

Controle Preditivo LPV Para Geração de Hidrogênio Renovável

Naspolini, Amir¹

Univ. Federal de Santa Catarina.
<https://orcid.org/0000-0002-5329-3463>
amir.naspo@gmail.com

M. Morato, Marcelo²

Univ. Federal de Santa e Univ. Grenoble Alpes.
<https://orcid.org/0000-0002-7137-0522>
marcelomnzm@gmail.com

Dr. Normey-Rico, Julio E.³

Univ. Federal de Santa Catarina.
<https://orcid.org/0000-0002-6510-9803>
julio.normey@ufsc.br

Resumo

Neste artigo, é apresentado um controlador para o gerenciamento de cargas em microrredes renováveis para a geração de hidrogênio. As microrredes consideradas apresentam diferentes eficiências de carga e descarga para os sistemas de armazenamento de energia elétrica. Aborda-se uma visão geral das soluções do Controle Preditivo baseado em Modelo (MPC, do inglês Model Predictive Control) para sistemas não lineares híbridos, utilizando-se da representação misto inteiro dinâmica (MLD, do inglês Mixed Logical Dynamical). Outrossim, desenvolve-se uma alternativa ao uso do método MLD, usando a modelagem do tipo linear a parâmetros variantes (LPV). Para fins de ilustração da eficiência do método proposto, demonstra-se como o problema de otimização híbrido pode ser simplificado quando utilizado um sistema com dinâmica lenta, tal como microrredes. Por fim, apresentam-se resultados em simulação realística da estratégia LPV MPC proposta, comparada com outras abordagens da literatura.

Palavras chaves: Controle Preditivo; LPV; MLD; Otimização; Microrrede.

¹Graduando em Engenharia de Controle e Automação pela UFSC/Brasil.

² Doutorando em Engenharia de Automação e Sistemas pela UFSC/Brasil e em Automação e Produção pela UGA/França.

³ Doutor pela Universidade de Sevilha na Espanha. Atualmente é Professor Titular na UFSC/Brasil.

LPV Predictive Control for Renewable Hydrogen Generation

Abstract

This paper presents a controller for load management in renewable microgrids for hydrogen generation. The considered microgrids present different charging and discharging efficiencies for electrical energy storage systems. An overview of Model Predictive Control (MPC) solutions for hybrid non-linear systems is addressed, using the Mixed Logical Dynamical representation (MLD). Furthermore, an alternative to the use of the MLD method is developed, using Linear Parameter Varying (LPV) modeling. In order to illustrate the efficiency of the proposed method, it is demonstrated how the hybrid optimization problem can be simplified when using a system with slow dynamics, such as microgrids. Finally, results are presented in a realistic simulation of the proposed LPV MPC strategy, compared with other approaches in the literature.

Keywords: Predictive Control; LPV; MLD; Optimization; Microgrid.

1 Introdução

O atual paradigma de geração de energia esta mudando de forma profunda, tendo em vista que as reservas de combustíveis fósseis estão diminuindo a cada ano e, devido ao avanço da tecnologia, as demandas de energia crescem em todos os países (Utama et al., 2014). Além disso, a atual estrutura de desenvolvimento global visa evitar emissões de gases poluentes e diminuir o impacto ambiental, destacando-se as fontes de energia renováveis, ecológicas e sustentáveis (Shafiee & Topal, 2009).

Apesar deste cenário, é importante ressaltar que as fontes de energias renováveis são intermitentes e imprevisíveis. Portanto, torna-se necessário adicionar outros meios de geração às redes de tal forma que as demandas de energia possam ser supridas. A utilização de painéis fotovoltaicos para geração de energia através da energia solar, por exemplo, quando em um período noturno ou nublado, pode ser incapaz de fornecer energia para altas demandas, sendo necessário, neste caso, o uso da rede externa. Visando armazenar energia durante o período diurno para utilizá-la durante a noite, ou em momentos nublados, é plausível, por exemplo, a inclusão de unidades de armazenamento intermediário de energia, como baterias, supercapacitores, estruturas de ar comprimido e outros. Assim, deficiências na geração energética instantânea podem ser compensadas pela carga armazenada.

Existem diversas tecnologias para armazenar energia e cada uma tem suas próprias vantagens e

desventajas, considerando costo económico, autonomía, tiempo de respuesta, vida útil e degradación (Dehghani-Sani et al., 2019). O uso de sistemas de almacenamiento de energía híbridos, integrando diversas tecnologías de almacenamiento, surgen como una solución para mitigar las desventajas de estas tecnologías (Ferrari-Trecate et al., 2004), (Greenwell & Vahidi, 2010).

Ao longo deste artigo, é abordada a utilização da combinação de armazenamento de hidrogênio renovável (também chamado de hidrogênio verde), em conjunto com baterias eletroquímicas e ultracapacitores. O hidrogênio é um composto com grande capacidade de armazenar energia e, apesar de sua baixa densidade de energia volumétrica, o hidrogênio tem a maior relação energia-peso, quando comparado com outros combustíveis. Quando produzido a partir de fontes renováveis (etanol e água) e tecnologias renováveis (energias solar, eólica e hidráulica), o hidrogênio torna-se um combustível renovável e ecologicamente coerente (Reinaldo A. Vargas, 2006). Em relação a este tópico, a utilização de hidrogênio como forma de energia para as microrredes apresenta-se como uma ótima alternativa, uma vez que pode-se combinar a capacidade de armazenamento do hidrogênio, a longo prazo, com a rápida resposta dinâmica dos ultracapacitores.

Atualmente, a operação dos recursos de energia distribuída, em conjunto com cargas controláveis e diferentes tecnologias de armazenamento (baterias, ultracapacitores ou hidrogênio), constituem o núcleo do conceito de microrrede. A microrrede permite uma interligação entre as unidades, incluindo, de forma integrada, a geração distribuída, cargas locais e sistemas de armazenamento de energia. A microrrede pode operar conectada a rede de distribuição principal, através do Ponto de Acoplamento Comum (PCC), ou em modo ilhado, podendo também ser conectada a outras microrredes, dando origem a sistemas ainda mais sofisticados (Bordons et al., 2020).

Sistemas de gestão da microrrede são responsáveis por alcançar o balanço energético de maneira mais eficaz. O principal objetivo é garantir a entrega estável de energia elétrica para seus consumidores, podendo ocorrer pelo gerenciamento do excesso, ou déficit, de energia ou considerando outras funcionalidades, como critérios econômicos ou operacionais. Quando possível, a energia elétrica das fontes renováveis é entregue diretamente às cargas e qualquer excesso de energia é desviado para as unidades de armazenamento ou a rede. Se a energia não estiver disponível, a partir de fontes renováveis, deve ser fornecida pelas unidades de armazenamento ou a rede externa. Todavia, há a dificuldade em prever qual será a geração e a demanda, adicionando uma incerteza significativa e inevitável no processo. A utilização de um algoritmo de controle preditivo é uma ótima solução para este problema, uma vez que este controle trabalha com um horizonte de predição.

O Controle Preditivo Baseado em Modelo (*Model Predictive Control - MPC*) é um método para a regulação de processos com restrições (Camacho & Bordons, 2013). Nas últimas décadas, tem aumentado o interesse de pesquisa acerca do MPC, com extensões desenvolvidas para uma ampla variedade de sistemas. A teoria em MPC estabelece que seja possível conceber algoritmos de controle com viabilidade recursiva de otimização e estabilidade em malha fechada (Mayne et al., 2000). Tal propriedade é explorada para garantir a estabilidade do processo controlado.

Aplicado na microrrede, o MPC resolve o problema de otimização, a fim de determinar o custo mínimo de operação, atendendo à demanda e considerando limites técnicos e físicos dos sistemas de armazenamento (Vergara-Dietrich et al., 2019). Contudo, as microrredes são sistemas híbridos não lineares, ocasionando um alto custo computacional para resolver o problema de otimização. Muitas operações ligadas à gestão de microrredes precisam ser modeladas considerando dinâmicas contínuas e alternando entre diferentes condições de operação. Na engenharia de controle, os sistemas híbridos são sistemas dinâmicos com variáveis contínuas, discretas e de eventos (Bordons et al., 2020).

Existem várias técnicas as quais devem ser suficientes para capturar o comportamento dos vários elementos do sistema e considerar interconexões entre a dinâmica lógica e a dinâmica contínua. Uma das principais técnicas é utilizar o modelo MLD, o qual foi utilizado para realização deste artigo. O modelo MLD pode ser muito útil para transformar problemas de otimização dinâmica híbrida em programas lineares inteiro-misto (Ferrari-Trecate et al., 2004).

De mesmo modo, ferramentas recentes mostram como o problema de otimização do MPC para sistemas não lineares (NMPC) podem ser resolvidos (Andersson et al., 2018), (Gros et al., 2020), através de aproximações não lineares. Os modelos LPV são capazes de descrever comportamentos não lineares e variáveis no tempo, sob estruturas de dinâmica linear (Mohammadpour & Scherer, 2012), que dependem de parâmetros de escalonamento limitados e conhecidos, denominados ρ . A elegância do MPC, com incorporação do LPV, reside no fato de que, as previsões não lineares são substituídas por descrições lineares (Morato et al., 2020), permitindo uma operação rápida da otimização correspondente. A maioria destes algoritmos (propostos pela primeira vez em P. S. Cisneros & Werner (2016), sendo estabelecidos e generalizados desde então) são baseados em um mecanismo iterativo para estimar as futuras trajetórias de programação. Desta forma o algoritmo de controle resultante opera com uma carga numérica reduzida, semelhante à de um programa quadrático sequencial (SQP).

A fim de obter um melhor custo computacional para um resultado similar, este artigo demonstra alternativas ao uso dos modelos comumente usados para sistemas híbridos das microrredes. Para isso, o artigo foi organizado da seguinte maneira:

- É apresentado na seção 2 a microrrede utilizada e o seu modelo, que é aplicado ao MPC;
- Na seção 3 demonstra-se uma revisão da abordagem MPC clássica, utilizada para o controle e gestão de cargas. Também é fornecido a configuração geral do problema NMPC;
- Na seção 4 é discorrido sobre a abordagem MLD, bem como a sua incorporação no modelo da microrrede;
- Na seção 5 é detalhado sobre a abordagem LPV. É também demonstrado a sua incorporação no modelo da microrrede;

- Os resultados da simulação são apresentados na seção 6, comparando as abordagens LPV, MPC, MLD MPC e NMPC;
- As considerações finais são relatadas na seção 7.

2 Microrredes

Considerou-se, como caso de estudo, uma microrrede renovável composta por painéis fotovoltaicos para a energia renovável, enquanto para o armazenamento de energia são utilizadas baterias, eletrolisadores e células combustíveis.

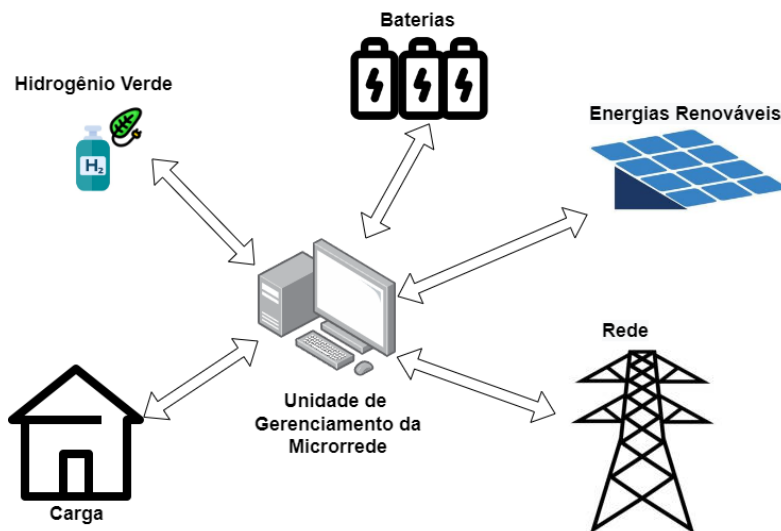


Figura 1: Diagrama da microrrede utilizada.

2.1 Painéis Fotovoltaicos

Células fotovoltaicas são dispositivos eletrônicos que convertem a energia solar em energia elétrica. A parte mais importante de um painel solar são as células fotovoltaicas, geralmente de silício, as quais são responsáveis pela geração de energia renovável na microrrede.

2.2 Baterias

As baterias são dispositivos que transformam energia química em energia elétrica. Dentro desses aparelhos ocorrem reações de oxirredução, as quais consistem na transferência de elétrons,

produzindo assim corrente elétrica. Este dispositivo é utilizado na microrrede como forma de armazenamento de energia, a fim de suprir alguma demanda que não foi capaz de ser atingida apenas pela energia renovável.

2.3 Armazenamento de Hidrogênio

O hidrogênio pode ser considerado uma alternativa promissora para ser usado como sistema de armazenamento de energia (Mendes et al., 2016), em particular quando o hidrogênio é produzido a partir de energias renováveis. Na microrrede, o uso do hidrogênio para o armazenamento de energia elétrica baseia-se na produção de hidrogênio por eletrólise. Para tal, armazena-se o hidrogênio (pressurizado, hidreto metálico, etc.) e depois utiliza-o para gerar energia através de células de combustível.

Os eletrolisadores são dispositivos eletroquímicos capazes de separar o hidrogênio e o oxigênio das moléculas da água, através da eletricidade. Através desta eletrólise se obtêm o hidrógeno em seu estado livre e então é possível armazená-lo.

Semelhante às baterias, a célula de combustível é uma célula eletroquímica capaz de gerar energia elétrica através de reações de oxirredução. Contudo, ela produz eletricidade a partir do fluxo de elétrons de hidrogênio e oxigênio, diferente dos processos a partir da queima de combustíveis fósseis, em que a energia passa por diferentes transformações até chegar na energia elétrica. Portanto, este processo possui alta eficiência, visto que a conversão de energia é direta.

2.4 Modelagem da microrrede

O MPC precisa de um modelo da microrrede para realizar as predições, sendo este modelo simplificado para poder ser integrado ao procedimento de otimização. A dinâmica de cargas e geradores é muito rápida em comparação com o tempo de amostragem e pode ser desconsiderada, ou seja, a principal dinâmica a ser considerada é a das unidades de armazenamento que, juntamente com a equação de equilíbrio de potências no barramento, constituirá o modelo a ser utilizado pelo MPC. Seguindo as orientações de Geidl et al. (2007), os critérios de sinais usados ao longo deste trabalho são que as potências injetadas no barramento devem ser positivas e as potências extraídas do barramento devem ser negativas. Deste modo, no caso de sistemas de armazenamento, que podem injetar ou extrair do barramento, sua potência é considerada positiva na descarga e negativa quando está carregando.

As unidades armazenadoras podem ser modeladas por uma equação de balanço de energia que determina o incremento no nível de energia $x(k)$ da seguinte maneira:

$$x(k+1) = x(k) - \eta T_s P_i(k) \quad (1)$$

Em que T_s é o tempo de amostragem em segundos e P_i é a potência referente à unidade armazenadora. Em geral, a influência da carga/descarga das unidades de armazenamento nos níveis de energia armazenada não é o mesmo, por isso diferentes eficiências são usadas:

$$\eta = \begin{cases} \eta_{ch}, & \text{se } P_i < 0 \text{ (carregando)} \\ \frac{1}{\eta_{dis}}, & \text{Outro Caso (descarregando)} \end{cases} \quad (2)$$

Para a modelagem da microrrede, deve-se também levar em conta fatores como a capacidade máxima da bateria ou o volume máximo de hidrogênio nos tanques (Bordons et al., 2020). Neste artigo foi considerada a união de todos estes fatores em uma única constante K_i para simplificar o modelo.

A bateria conecta-se diretamente no barramento elétrico. Portanto, ela deve compensar o resto das potências. Para uma microrrede que utiliza bateria e armazenamento de hidrogênio, pode-se considerar a seguinte equação de balanço de potências:

$$P_{bat}(k) = P_{load}(k) + P_{elz}(k) - P_{fc}(k) - P_{grid}(k) - P_{gen}(k) \quad (3)$$

Nesta equação, $P_{load}(k)$ é a potência da carga, $P_{elz}(k)$ é a potência do eletrolisador, $P_{fc}(k)$ é a potência da célula combustível, $P_{grid}(k)$ é a potência da rede externa e $P_{gen}(k)$ é a potência gerada pelos painéis fotovoltaicos.

É possível simplificar o problema utilizando-se apenas uma variável para a bateria (P_{bat}) e uma variável para a potência gerada pelo hidrogênio ($P_{H_2} = P_{fc} - P_{elz}$), o qual é positivo quando a célula de combustível (P_{fc}) é usada e negativo quando o eletrolisador (P_{elz}) está funcionando (Pereira et al., 2015). Outrossim, é observado na equação (3) que $P_{load}(k)$ e $P_{gen}(k)$ são perturbações mensuráveis, por isso considera-se uma única variável para perturbação $d(t) = P_{gen}(k) - P_{load}(k)$. Tendo em vista as considerações, reescreve-se a equação do balanço de potência da seguinte maneira:

$$P_{bat}(k) = -d(k) - P_{H_2}(k) - P_{grid}(k) \quad (4)$$

Com o propósito de gerenciar os diferentes comportamentos na carga e descarga das unidades de armazenamento que foram utilizadas, uma variável binária deve ser considerada $\delta(k)$. Logo, a dinâmica de armazenamento pode ser escrita como em Eq. (5).

$$\begin{aligned} SOC(k+1) &= SOC(k) - K_{bat,ch}T_s P_{bat}(k) + \delta_{bat}(k)(K_{bat,ch} - K_{bat,dis})T_s P_{bat}(k) \\ LOH(k+1) &= LOH(k) - K_{fc}T_s P_{H_2}(k) + \delta_{H_2}(k)(K_{fc} - K_{elz})T_s P_{H_2}(k) \end{aligned} \quad (5)$$

Nestas equações, SOC é o estado de carga da bateria, LOH é o nível de hidrogênio nos tanques. Por fim, chega-se a equação final substituindo Eq. (4) em Eq. (5):

$$\begin{aligned} SOC(k+1) &= SOC(k) + K_{bat,ch}T_s(P_{grid}(k) + P_{H2}(k) + d(k)) \\ &\quad - (K_{bat,dis} - K_{bat,ch})T_s(P_{grid}(k)\delta_{grid}(k) + P_{H2}(k)\delta_{H2}(k) + d(k)\delta_{pert}(k)) \quad (6) \\ LOH(k+1) &= LOH(k) - K_{fc}T_sP_{H2}(k) + \delta_{H2}(t)(-K_{elz} + K_{fc})T_sP_{H2}(k) \end{aligned}$$

Ressalta-se que δ_{grid} , δ_{H2} e δ_{pert} são variáveis binárias e caso assumam o valor 1, utilizam a eficiência de descarga (Potências < 0) e caso sejam 0, utilizam a eficiência de carga (Potências > 0). Note também que o nível de hidrogênio (LOH) quando $P_{H2} > 0$ está utilizando a eficiência da célula combustível (está retirando hidrogênio para dar energia ao sistema) e quando $P_{H2} < 0$ utiliza a eficiência do eletrolisador (soma o nível de hidrogênio no tanque).

3 Controle Preditivo Baseado em Modelo (MPC)

MPC é uma família de métodos que diferem entre si no tipo de modelo, na função de custo e no método de resolução. Diversas dinâmicas de plantas são geralmente formuladas como equações de espaço de estado, podendo ser usadas para formular o problema de controle preditivo. As seguintes equações são usadas no caso linear para capturar a dinâmica do sistema:

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) \\ y(k) = Cx(k) + Du(k) \end{cases} \quad (7)$$

Em que $x(k) \in \mathbb{R}^{n_x}$ é o vetor de espaço de estados, $u(k) \in \mathbb{R}^{n_u}$ é o vetor de entradas, $y(k) \in \mathbb{R}^{n_y}$ é o vetor de saídas, $A \in \mathbb{R}^{n_x \times n_x}$, $B \in \mathbb{R}^{n_x \times n_u}$, $C \in \mathbb{R}^{n_y \times n_x}$ e $D \in \mathbb{R}^{n_y \times n_u}$.

3.1 Obtenção da Lei de Controle

Uma vez que um modelo dinâmico esteja disponível, ele pode ser usado na função de custo para o cálculo das previsões. Os vários algoritmos MPC usam diferentes funções de custo para calcular a lei de controle. Normalmente, o objetivo principal é que a saída futura $y(k+j | k)$ ¹ rastreie um certo sinal de referência $r(k+j)$ ao longo do horizonte, ponderando o esforço de controle $u(k+j)$ necessário para fazer o rastreamento. A expressão tradicional utilizada para o MPC é a seguinte:

¹A notação $(k+j | k)$ é usada para representar um valor predito para o instante $k+j$, calculado no instante k .

$$\begin{aligned}
 J_k &= J(x(k), U_k) = \sum_{j=1}^{N_p} (\|\hat{y}(k+j|k) - r(k+j|k)\|_{Q(j)}^2 + \|\Delta u(k+j-1)\|_{R(j)}^2) \\
 &= \sum_{j=1}^{N_p} ([\hat{y}(k+j|k) - r(k+j|k)]^T Q(j) [\hat{y}(k+j|k) - r(k+j|k)] + [\Delta u(k+j-1)]^T R(j) [\Delta u(k+j-1)]) \\
 U_k &= [u(k|k) \ u(k+1|k) \ \dots \ u(k+N_p-1|k)]^T
 \end{aligned} \tag{8}$$

No qual \hat{y} é a saída estimada, Q é a ponderação ao seguimento de referência, R é a ponderação ao incremento de controle e N_p é o horizonte de predição. Por fim, o problema a ser resolvido é:

$$\begin{aligned}
 \mathbf{U}_k^* &= \arg \min_{\mathbf{U}_k} J_k \\
 \text{s.t.} & \begin{cases} x(k+j+1) = Ax(k+j) + Bu(k+j) \\ y(k+j) = Cx(k+j) + Du(k+j) \\ \underline{x} \leq x(k+j) \leq \bar{x} \\ \underline{u} \leq u(k+j) \leq \bar{u} \\ \underline{\Delta u} \leq \Delta u(k+j) \leq \bar{\Delta u} \end{cases}
 \end{aligned} \tag{9}$$

Em que \bar{x} e \underline{x} são as limitações superior e inferior dos estados, \bar{u} e \underline{u} são as limitações superior e inferior da entrada, $\bar{\Delta u}$ e $\underline{\Delta u}$ são os limites superior e inferior do incremento da entrada.

3.2 MPC não linear (NMPC)

Nem sempre a dinâmica do problema será linear, aumentando assim a complexidade e custo computacional ao aplicar um MPC para casos não lineares (NMPC). Deste modo, o problema NMPC a ser resolvido pode ser descrito, similarmente ao caso linear, de acordo com Eq. 10.

$$\begin{aligned}
 \mathbf{U}_k^* &= \arg \min_{\mathbf{U}_k} \sum_{j=1}^{N_p} J(x(k+j|k), y(k+j|k), u(k+j-1|k)) \\
 \text{s.t.} & \begin{cases} x(k+j+1) = f(x(k+j), u(k+j)) \\ \underline{x} \leq x(k+j) \leq \bar{x} \\ \underline{u} \leq u(k+j) \leq \bar{u} \\ \underline{\Delta u} \leq \Delta u(k+j) \leq \bar{\Delta u} \end{cases}
 \end{aligned} \tag{10}$$

Nestas equações de Eq. (10), $J(\cdot)$ é a função de custo do MPC e $f(\cdot)$ é a função não linear de

$x(k+1)$.

4 Modelagem MLD

O desenvolvimento da forma MLD de um sistema híbrido envolve três etapas, descrito em Ferrari-Trecate et al. (2004). A primeira é associar uma afirmação lógica S (que pode ser verdadeira ou falsa) com uma variável binária $\delta \in \{0, 1\}$ que é 1 se, e somente se, a declaração permanecer verdadeira. Assim, a combinação de afirmações lógicas S_1, \dots, S_q , em conjunto dos operadores booleanos AND (\wedge), OR (\vee), NOT (\sim), pode ser representada como desigualdades lineares sobre as variáveis binárias correspondentes $\delta_1, \dots, \delta_q$. As desigualdades decorrentes das declarações compostas podem ser encontradas em Ferrari-Trecate et al. (2004). O segundo passo é representar o produto entre funções lineares e lógicas variáveis introduzindo uma variável auxiliar $z = \delta x$, sendo x uma variável contínua e δ uma variável binária. A terceira e última etapa é formar um modelo dinâmico discreto linear invariante no tempo (LTI) que inclui variáveis binárias e variáveis auxiliares com a seguinte forma geral:

$$\begin{aligned} x(k+1) &= Ax(k) + B_1u(k) + B_2\delta(k) + B_3z(k) \\ y(k) &= Cx(k) + D_1u(k) + D_2\delta(k) + D_3z(k) \end{aligned} \quad (11)$$

Nas equações de Eq. (11), $x = [x_c^T \ x_l^T]^T \in \mathbb{R}^{n_c} \times \{0,1\}^{n_l}$ são as variáveis de estado², $u = [u_c^T \ u_l^T]^T \in \mathbb{R}^{m_c} \times \{0,1\}^{m_l}$ são as entradas, $y = [y_c^T \ y_l^T]^T \in \mathbb{R}^{p_c} \times \{0,1\}^{p_l}$ são as saídas, $\delta \in \{0,1\}^r$ representa a variável binária e $z \in \mathbb{R}^c$ representa as variáveis auxiliares. Todas as restrições sobre os estados, as entradas e as variáveis δ e z são resumidas na desigualdade Eq. (12).

$$E_2\delta(k) + E_3z(k) \leq E_1u(k) + E_4x(k) + E_5 \quad (12)$$

4.1 Aplicação do MLD no Modelo da Microrrede

Observando a equação (6), é preciso garantir que δ_n assumo valor 0 quando $P_n \geq 0$ e valor 1 quando $P_n < 0$. Para isso, são adicionadas as seguintes restrições no problema:

$$\begin{aligned} P_n &\leq P_{n,max} \cdot (1 - \delta_n) + \varepsilon \\ P_n &\geq P_{n,min} \cdot \delta_n + \varepsilon \end{aligned} \quad (13)$$

ε é um valor positivo muito pequeno. Observe que quando $P_n \geq 0$, a única solução viável é

²As notações subscritas c e l são usadas para denotar as variáveis contínuas e binárias, respectivamente.

$\delta_n = 0$, assim como $\delta_n = 1$ é a única solução plausível para $P_n < 0$. Agora basta definir a variável ($z_n = P_n \delta_n$) que irá assumir o valor de P_n quando $P_n < 0$. Têm-se o seguinte vetor de entradas:

$$u = \begin{bmatrix} P_{H2} \\ P_{grid} \\ z_{H2} \\ z_{grid} \end{bmatrix} \quad (14)$$

Assim como em Conte et al. (2020), o problema ainda é não linear caso restrinja z_n a ser igual a $P_n(k)\delta_n(k)$. Portanto, a variável de decisão z deve respeitar as seguintes restrições em forma de desigualdade:

$$\begin{aligned} z_n(k) &\leq P_{n,max} \delta_n \\ z_n(k) &\geq P_{n,min} \delta_n \\ z_n(k) &\leq P_n - P_{n,min}(1 - \delta_n) \\ z_n(k) &\geq P_n - P_{n,max}(1 - \delta_n) \end{aligned} \quad (15)$$

Com as restrições de (15), garante-se que a variável auxiliar z_n obtenha valor nulo quando $\delta_n = 0$ e que z_n obtenha o valor de P_n quando $\delta_n = 1$.

Em relação a perturbação, como ela é mensurável (ou também sabe-se o valor dela por uma estimativa feita por inteligência artificial) e no problema MPC é considerada igual em todas N_p predições, pode-se facilmente decidir qual variável usar no problema de controle. Foi utilizado da seguinte maneira: quando $d > 0$ utiliza-se apenas a variável d , quando $d < 0$ utiliza-se apenas a variável $z_d = d$.

Estabelecido os vetores de entrada, estado e saída, monta-se a equação em espaço de estado:

$$\begin{aligned} \begin{bmatrix} SOC(k+1) \\ LOH(k+1) \end{bmatrix} &= A \begin{bmatrix} SOC(k) \\ LOH(k) \end{bmatrix} + B_u T_s \begin{bmatrix} P_{H2}(k) \\ P_{grid}(k) \\ z_{H2}(k) \\ z_{grid}(k) \end{bmatrix} + B_d T_s \begin{bmatrix} d(k) \\ z_d(k) \end{bmatrix} \\ y(k) &= C \begin{bmatrix} SOC(k) \\ LOH(k) \end{bmatrix} \\ A &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \\ B_u &= \begin{bmatrix} K_{bat,ch} & K_{bat,ch} & K_{bat,dis} - K_{bat,ch} & K_{bat,dis} - K_{bat,ch} \\ -K_{fc} & 0 & -K_{elz} + K_{fc} & 0 \end{bmatrix} \\ B_d &= \begin{bmatrix} K_{bat,ch} & K_{bat,dis} \\ 0 & 0 \end{bmatrix} \\ C &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \end{aligned} \quad (16)$$

Aproveitando da variável auxiliar z_n , é possível atribuir diferentes ponderações para as entradas no objetivo (Conte et al., 2020), assim como feito com os diferentes fatores multiplicativos na equação de espaço de estados. Deste modo é possível, por exemplo, priorizar mais a venda de energia para a rede externa do que a compra. Escreve-se a função objetivo da seguinte maneira:

$$\begin{aligned} J &= \sum_{i=0}^{i=N_p} ((x(i+1) - x_{ref})^T Q_x (x(i+1) - x_{ref}) + u_u(i)^T Q_u u_u(i) + z(i)^T (Q_z - Q_u) z(i)) \\ &+ \sum_{j=0}^{j=N_u} \Delta u(j)^T Q_{\Delta u} \Delta u(j) \end{aligned} \quad (17)$$

Em Eq. (17), $u_u = [P_{H2} P_{grid}]$ é o vetor de entradas sem as variáveis auxiliares, $z = [z_{H2} z_{grid}]$ é o vetor das variáveis auxiliares, $\Delta u = [\Delta P_{H2} \Delta P_{grid}]$ é o vetor do incremento das entradas, $Q_z = \text{diag}(Q_{P_{H2}<0} Q_{P_{grid}<0})$ é a ponderação das variáveis auxiliares, $Q_u = \text{diag}(Q_{P_{H2}\geq 0} Q_{P_{grid}\geq 0})$ é a ponderação das entradas, $Q_{\Delta u}$ é a ponderação do incremento da entrada e Q_x é a ponderação do seguimento de referência.

5 Modelagem LPV

Muitos sistemas não lineares podem ser descritos sob um formalismo LPV, desde que a Inclusão Diferencial Linear (*Linear Differential Inclusion* - LDI) seja respeitada, veja Morato et al. (2020) e suas referências. Então, a propriedade LDI permite gerar formulações LPV de espaço de estado para o sistema não linear genérico de (10). Esta propriedade é a seguinte: para cada x , y , u e instante k , existe uma matriz $G(x, u, k) \in \mathcal{G}$ de tal forma que a seguinte relação seja válida para todo $x \in X$ e $u \in U$:

$$\begin{bmatrix} f(x(k), u(k)) \\ f_y(x(k), u(k)) \end{bmatrix} = G(x, u, k) \begin{bmatrix} x(k) \\ u(k) \end{bmatrix} \quad (18)$$

Sendo $\mathcal{G} \subseteq \mathbb{R}^{(n_x+n_y) \times (n_x+n_u)}$. Quando confirmada esta propriedade (existe a matriz $G(x, u, k)$), pode-se reescrever Eq. (18) da seguinte forma:

$$\begin{cases} x(k+1) = A(\rho(k))x(k) + B(\rho(k))u(k) \\ y(k) = C(\rho(k))x(k) + D(\rho(k))x(k) \\ \rho(k) \in \mathcal{P} \end{cases} \quad (19)$$

Neste modelo LPV, os parâmetros de escalonamento ρ e seu respectivo conjunto \mathcal{P} derivam de $\mathcal{G}(x, u, k)$. Os parâmetros de escalonamento utilizados neste artigo são variáveis exógenas, tendo seus valores atribuídos externamente. Ainda assim, a formulação MPC requer o conhecimento dos valores futuros dos parâmetros de agendamento $\rho(k+j)$, ao longo do horizonte de previsão. Como solução, foi considerado o valor de ρ constante para todo horizonte, isto é, $\rho(k) = \rho(k+1)$ (Morato et al., 2020).

5.1 Aplicação do LPV no Modelo da Microrrede

Na microrrede a dinâmica de carga e descarga das unidades armazenadoras é lenta, podendo aderir às seguintes hipóteses:

- Quando a unidade armazenadora está descarregando/carregando, ela tende a descarregar/carregar por um período de tempo;
- Este período de tempo é maior que o tempo das N_p amostras.

Sendo assim, é possível atribuir o valor da eficiência de carga/descarga à uma variável exógena ρ baseado em valores de variáveis passadas. Para este artigo, atribuiu-se o valor de ρ de acordo com Eq. 20.

$$\rho = \begin{cases} \rho_1 = K_{bat,ch} \text{ e } \rho_4 = K_{bat,fc}, \text{ se } P_{H2}(k-1) \geq 0 \\ \rho_1 = K_{bat,dis} \text{ } \rho_4 = K_{bat,elz}, \text{ Caso Contrário} \\ \\ \rho_2 = K_{bat,ch}, \text{ se } P_{grid}(k-1) \geq 0 \\ \rho_2 = K_{bat,dis}, \text{ Caso Contrário} \\ \\ \rho_3 = K_{bat,ch}, \text{ se } d(k) \geq 0 \\ \rho_3 = K_{bat,dis}, \text{ Caso Contrário} \end{cases} \quad (20)$$

Sendo definido, em Eq. (20), $\rho = [\rho_1 \ \rho_2 \ \rho_3 \ \rho_4]$ o vetor dos parâmetros de agendamento. Estabelecido os vetores de agendamento, monta-se as equações em espaço de estados:

$$\begin{aligned} \begin{bmatrix} SOC(k+1) \\ LOH(k+1) \end{bmatrix} &= \begin{bmatrix} SOC(k) \\ LOH(k) \end{bmatrix} + \begin{bmatrix} \rho_1 & \rho_2 \\ -\rho_4 & 0 \end{bmatrix} T_s \begin{bmatrix} P_{H2}(k) \\ P_{grid}(k) \end{bmatrix} + \begin{bmatrix} \rho_3 \\ 0 \end{bmatrix} T_s d(k) \\ y(k) &= \begin{bmatrix} SOC(k) \\ LOH(k) \end{bmatrix} \end{aligned} \quad (21)$$

Assim como feito para as variáveis auxiliares da modelagem MLD, também é possível utilizar diferentes ponderações para diferentes cenários de carga ou descarga para a modelagem LPV. Escreve-se a função objetivo da seguinte maneira:

$$J = \sum_{i=0}^{i=Np} ((x(i+1) - x_{ref})^T Q_x (x(i+1) - x_{ref}) + u(i)^T R u(i)) + \sum_{j=0}^{j=Nu} \Delta u(j)^T Q_{\Delta u} \Delta u(j) \quad (22)$$

A ponderação R é estabelecida com a mesma lógica de ρ :

$$R = \begin{bmatrix} R_1 & 0 \\ 0 & R_2 \end{bmatrix} \begin{cases} R_1 = Q_{P_{H2} \geq 0}, \text{ se } P_{H2}(k-1) \geq 0 \\ R_1 = Q_{P_{H2} < 0}, \text{ Caso Contrário} \\ \\ R_2 = Q_{P_{grid} \geq 0}, \text{ se } P_{grid}(k-1) \geq 0 \\ R_2 = Q_{P_{grid} < 0}, \text{ Caso Contrário} \end{cases} \quad (23)$$

6 Resultados

Nesta seção, são apresentados os resultados das simulações e a incorporação das ferramentas LPV e MLD no sistema. Para a obtenção dos resultados que serão apresentados a seguir, foram utilizados: Matlab, Yalmip (Löfberg, 2004), Gurobi (Gurobi Optimization, 2022) e o simulador de microrrede Sim μ grid (Bordons et al., 2020), que usa um modelo realista e não linear para a simulação. Para a otimização do problema, adotou-se um horizonte de predição de $N_p = 10$ amostras e um horizonte de controle de $N_c = 2$ amostras, com as ponderações $Q_x = \text{diag}(1 \cdot 10^{-8} \ 1 \cdot 10^{-8})$, $Q_{P_{H_2} \geq 0} = 5 \cdot 10^{-3}$, $Q_{P_{H_2} < 0} = 8 \cdot 10^{-3}$, $Q_{P_{grid} \geq 0} = 6 \cdot 10^{-3}$, $Q_{P_{grid} < 0} = 7 \cdot 10^{-3}$ e $Q_{\Delta u} = \text{diag}(4 \ 1 \cdot 10^{-3})$. As restrições utilizadas foram $\bar{x} = [75; 90]$, $\bar{y} = [40; 10]$, $\bar{u} = [0.9; 6]$, $\underline{u} = [-0.9; -2.5]$, $\overline{\Delta u} = [0.02; 1]$ e $\underline{\Delta u} = [-0.02; -1]$.

A simulação aconteceu em um período de aproximadamente 24 horas. Na simulação foi considerado um dia ensolarado e pode-se observar na Figura 2 a grande geração de energia das células fotovoltaicas no período da manhã. Na mesma figura, é possível observar a demanda de energia ao longo da simulação.

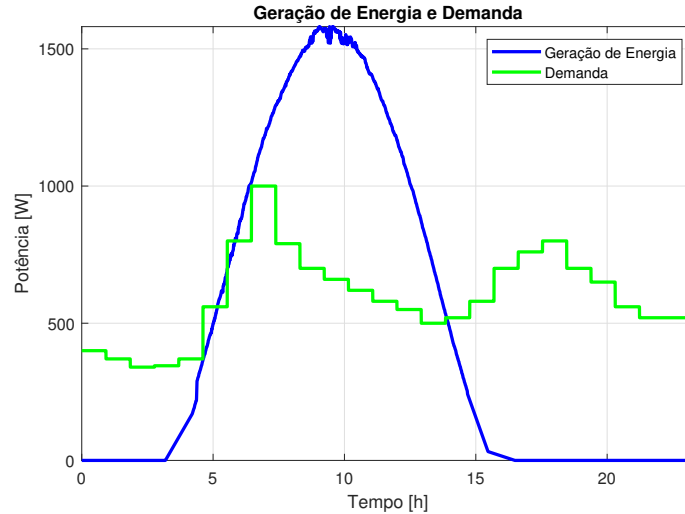


Figura 2: Geração de Energia e Demanda.

Para as simulações foram utilizados a amostragem de $T_s = 15s$ e os valores de $K_{bat,ch} = 2.34 \cdot 10^{-2}$, $K_{bat,dis} = \frac{2.34 \cdot 10^{-2}}{2}$, $K_{elz} = 4.824 \cdot 10^{-2}$ e $K_{fc} = 12.174 \cdot 10^{-2}$, retirados de Bordons et al. (2020). As condições iniciais são: $x(0) = [62 \ 55]^T$ e $u(0) = [0 \ 0]^T$. Para ilustrar a eficácia da abordagem de incorporação LPV para NMPC, três estratégias distintas são empregadas para gerenciar a microrrede:

- A solução do NMPC da seção 3.2;

- O MPC LPV da seção 5, que resolve um QP para o problema de otimização;
- O MPC MLD da seção 4, que resolve um MIP para o problema de otimização.

A seguir, as Figuras 3, 4, 5 e 6 mostram as trajetórias de P_{H_2} , P_{grid} , P_{bat} e as saídas SOC e NHM , respectivamente, obtidas com cada método de controle:

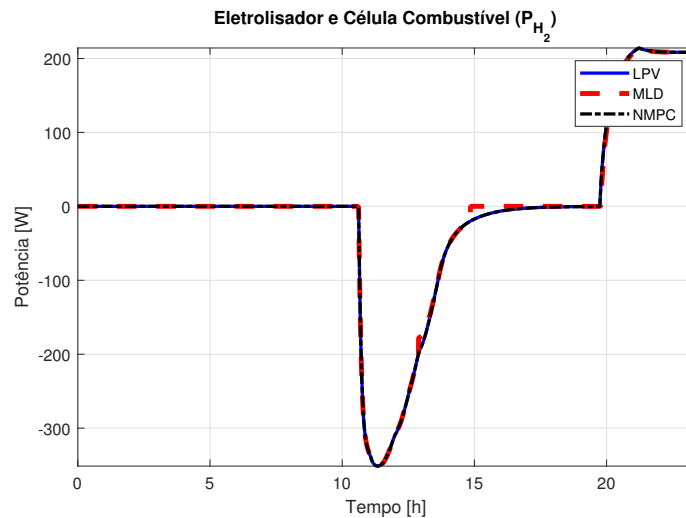


Figura 3: Potências do Eletrolisador e da Célula Combustível.

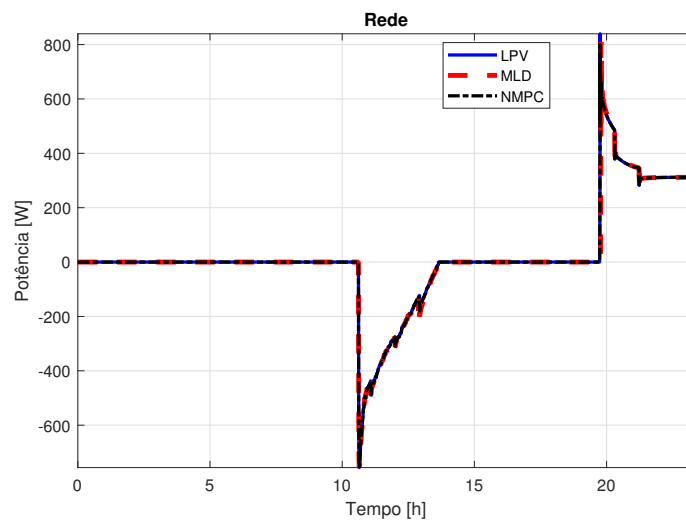


Figura 4: Potência da Rede Externa.

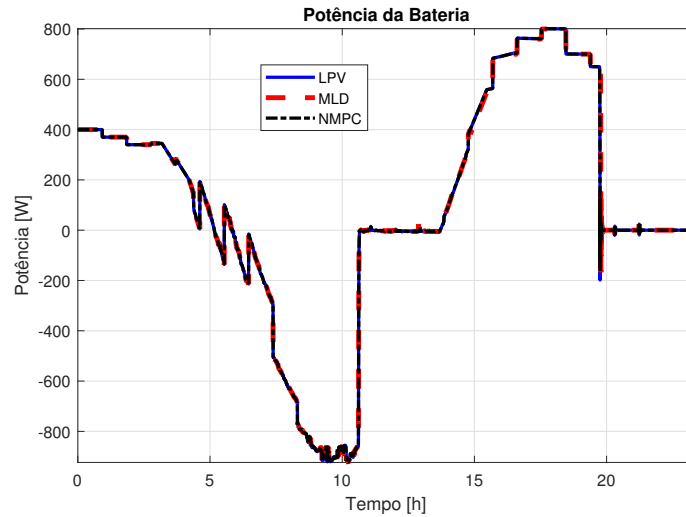


Figura 5: Potência da Bateria.

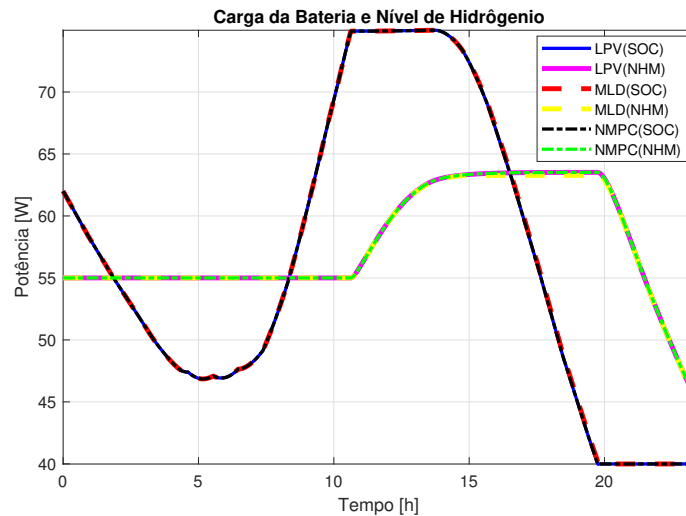


Figura 6: Nível de Carga da Bateria e Nível de Hidrógeno.

Ressalta-se que ambos os métodos LPV e MLD produzem resultados muito semelhantes em relação ao NMPC. Contudo, observando a Tabela 1, nota-se que há diferenças para o desempenho de cada método. Destaca-se as principais descobertas:

- Em relação a otimização em tempo real, os métodos LPV e MLD mostram-se como soluções mais rápidas em relação ao NMPC. A carga computacional média com essas abordagens (tc)

é menor do que o exigido para quando não são utilizados os métodos;

- Apesar da solução por abordagens MLD ser amplamente aplicada em trabalhos recentes, por exemplo em Mendes et al. (2016), defende-se o uso da abordagem do LPV. O método LPV se demonstrou muito mais rápido que o MLD (mais de sete vezes menor), uma vez que um QP é necessário para resolver a otimização ao invés de um MIP.

Tabela 1: Comparação do Desempenho dos Métodos de Controle Utilizados.

Metódo	$\text{rms}\{J(\cdot)\}$	t_c
NMPC	0.0061	0.3175 s
MLD MPC	0.0061	0.1298 s
LPV MPC	0.0061	0.0176 s

7 Conclusões

Este artigo apresentou uma solução MPC LPV para o gerenciamento de energia em microrredes com energias renováveis, utilizando tanques de hidrogênio e baterias como armazenamento híbrido. Realizando um controle para o gerenciamento de microrredes, com diferentes eficiências para a carga e descarga das unidades de armazenamento, demonstrou-se a eficácia da abordagem LPV. Para tal demonstração, o método é comparado em termos de carga numérica a uma técnica MLD comumente usada e a uma solução NMPC. Defende-se a utilização da abordagem LPV, uma vez que demonstramos como a ferramenta é capaz de alcançar resultados comparáveis para algoritmos NMPC. Ademais, o método LPV demonstrou-se mais rápido que o método MLD, usando apenas um programa quadrático por amostra ao invés de um programa inteiro-misto.

Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (304032/2019-0 e 403949/2021-1) e do Departamento de Automação e Sistemas (DAS) da Universidade Federal de Santa Catarina (UFSC).

Referências

- Andersson, J. A. E., Gillis, J., Horn, G., Rawlings, J. B., & Diehl, M. (2018, jul). CasADi: a software framework for nonlinear optimization and optimal control. *Mathematical Programming Computation*, *11*(1), 1–36. doi: 10.1007/s12532-018-0139-4
- Bordons, C., Garcia-Torres, F., & Ridao, M. A. (2020). *Model predictive control of microgrids*. Springer International Publishing. doi: 10.1007/978-3-030-24570-2
- Camacho, E. F., & Bordons, C. (2013). Model predictive control. *Springer Science Business Media*.
- Conte, E., Mendes, P. R. C., & Normey-Rico, J. E. (2020, jul). Economic management based on hybrid MPC for microgrids: A brazilian energy market solution. *Energies*, *13*(13), 3508. doi: 10.3390/en13133508
- Dehghani-Sani, A., Tharumalingam, E., Dusseault, M., & Fraser, R. (2019, apr). Study of energy storage systems and environmental challenges of batteries. *Renewable and Sustainable Energy Reviews*, *104*, 192–208. doi: 10.1016/j.rser.2019.01.023
- Ferrari-Trecate, G., Gallestey, E., Letizia, P., Spedicato, M., Morari, M., & Antoine, M. (2004, sep). Modeling and control of co-generation power plants: A hybrid system approach. *IEEE Transactions on Control Systems Technology*, *12*(5), 694–705. doi: 10.1109/tcst.2004.826958
- Geidl, M., Koeppl, G., Favre-Perrod, P., Klockl, B., Andersson, G., & Frohlich, K. (2007, jan). Energy hubs for the future. *IEEE Power and Energy Magazine*, *5*(1), 24–30. doi: 10.1109/mpae.2007.264850
- Greenwell, W., & Vahidi, A. (2010, jun). Predictive control of voltage and current in a fuel cell-ultracapacitor hybrid. *IEEE Transactions on Industrial Electronics*, *57*(6), 1954–1963. doi: 10.1109/tie.2009.2031663
- Gros, S., Zanon, M., Quirynen, R., Bemporad, A., & Diehl, M. (2020). “from linear to nonlinear mpc: Bridging the gap via the real-time iteration”. *International Journal of Control*, vol. 93, no. 1, pp. 62–80.
- Gurobi Optimization, L. (2022). *Gurobi optimizer reference manual*. Retrieved from <https://www.gurobi.com>
- Löfberg, J. (2004). Yalmip : A toolbox for modeling and optimization in matlab. In *In proceedings of the cacsds conference*. Taipei, Taiwan.
- Mayne, D., Rawlings, J., Rao, C., & Scokaert, P. (2000, jun). Constrained model predictive control: Stability and optimality. *Automatica*, *36*(6), 789–814. doi: 10.1016/s0005-1098(99)00214-9

Revista REDIUNP

Revista Electrónica de divulgación de Metodologías Emergentes en el Desarrollo de STEM
Aprobada en Consejo Directivo de la Facultad RCDFI-419-2018
ISSN:2683-8648
Vol. 4 N° 2(2022)



Naspolini, Amir; M. Morato, Marcelo; Dr. Normey-Rico, Julio E.
Control Predictivo LPV Para Generación de Hidrógeno Renovable.

- Mendes, P. R., Isorna, L. V., Bordons, C., & Normey-Rico, J. E. (2016, sep). Energy management of an experimental microgrid coupled to a v2g system. *Journal of Power Sources*, 327, 702–713. doi: 10.1016/j.jpowsour.2016.07.076
- Mohammadpour, J., & Scherer, C. W. (2012). Control of linear parameter varying systems with applications. *Springer Science BusinessMedia*.
- Morato, M. M., Normey-Rico, J. E., & Sename, O. (2020). Model predictive control design for linear parameter varying systems: A survey. *Annual Reviews in Control*, 49, 64–80. doi: 10.1016/j.arcontrol.2020.04.016
- Pereira, M., Limon, D., de la Pena, D. M., Valverde, L., & Alamo, T. (2015, aug). Periodic economic control of a nonisolated microgrid. *IEEE Transactions on Industrial Electronics*, 62(8), 5247–5255. doi: 10.1109/tie.2015.2404815
- P. S. Cisneros, S. V., & Werner, H. (2016). “efficient nonlinear model predictive control via quasi-lpv representation”. *IEEE 55th Conference on Decision and Control (CDC)*, pp. 3216–3221..
- Reinaldo A. Vargas, E. G. F. E. S. M. S., Rubens Chiba. (2006). Hidrogênio: O vetor energético do futuro? In *Congresso de administracao da faculdade alfcastelo*.
- Shafiee, S., & Topal, E. (2009, jan). When will fossil fuel reserves be diminished? *Energy Policy*, 37(1), 181–189. doi: 10.1016/j.enpol.2008.08.016
- Utama, N. A., Fathoni, A. M., Kristianto, M. A., & McLellan, B. C. (2014). The end of fossil fuel era: Supply-demand measures through energy efficiency. *Procedia Environmental Sciences*, 20, 40–45. doi: 10.1016/j.proenv.2014.03.007
- Vergara-Dietrich, J. D., Morato, M. M., Mendes, P. R., Cani, A. A., Normey-Rico, J. E., & Bordons, C. (2019, feb). Advanced chance-constrained predictive control for the efficient energy management of renewable power systems. *Journal of Process Control*, 74, 120–132. doi: 10.1016/j.jprocont.2017.11.003