

CONTROLE PREDITIVO COM GARANTIA DE ESTABILIDADE E FACTIBILIDADE EMBARCADO EM UM CLP INDUSTRIAL

BRUNO A. SANTANA*, MÁRCIO A. F. MARTINS*, THIAGO P. CHAGAS†

*Programa de Pós-Graduação em Mecatrônica, Universidade Federal da Bahia, Salvador, BA, Brasil.

†Laboratório de Mecatrônica, Universidade Estadual de Santa Cruz, Ilhéus, BA, Brasil.

Emails: bruno.aguiar@ufba.br, marciomartins@ufba.br, tpchagas@uesc.br

Abstract— This work presents an implementation of a stabilizing model predictive control strategy with guaranteed feasibility on an industrial programmable logic controller (PLC), hitherto unexplored in the literature. The formulation of this controller results in a quadratic programming problem that is always feasible, therefore, it becomes an attractive option for industrial applications. In order to calculate the stabilizing control law, the ADMM optimization technique (Alternating Direction Method of Multipliers) is used, enabling the control of a fast dynamic electromechanical system in a PLC with low memory capacity and limited computational performance. Simulation and experimental results illustrate the good performance and robustness of the implemented MPC controller, which is able to tolerate a certain degree of plant-model mismatch, making it suitable for practical applications.

Keywords— Predictive control, closed-loop stability, feasibility, PLC, ADMM.

Resumo— Este trabalho apresenta a implementação de uma estratégia de controle preditivo baseado em modelo estabilizante com garantia de factibilidade em um controlador lógico programável (CLP) industrial, tratando-se de uma aplicação ainda não descrita na literatura. A formulação deste controlador resulta em um problema de programação quadrática que é sempre viável, por isso, torna-se uma opção atrativa para aplicações industriais. Para calcular a lei de controle estabilizante é proposta a utilização da técnica de otimização ADMM (*Alternating Direction Method of Multipliers*), viabilizando o controle de um sistema eletromecânico de dinâmica rápida em um CLP com baixa capacidade de memória e desempenho computacional limitado. Resultados de simulação e experimentais ilustram o bom desempenho e a robustez do controlador MPC implementado, o qual é capaz de tolerar certo grau de desassociação no modelo da planta, apontando-o como uma estratégia de controle adequada para aplicações práticas.

Palavras-chave— Controle preditivo, estabilidade em malha fechada, factibilidade, CLP, ADMM.

1 Introdução

O controle preditivo baseado em modelo (MPC, do inglês *Model Predictive Control*) é uma estratégia de controle avançado usualmente empregada na indústria de processos. A aplicação desta estratégia tem grande aceitação por ser uma técnica capaz de lidar com sistemas de dinâmica complexa e tratar naturalmente as restrições do processo em sua formulação (Camacho and Bordons, 2004). Tradicionalmente, o MPC é hospedado por um computador em sistemas digitais de controle distribuído (SDCD) que atua, de modo remoto, controlando os pontos de ajuste dos controladores, em sua maioria controladores PID, responsáveis por garantir a estabilidade de variáveis de processo como temperatura, pressão entre outras.

No entanto, com os avanços no desenvolvimento de *hardware*, *software* e métodos numéricos, controladores avançados, como o MPC, começaram a ganhar espaço em aplicações de baixos níveis de automação. Além disso, diversos autores já demonstraram que a utilização do MPC em malhas locais é uma opção viável, obtendo-se, inclusive, sintonia mais intuitiva e desempenho superior em relação aos controladores PID clássicos (Pannocchia et al., 2005; Valencia-Palomo and Rossiter, 2009).

Neste contexto, o controlador lógico progra-

mável (CLP) é o computador mais utilizado em malhas de controle de baixo nível, o qual é baseado em um microprocessador com função dedicada. Apesar de sua operação robusta e confiável, este *hardware* de computação geralmente possui baixo poder de processamento e baixa capacidade de memória, fatores que podem limitar a implementação das estratégias de controle avançado. O número de artigos que discutem implementações de controle preditivo em CLP é ainda limitado, por isso quando se aborda este tipo de aplicação os autores, em geral, propõe técnicas para solucionar o problema de otimização do MPC de forma eficiente, a fim de viabilizar a aplicação do controlador no referido *hardware* (Valencia-Palomo and Rossiter, 2009; Huyck et al., 2014; Kufolator et al., 2014; Levenson et al., 2017; Krupa et al., 2018).

Nos artigos supracitados, questões como estabilidade em malha fechada e factibilidade não são abordadas. No entanto, como o uso da estratégia MPC pode causar uma resposta instável em malha fechada (Maciejowski, 2002), considerar a estabilidade em malha fechada e factibilidade são aspectos muito importantes quando se pretende aplicar tal estratégia. Além disso, a factibilidade é uma propriedade essencial neste caso, uma vez que o domínio de atração do controlador se torna muito reduzido para atender a restrições rígidas

associadas às formulações que garantem uma lei de controle estabilizante.

Odloak (2004) propõe um MPC de horizonte infinito (IHMP) baseado em restrições terminais suavizadas, que é uma versão estendida da formulação proposta por Muske and Rawlings (1993). Com isso, o controlador possui garantia de estabilidade nominal e resulta em um problema de programação quadrática (QP, do inglês *Quadratic Programming*) que é sempre viável, tornando-o adequado para implementação. Apesar das vantagens deste controlador MPC, sua implementação em sistemas reais, assim como a vasta maioria dos controladores MPC estabilizantes propostos até então, ainda se encontra em andamento (Brugnolli et al., 2019; Silva et al., 2020), contudo, aplicações envolvendo CLP não foram descritas na literatura até então.

O principal objetivo deste trabalho é implementar a formulação do MPC proposta por Odloak (2004) em um CLP industrial, utilizando como estudo de caso o controle de um sistema eletromecânico de dinâmica rápida. Para solucionar a QP associada à formulação de controle estabilizante é utilizada a técnica ADMM (*Alternating Direction Method of Multipliers*), que já foi avaliada em Santana et al. (2019) para calcular a lei de controle do IHMP, o que permitiu avançar na implementação prática via CLP. As principais contribuições deste artigo são: (i) validação da técnica de otimização proposta para calcular a lei de controle estabilizante; (ii) análise experimental da robustez da lei de controle embarcada no CLP.

2 Formulação do MPC nominalmente estável

A formulação do MPC de horizonte infinito, em sua versão implementável com garantia de factibilidade, é resumida pelo seguinte problema de otimização (Odloak, 2004):

Problema 1.

$$\begin{aligned} \min_{\Delta u_k, \delta_k} V_k = & \sum_{j=1}^m \|y(k+j|k) - y_{sp,k} - \delta_k\|_Q^2 \\ & + \|x^d(k+m|k)\|_{\bar{Q}}^2 \\ & + \sum_{j=0}^{m-1} \|\Delta u(k+j|k)\|_R^2 + \|\delta_k\|_S^2, \end{aligned}$$

sujeito a:

$$x^s(k+m|k) - y_{sp,k} - \delta_k = 0, \quad (1)$$

$$\Delta u(k+j|k) \in \mathbb{U}, \quad j = 0, \dots, m-1, \quad (2)$$

$$\mathbb{U} = \left\{ \begin{array}{l} -\Delta u_{max} \leq \Delta u(k+j|k) \leq \Delta u_{max} \\ \Delta u(k+j|k) = 0, j \geq m \\ u_{min} \leq u(k-1) + \sum_{i=0}^j \Delta u(k+i|k) \leq u_{max} \end{array} \right\}$$

onde $m \in \mathbb{N}_{\neq 0}$ é o horizonte de controle, $\Delta u(k+j|k) \in \mathbb{R}^{nu}$ é o vetor de movimentos da entrada no instante de tempo $k+j$ e a sequência ao longo do horizonte de controle Δu_k é o vetor de variáveis de decisão, $Q \in \mathbb{R}^{ny \times ny}$ é a matriz definida positiva de ponderação das saídas controladas, $R \in \mathbb{R}^{nu \times nu}$ é a matriz semi-definida positiva de ponderação dos movimentos das entradas, $\delta_k \in \mathbb{R}^{ny}$ é o vetor de variáveis de folga, $S \in \mathbb{R}^{ny \times ny}$ é a matriz definida positiva de ponderação das variáveis de folga, $y_{sp,k} \in \mathbb{R}^{ny}$ é o vetor de referências das variáveis controladas, $y(k+j|k) \in \mathbb{R}^{ny}$ é o vetor de saídas previstas no instante de tempo $k+j$ calculada no instante k , considerando o modelo em espaço de estados obtido de uma expressão analítica da resposta ao degrau do sistema, dado por:

$$\begin{bmatrix} x^s(k+1) \\ x^d(k+1) \end{bmatrix} = \underbrace{\begin{bmatrix} I_{ny} & 0 \\ 0 & F \end{bmatrix}}_A \begin{bmatrix} x^s(k) \\ x^d(k) \end{bmatrix} + \underbrace{\begin{bmatrix} D^0 \\ D^d F N \end{bmatrix}}_B \Delta u(k)$$

$$y(k) = \underbrace{\begin{bmatrix} I_{ny} & \Psi \end{bmatrix}}_C \begin{bmatrix} x^s(k) \\ x^d(k) \end{bmatrix}. \quad (3)$$

No modelo definido em (3), $x^s(k)$ são os estados integradores artificiais introduzidos pela forma incremental das entradas e $x^d(k)$ são os estados estáveis do sistema. As demais matrizes do modelo são obtidas a partir dos coeficientes da resposta ao degrau da função de transferência do sistema, e podem ser encontradas com mais detalhes em Odloak (2004).

Além disso, a restrição terminal de igualdade (1) associada aos estados integradores artificiais (x^s) deve ser imposta ao fim do horizonte de controle para limitar a função custo do controlador. Note que nessa restrição é incluído o vetor de variáveis de folga (δ) para suavizá-la, resultando em um problema que é sempre viável. Na prática, a infactibilidade ocorre geralmente quando há grandes distúrbios no sistema ou quando os valores das referências variam consideravelmente.

Por fim, o termo do custo terminal relacionado aos estados estáveis (x^d) é naturalmente adotado e a matriz de ponderação \bar{Q} é calculada a partir da solução da equação de Lyapunov do sistema:

$$\bar{Q} = \Psi^T Q \Psi + F^T \bar{Q} F. \quad (4)$$

3 Algoritmo ADMM

Neste trabalho, propõe-se a utilização do ADMM para calcular a lei de controle quadrática do IHMP. A escolha deste algoritmo ocorre por ser de fácil implementação e capaz de fornecer, dentro de poucas iterações, uma solução, suficientemente precisa, para o **Problema 1** (Santana

et al., 2019), tornando-o adequado para a implementação embarcada no CLP.

Considere o seguinte problema geral de programação quadrática:

$$\begin{aligned} \min \quad & \frac{1}{2}x^T Hx + q^T x \\ \text{s.a.} \quad & A_{\text{eq}}x = b_{\text{eq}}, \\ & A_{\text{ineq}}x \leq b_{\text{ineq}}, \end{aligned} \quad (5)$$

onde $H \in \mathbb{S}_+^n$, $x \in \mathbb{R}^n$, $A_{\text{eq}} \in \mathbb{R}^{m \times n}$, $b_{\text{eq}} \in \mathbb{R}^m$, $A_{\text{ineq}} \in \mathbb{R}^{p \times n}$ e $b_{\text{ineq}} \in \mathbb{R}^p$. No caso do **Problema 1**, o vetor x irá conter a sequência de ações da lei de controle, incluindo a variável de folga para relaxação da restrição terminal, portanto terá dimensão $x \in \mathbb{R}^{m \cdot nu + ny}$. Para utilizar o algoritmo ADMM, o problema expresso em (5) deve ser reescrito para a forma padrão requerida pelo método de otimização em questão. Os passos deste processo serão omitidos, mas podem ser encontrados com detalhes em Santana et al. (2019), onde o problema de (5) é reescrito acrescentando-se variáveis de folga (z) como:

$$\begin{aligned} \min \quad & f(x) + g(z) \\ \text{s.a.} \quad & A_p x + \tilde{\mathbf{I}}z - b_p = 0, \end{aligned} \quad (6)$$

onde:

$$\begin{aligned} f(x) &= \frac{1}{2}x^T Hx + q^T x, \\ g(z) &= \begin{cases} 0 & \text{se } z \geq 0 \\ \infty & \text{se } z < 0, \end{cases} \\ A_p &= [A_{\text{eq}} \quad A_{\text{ineq}}]^T, \\ b_p &= [b_{\text{eq}} \quad b_{\text{ineq}}]^T, \\ \tilde{\mathbf{I}} &= [\mathbf{0}_{m,p} \quad \mathbf{I}_p]^T, \\ \mathbf{0}_{m,p} &= \begin{bmatrix} 0 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 0 \end{bmatrix}, \quad \mathbf{0}_{m,p} \in \mathbb{N}^{m \times p}. \end{aligned}$$

O ADMM é um método de primeira ordem que utiliza a abordagem lagrangiana para solucionar o problema expresso em (6). Nesta abordagem um termo de penalidade quadrática associado à restrição do problema é adicionado à função custo, aumentando as propriedades de convergência do algoritmo (Boyd et al., 2010). O método proposto para solucionar o **Problema 1** é resumido no **Algoritmo 1**, onde são usados os seguintes parâmetros de sintonia do algoritmo: ρ é o parâmetro de penalidade das restrições, ϵ é a tolerância dos resíduos e k_{max} é o número máximo de iterações.

4 Simulação

Nesta seção serão apresentados os testes por simulação computacional que foram realizados para a

Algoritmo 1: ADMM proposto para solucionar a QP expressa em (6)

Dados: valores iniciais x^0, z^0, u^0 e parâmetros $\rho > 0, k_{max} > 0, \epsilon$

Saída: x

- 1 $\tilde{H} = H + \rho A_p^T A_p$;
 - 2 armazena \tilde{H}^{-1} ;
 - 3 $k \leftarrow 0$;
 - 4 **repita**
 - 5 $v = -\tilde{\mathbf{I}}z^k + b_p - u^k$;
 - 6 $x^{k+1} = \tilde{H}^{-1}(\rho A_p^T v - q)$;
 - 7 $z^{k+1} = \max\{0, -A_p x^{k+1} + b_p - u^k\}$;
 - 8 $u^{k+1} = u^k + A_p x^{k+1} + \tilde{\mathbf{I}}z^{k+1} - b_p$;
 - 9 $k \leftarrow k + 1$;
 - 10 **até que o critério de parada seja satisfeito ou** $k > k_{max}$;
 - 11 **retorna** x^{k+1}
-

sintonia dos parâmetros do controlador e otimizador antes de embarcar a aplicação experimental no CLP. O sistema SISO (*Single Input - Single Output*) escolhido para a aplicação de controle neste trabalho é constituído por um motor elétrico de corrente contínua com um encoder incremental acoplado, tendo com variável a ser manipulada pelo controlador a tensão de armadura do motor e como variável a ser controlada pelo sistema a velocidade do eixo em rotações por minuto (RPM). A escolha de uma planta SISO é justificada por ser uma opção viável para uma primeira implementação embarcada. Além disso, como o sistema possui dinâmica rápida, tal característica impõe um rígido limite de tempo na computação das ações de controle. A planta foi modelada como a seguinte função de transferência de primeira ordem:

$$G(s) = \frac{96.83}{s + 8.401}. \quad (7)$$

Para validar o algoritmo de otimização proposto para solucionar o **Problema 1**, procedeu-se com simulações em MATLAB[®]. Nestas simulações o IHMPC foi testado para o caso nominal com o modelo de (7), calculando sua respectiva lei de controle com o uso do **Algoritmo 1** e do *solver quadprog*, parametrizado para executar o algoritmo de ponto interior. Ambos foram configurados para uma tolerância residual $\epsilon = 0.1$, sendo esta uma precisão moderada e suficiente para a aplicação (ver Figura 5 para aplicação experimental). Além disso, os demais parâmetros de sintonia do ADMM foram obtidos a partir de uma análise de sensibilidade e definidos como: $\rho = 100$ e $k_{max} = 15$. Já os parâmetros do controlador foram ajustados em: intervalo de amostragem $\Delta t = 0.1$ s, $m = 1$, $R = 1$, $Q = 10$, $S = 1 \times 10^6$, $u_{min} = 0$ V, $u_{max} = 12$ V e $\Delta u_{max} = 10$ V.

A aplicação do controlador IHMPC segue o esquema apresentado na Figura 1, cujo estimador

de estados baseado no filtro de Kalman será usado na implementação com o CLP, quando há um cenário de desassociação entre os modelos da planta e de predição. A simulação foi executada por 300 tempos de amostragem discretos, onde o seguinte cenário foi estabelecido: os estados iniciais do sistema são iguais a zero e, conseqüentemente, a velocidade de rotação do motor é nula. No instante 1 s há uma mudança de referência (*set point*) para a saída igual a $y_{sp} = 60$ RPM. Já nos instantes 10 s e 20 s, as referências são deslocadas para $y_{sp} = 80$ RPM e $y_{sp} = 100$ RPM, respectivamente. Ainda, no instante 25 s um distúrbio é aplicado na entrada do sistema, com amplitude $d_u = 2$ V.

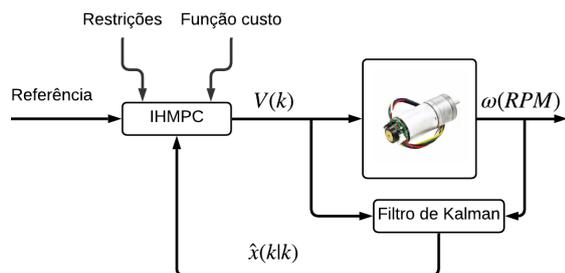


Figura 1: Esquema para a aplicação do IHMPC ao sistema eletromecânico.

A Figura 2 mostra a saída controlada (rotação do motor) e a variável manipulada (tensão na armadura do motor) simuladas para o controlador IHMPC. Os resultados da simulação mostram que o sistema segue a referência com um bom desempenho e o efeito do distúrbio é rapidamente compensado. Além disso, nota-se que a restrição da entrada não é violada e ambos os algoritmos de otimização fornecem soluções semelhantes. Para avaliar a precisão numérica do **Algoritmo 1**, calculou-se o índice ITAE (*Integral Time-weighted Absolute Error*), considerando a *quadprog* como referência, o que resultou em um erro de apenas 0.027 V.

A Figura 3 mostra a função custo do controlador, onde verifica-se que a mesma se comporta como uma função de Lyapunov, como seria esperado por se tratar do caso nominal. Nota-se que o nível de otimalidade é mantido com ambos os algoritmos de otimização, portanto validando o **Algoritmo 1**.

Por fim, a quantidade de iterações dos algoritmos de otimização é ilustrada na Figura 4. Nessa simulação, o ADMM requer mais iterações que a *quadprog* durante os instantes de transitório, enquanto em estado estacionário somente uma iteração é requerida. Ainda assim, o ADMM apresenta vantagem devido ao seu tempo de cômputo consideravelmente menor, já que suas iterações são menos custosas do ponto de vista computacional, como pode ser visto claramente na Tabela 1. Nesta tabela são apresentados o tempo mé-

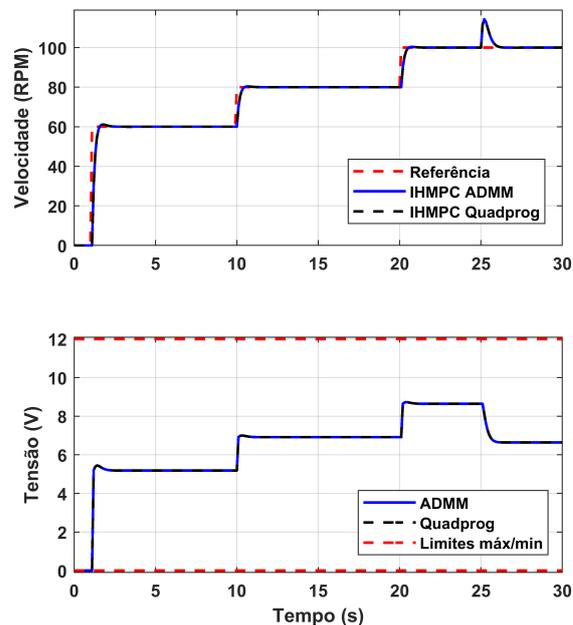


Figura 2: Saída controlada e variável manipulada simuladas para o IHMPC.

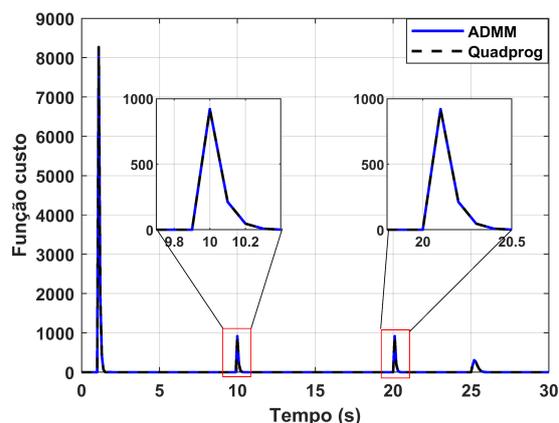


Figura 3: Função custo simulada para o IHMPC.

dio de computação por intervalo de amostragem e o tempo de execução do pior caso (WCET - *Worst Case Execution Times*) durante a simulação. Nota-se que o tempo médio de computação para o ADMM é menor do que a *quadprog* em mais de 100 ordens de magnitude, sendo estes resultados obtidos em um computador com processador Intel Core i3 2.2GHz, 4 GB de memória RAM e sistema operacional *Windows 10*.

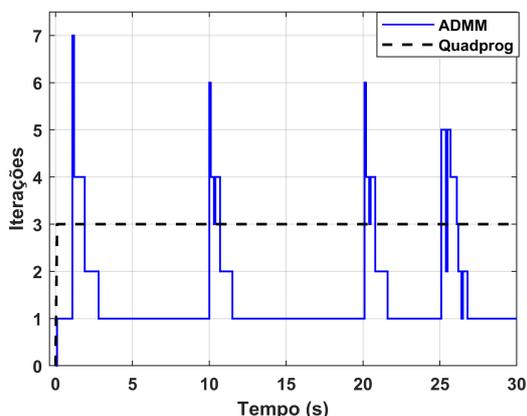


Figura 4: Comparação entre o número de iterações entre ADMM e Quadprog.

Tabela 1: Comparação entre os tempos de computação.

	Quadprog	ADMM
Tempo médio	8.361 ms	0.081 ms
WCET	15.421 ms	0.311 ms

5 Implementação CLP

Após as simulações para o caso nominal, seguiu-se para o último objetivo deste trabalho: implementar o controlador IHMPC no CLP usando o algoritmo ADMM para solucionar o **Problema 1**, tratando-se de uma aplicação ainda não descrita na literatura. Vale ressaltar que, neste caso há um cenário de desassociação no modelo da planta, o que inclui o modelo simplificado para prever o comportamento futuro do sistema, ruídos de medição e outras não linearidades que são típicas em sistemas dinâmicos rápidos eletromecânicos.

O modelo do CLP utilizado nessa implementação foi o CompactLogix L32E da Allen-Bradley, que é recomendado para aplicações de controle de pequeno porte, com memória total de 750 kilobytes e tempo mínimo de ciclo de 0.1 milissegundo. O controlador IHMPC e o ADMM foram implementados utilizando a linguagem de programação texto estruturado no *software* RSLogixTM5000, requerendo aproximadamente 47% da memória total disponível.

Os parâmetros de sintonia do controlador e do ADMM usados nesta implementação são os mesmos definidos na seção (4). Além disso, o filtro de Kalman é usado como estimador de estados e seus parâmetros de sintonia foram definidos considerando as covariâncias do ruído do estado e da medida como identidades. A Figura 5 mostra a saída controlada (variável controlada) e o sinal de controle (variável manipulada) obtidos com o experimento em malha fechada. Nota-se que o controlador IHMPC conduz a saída do sistema eletromecânico para as referências desejadas e compensa o distúrbio rapidamente, havendo um sobressinal razoável durante o transitório devido à sintonia agressiva do controlador.

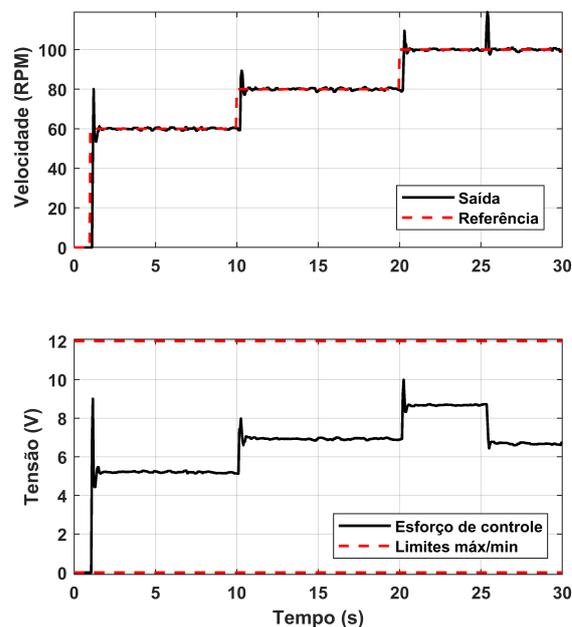


Figura 5: Saída controlada e sinal de controle obtidos experimentalmente com o CLP.

A Figura 6 mostra a função custo obtida experimentalmente, onde mesmo em um cenário de desassociação no modelo da planta, nota-se um comportamento semelhante a uma função de Lyapunov. Com isso, mostra-se a robustez do controlador implementado, que é capaz de acomodar um cenário médio de desassociações no modelo e garantir uma lei de controle estabilizante mesmo diante de ruídos de medição e não-linearidades presentes no sistema eletromecânico, e.g. zona morta para pequenas tensões. Dessa forma, o ajuste dos parâmetros de sintonia somente estão relacionados ao desempenho em malha fechada, tornando uma estratégia de controle adequada para implementações. Além disso, vale ressaltar que a formulação do controlador implementada garante sempre a existência de uma solução viável para o **Problema 1**, reforçando sua aplicabilidade prática.

6 Conclusões

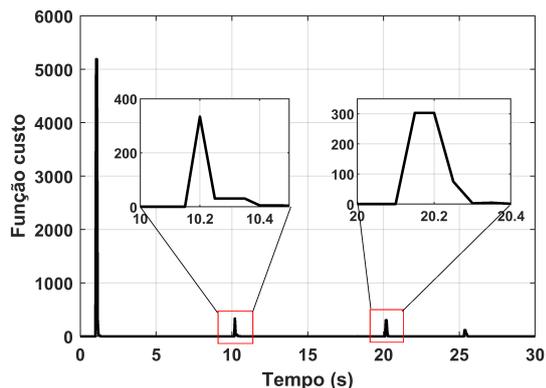


Figura 6: Função custo obtida experimentalmente com o CLP.

Finalmente, a Figura 7 ilustra a quantidade de iterações requeridas pelo ADMM ao longo do experimento e o tempo de cômputo associado. Assim como na simulação, durante os instantes de regime transitório, o ADMM requer uma quantidade maior de iterações, atingindo o limite máximo de 15 iterações definido na sintonia. No entanto, durante os instantes de regime permanente somente uma iteração é requerida. O tempo médio de computação ao longo do experimento foi de 22.486 ms e o tempo de execução do pior caso foi de 65.578 ms, correspondente à execução das 15 iterações durante o transitório. Portanto, percebe-se que o algoritmo ADMM viabilizou a aplicação do controlador IHMPC embarcado no CLP, calculando a lei de controle estabilizante em um tempo razoavelmente menor do que o período de amostragem do sistema (100 ms), mesmo nos instantes de transitório onde o tempo de cômputo atingiu o máximo de 65.578 ms.

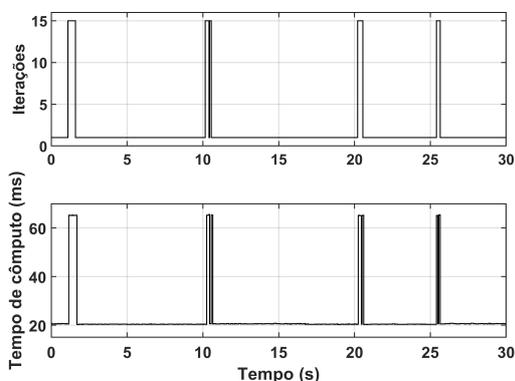


Figura 7: Iterações do ADMM e tempo de cômputo no experimento com o CLP.

Este artigo tratou da implementação de uma estratégia MPC estabilizante embarcada em um CLP industrial, que foi aplicada para controlar um sistema eletromecânico de dinâmica rápida. O algoritmo ADMM foi proposto para calcular a lei de controle estabilizante do IHMPC e apresentou resultados semelhantes ao *solver quadprog* na simulação em MATLAB[®], porém com tempo médio de computação aproximadamente 100 vezes menor.

Já na implementação com o CLP, que demandou 47% da memória total disponível do controlador, o tempo médio de computação da lei de controle com o ADMM foi de 22.486 ms. Mesmo no pior caso de execução, correspondente aos instantes de transitório, o tempo máximo de cômputo foi de 65.578 ms, atendendo com folga o limite de tempo da aplicação. Além disso, mostrou-se experimentalmente que a lei de controle estabilizante e com garantia de factibilidade do IHMPC permitiu o controle das variáveis do sistema de modo adequado, garantindo que a variável controlada não extrapolasse os valores definidos como referência (*set point*).

Uma importante característica do controlador IHMPC é a garantia de estabilidade nominal, em que a sua função custo comporta-se como uma função de Lyapunov ao longo da solução do problema, no cenário em que o modelo de predição descreve com exatidão a dinâmica da planta. Por outro lado, mostrou-se que o controlador também é capaz de acomodar um cenário médio de desassociação no modelo da planta para o sistema eletromecânico, mantendo o comportamento da função custo como uma função de Lyapunov, caracterizando com isso um certo grau de robustez. Portanto, conclui-se que tal estratégia MPC implementada no CLP com o algoritmo ADMM pode ser aplicada com êxito em tarefas de controle industriais, cujos limites de tempo de amostragem não sejam tão restritivos quanto aquele considerado neste trabalho.

Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) e do Programa de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) - PRH-35.1.

Referências

Boyd, S., Parikh, N., Chu, E., Peleato, B. and Eckstein, J. (2010). Distributed optimization and statistical learning via the alternating direction method of multipliers, *Foun-*

- dations and Trends® in Machine Learning* **3**(1): 1–122.
- Brugnolli, M. M., Angelico, B. A. and Lagana, A. A. M. (2019). Predictive adaptive cruise control using a customized ecu, *IEEE Access* **7**: 55305–55317.
- Camacho, E. F. and Bordons, C. (2004). *Model Predictive Control*, 2 edn, Springer Verlag.
- Huyck, B., Brabanter, J. D., Moor, B. D., Impe, J. F. V. and Logist, F. (2014). Online model predictive control of industrial processes using low level control hardware: A pilot-scale distillation column case study, *Control Engineering Practice* **28**: 34 – 48.
- Krupa, P., Limon, D. and Alamo, T. (2018). Implementation of model predictive controllers in programmable logic controllers using iec 61131-3 standard, *2018 European Control Conference (ECC)*, pp. 1–6.
- Kufoalor, D., Richter, S., Imsland, L., Johansen, T., Morari, M. and Eikrem, G. (2014). Embedded model predictive control on a plc using a primal-dual first-order method for a subsea separation process, *2014 22nd Mediterranean Conference on Control and Automation, MED 2014* pp. 368–373.
- Levenson, R. M., Nelson, Z. E. and Adegebe, A. A. (2017). Programmable logic controller for embedded implementation of input-constrained systems, *IFAC-PapersOnLine* **50**(1): 14412 – 14417. 20th IFAC World Congress.
- Maciejowski, J. M. (2002). *Predictive Control: With Constraints*, Prentice Hall.
- Muske, K. R. and Rawlings, J. B. (1993). Model predictive control with linear models, *AIChE Journal* **39**(2): 262–287.
- Odloak, D. (2004). Extended robust model predictive control, *AIChE Journal* **50**(8): 1824–1836.
- Pannocchia, G., Laachi, N. and Rawlings, J. B. (2005). A candidate to replace pid control: Siso-constrained lq control, *AIChE Journal* **51**(4): 1178–1189.
- Santana, B. A., Martins, M. A. F. and Chagas, T. P. (2019). Controle preditivo com garantia de estabilidade nominal e factibilidade para sistemas embarcados, *Anais do 14º Simpósio Brasileiro de Automação Inteligente*, Vol. 1, pp. 1509–1515.
- Silva, B. P., Santana, B. A., Santos, T. L. and Martins, M. A. (2020). An implementable stabilizing model predictive controller applied to a rotary flexible link: An experimental case study, *Control Engineering Practice* **99**: 104396.
- Valencia-Palomo, G. and Rossiter, J. (2009). Auto-tuned predictive control based on minimal plant information, *IFAC Proceedings Volumes* **42**(11): 554 – 559. 7th IFAC Symposium on Advanced Control of Chemical Processes.