componentes $\mathbf{z}_m$, onde $\mathbf{I}_{n_y}$ aparece na subdiagonal e zeros na diagonal. Os componentes $\mathbf{z}_m$ são definidos como $\mathbf{z}_m(k) = \Delta\mathbf{u}(k-m)$, $m = 1, \dots, \theta_{\max}$. A matriz $\mathbf{B}$ é constituída por $\mathbf{B}_0^s$ e $\mathbf{B}_0^d$ nas posições correspondentes a $\mathbf{x}^s$ e $\mathbf{x}^d$, e $\mathbf{I}_{n_y}$ na posição de $\mathbf{z}_1$. A matriz de saída $\mathbf{C} \in \mathbb{R}^{n_y \times n_x}$ extrai os componentes $\mathbf{x}^s$ e $\mathbf{x}^d$ do vetor de estado aumentado, sendo composta por $\mathbf{I}_{n_y}$ na posição correspondente a $\mathbf{x}^s$, Ψ na posição correspondente a $\mathbf{x}^d$ e zeros nas posições dos componentes $\mathbf{z}_m$. As matrizes $\mathbf{A}$, $\mathbf{B}$ e $\mathbf{C}$ do modelo aumentado são detalhadas em Santoro e Odloak (2012).

4.2 Lei de controle do IHMPC

O controlador é formulado como o seguinte problema de otimização, adaptado de Santoro e Odloak (2012):

$$\min_{\Delta \mathbf{u}_k, \delta_{y,k}} V_k = \sum_{j=0}^{m'-1} (\mathbf{y}(k+j|k) - \mathbf{y}_{sp} - \delta_{y,k})^T \mathbf{Q}_y (\mathbf{y}(k+j|k) - \mathbf{y}_{sp} - \delta_{y,k}) + \mathbf{x}^d(k+m'|k)^T \bar{\mathbf{Q}} \mathbf{x}^d(k+m'|k) + \sum_{j=0}^{m-1} \Delta \mathbf{u}(k+j|k)^T \mathbf{R} \Delta \mathbf{u}(k+j|k) + \delta_{y,k}^T \mathbf{S}_y \delta_{y,k} \quad (6)$$

sujeito à :

$$\mathbf{x}^s(k+m'|k) + \delta_{y,k} = \mathbf{y}_{sp} \quad (7) \quad -\Delta \mathbf{u}_{\max} \leq \Delta \mathbf{u}(k+j|k) \leq \Delta \mathbf{u}_{\max}, \quad j = 0, \dots, m-1 \quad (8)$$

$$\mathbf{u}_{\min} \leq \mathbf{u}(k+j|k) \leq \mathbf{u}_{\max}, \quad j = 0, \dots, m-1 \quad (9)$$

em que $m' = m + \theta_{\max}$ é o horizonte estendido, m é o horizonte de controle, $\mathbf{Q}_y \succ 0$ pondera o erro de rastreamento, $\mathbf{R} \succ 0$ pondera a supressão de movimento das entradas, $\mathbf{S}_y \succ 0$ penaliza as variáveis de folga $\delta_{y,k}$, $\Delta \mathbf{u}_{\max}$ incremento máximo da entrada a cada passo, $\mathbf{u}_{\max}$ e $\mathbf{u}_{\min}$ limite superior e inferior das entradas, respectivamente. A matriz $\bar{\mathbf{Q}}$ é obtida como solução da equação de Lyapunov discreta:

$$\bar{\mathbf{Q}} = \Psi^T \mathbf{Q}_y \Psi + \mathbf{F}^T \bar{\mathbf{Q}} \mathbf{F} \quad (10)$$

garantindo que a função custo V_k constitui uma função de Lyapunov para o sistema em malha fechada, o que assegura estabilidade nominal do controlador (Santoro e Odloak, 2012). As matrizes $\mathbf{S}_y$ devem satisfazer $\mathbf{S}_y \gg \mathbf{Q}_y$ para garantir a convergência das saídas aos seus setpoints.

5 PSO Como ferramenta de sintonia do controlador

O desempenho do IHMPC é determinado pela seleção das matrizes $\mathbf{Q}_y$, $\mathbf{R}$, $\mathbf{S}_y$, e m . A matriz $\mathbf{S}_y$ é dedicada às variáveis de folga e sua função é garantir a viabilidade do problema de otimização do controlador. Esta matriz deve apresentar magnitude várias ordens de grandeza superior à $\mathbf{Q}_y$ (González e Odloak, 2009). Dessa forma, $\mathbf{S}_y$ foi definida como uma matriz diagonal com seus elementos arbitrados em 10^4 . O horizonte de controle é denotado por m e define o número de ações de controle futuras calculadas pelo algoritmo. Valores elevados conferem mais graus de liberdade ao controlador, podendo resultar em ações de controle mais suaves, além de incrementar o tempo de computo do algoritmo, enquanto valores baixos reduzem o custo computacional e tendem a produzir respostas mais agressivas. Segundo Yamashita (2015), valores entre 3 e 6 representam uma relação adequada entre desempenho e custo de processamento, sendo neste trabalho definido como 6.

As matrizes $\mathbf{Q}_y$ e $\mathbf{R}$ representam, respectivamente, a importância relativa entre as variáveis controladas e a supressão do esforço de controle. Os valores de $\mathbf{Q}_y$ contemplam a importância relativa entre as saídas, sendo definidos com base em conhecimento do processo ou objetivos econômicos (Yamashita, 2015), portanto, neste trabalho adotam-se os valores diagonais (1,0; 1,0; 1,1). Já a matriz $\mathbf{R}$ de supressão do esforço, tem impacto direto no desempenho do controlador a depender da sua comparação com o $\mathbf{Q}_y$. Uma vez que $\mathbf{Q}_y$ fica fixada pela importância relativa das saídas, a matriz $\mathbf{R}$ torna-se o parâmetro efetivo de sintonia do controlador. Valores relativamente maiores de $\mathbf{R}$ penalizam mais os movimentos de controle, produzindo um controlador mais suave e conservador, enquanto valores menores priorizam o rastreamento de setpoint, produzindo respostas mais agressivas. Nesse sentido, este trabalho foca na seleção adequada do $\mathbf{R}$ a partir de um problema de otimização com os critérios de sintonia definidos pela integral do erro quadrático (ISE) e pela integral dos desvios da variável manipulada (IDMV), definindo assim a função objetivo:

$$\min_{\mathbf{R}} J(\mathbf{R}) = \alpha \cdot IDMV + \beta \cdot ISE \quad (11)$$

sujeito à:

$$\mathbf{R}_{\min} \leq \mathbf{R} \leq \mathbf{R}_{\max} \quad (12) \quad |J^{(k)} - J^{(k-1)}| < \varepsilon \quad (13)$$

onde $\mathbf{R}_{\min}$ e $\mathbf{R}_{\max}$ são os limites de valores possíveis para $\mathbf{R}$, α e β são pesos para definir o grau de importância de cada um dos indicadores de desempenho, $J^{(k)}$ e $J^{(k-1)}$ representam os valores da função custo na iteração atual e na anterior, respectivamente, enquanto ε define a tolerância de convergência para o critério de parada relativo a J .

A escolha do PSO como método de otimização para solucionar o problema proposto na Equação (11), justifica-se por operar por meio de busca global no espaço de soluções, sem necessidade de cálculo de gradientes, sendo adequado para funções objetivo não convexas e não analíticas (Suzuki et al., 2012).


O método consiste em realizar 4.000 execuções do algoritmo PSO, cada uma com 20 partículas, máximo de iteração 60, fatores cognitivo (c_1) 1.6, fator social (c_2) 1.0, o peso de inércia w partindo de 0.95 até 0.4 ao longo das iterações, limite inferior $R_{\min}$ 0.1 e limite superior $R_{\max}$ 20000. As múltiplas execuções buscam mitigar a sensibilidade do PSO a inicializações estocásticas e em busca da solução ótima. Os parâmetros do controlador foram definidos pelos valores de R relacionado à execução de menor função objetivo dentre as simulações.

6 Resultados e Discussão

Foram realizadas 4000 simulações do controlador em malha fechada utilizando o algoritmo PSO. A Figura 2(a) representa a fronteira de Pareto entre o esforço de controle e a rastreabilidade da referência. Em (b), (c) e (d) é possível verificar a distribuição dessas soluções no espaço de parâmetros (R_1 , R_2 , R_3), em relação a função custo. Os círculos em azuis representam todas as soluções obtidas pelo PSO. A estrela em cada painel indica a melhor solução, com $R_1 = 1390$, $R_2 = 1097$ e $R_3 = 52$, configuração efetivamente adotada no controlador.

A Figura 2 evidencia que o algoritmo PSO explorou amplamente o espaço de busca e que as soluções de melhor desempenho, a concentração estreita das soluções de baixo custo em R_2 e R_3 , frente à dispersão em R_1 , indica que o desempenho do controlador é mais sensível a R_2 e R_3 . Mesmo com essa sensibilidade, o ponto de menor custo localiza-se simultaneamente no mínimo dos três painéis, adotando-o como sintonia do controlador.

Figura 2: Resultados das 4.000 execuções do PSO. (a) Fronteira de Pareto. (b–d) Função custo em função de (R_1 , R_2 , R_3). A estrela indica a solução de menor custo.



A Figura 3 apresenta a resposta do controlador IHMPC, sintonizado via PSO, aplicado ao simulador rigoroso IDEAS. As variáveis controladas $Y1$ (residual superior) e $Y2$ (residual inferior) alcançaram seus valores de referência sem sobressinal. O número Kappa ($Y3$) apresentou sobressinal de aproximadamente 10%, comportamento possivelmente associado ao maior tempo morto dessa variável. As variáveis manipuladas permaneceram dentro dos limites operacionais ao longo de toda a simulação. Os resultados indicam que, apesar do *mismatch* entre os modelos, os parâmetros obtidos pelo PSO produziram desempenho satisfatório no simulador rigoroso.


7 Conclusão

A estrutura de controle aqui proposta se mostrou capaz de conduzir as variáveis controladas aos seus valores de referência, bem como acompanhar suas alterações. A utilização de IHMPC reduz a quantidade de parâmetros de ajuste, o que facilita a implementação do controlador.

Com a utilização do PSO para sintonizar o IHMPC é possível simplificar e padronizar a sintonia proposta em diferentes aplicações, reduzindo o grau de subjetividade e a necessidade de especialistas no assunto.

O método de sintonia offline utilizando o PSO, mostrou-se capaz de encontrar uma sintonia ótima que obteve resposta aceitável mesmo em condição de *mismatch*, contudo, o sobressinal no número Kappa requer investigação adicional para determinar se decorre de dinâmica não capturada pelo modelo linear utilizado, influen-

Figura 3: Resposta do controlador na planta simulada.



cia do elevado tempo morto ao qual essa variável está sujeita ou até mesmo influência da sintonia selecionada.

A utilização de controladores IHMPC por faixa e com objetivos econômicos, comparação de desempenho entre MPC, IHMPC e IHMPC por faixa além da investigação do sobressinal no número Kappa ficam como opções de trabalhos futuros.

Agradecimentos: Gostaria de agradecer à Andritz pelo fornecimento da licença do simulador de processo IDEAS.

Referências

- Al-Awami, L., Sidrak, Y., & Bettayeb, M. (1999). Classical and dynamic matrix control of Kamyr digesters: a comparative study. *Ind. Eng. Chem. Res.*, 38(10), 3950–3956.
- Alexandridis, A., Sarimveis, H., & Bafas, G. (2003). Adaptive control of continuous pulp digesters based on radial basis function neural network models. Em *Computer Aided Chemical Engineering* (pp. 995–1000, Vol. 14). Elsevier.
- Alexandridis, A., Sarimveis, H., & Bafas, G. (2004). Modeling and control of continuous digesters using the PLS methodology. *Chem. Eng. Commun.*, 191(10), 1271–1284.
- Gilbert, W., & Allison, B. (2024). Control of continuous digester kappa number using generalized model predictive control. *TAPPI J.*, 23(9), 467–476.
- González, A. H., & Odloak, D. (2009). A stable MPC with zone control. *Journal of Process Control*, 19(1), 110–122.
- Kayihan, F. (1998). Kappa number profile control for continuous digesters. Em *Nonlinear Model Based Process Control* (pp. 805–829). Springer.
- Larraín, S., Pradenas, L., Pulkkinen, I., & Santander, F. (2020). Multiobjective optimization of a continuous kraft pulp digester using SPEA2. *Comput. Chem. Eng.*, 143, 107086.
- Rahman, M., Avelin, A., & Kyprianidis, K. (2019). An approach for feedforward model predictive control of continuous pulp digesters. *Processes*, 7(9), 602.
- Rahman, M., Avelin, A., & Kyprianidis, K. (2020). A review on the modeling, control and diagnostics of continuous pulp digesters. *Processes*, 8(10), 1231.
- Santoro, B. F., & Odloak, D. (2012). Closed-loop stable model predictive control of integrating systems with dead time. *Journal of Process Control*, 22(7), 1209–1218.
- Suzuki, R., Kawai, F., Nakazawa, C., Matsui, T., & Aiyoshi, E. (2012). Parameter optimization of model predictive control by PSO. *Electrical Engineering in Japan*, 178(1), 40–49.
- Wisniewski, P. A., & Doyle, F. J., III. (1996). A reduced model approach to estimation and control of a Kamyr digester. *Comput. Chem. Eng.*, 20, S1053–S1058.
- Wisniewski, P. A., & Doyle, F. J., III. (2001). Model-based predictive control studies for a continuous pulp digester. *IEEE Trans. Control Syst. Technol.*, 9(3), 435–444.
- Yamashita, A. S. (2015). Development of a multi-objective tuning technique for model predictive controllers. *Phd, USP*.