



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Química

ANDRÉ LUIZ PAES DE LIMA

METODOLOGIA DE SINTONIA PARA CONTROLADORES PREDITIVOS
UTILIZANDO FUNÇÕES DE SENSIBILIDADE

TUNING STRATEGY FOR MODEL PREDICTIVE CONTROL THROUGH THE USE OF
SENSITIVITY FUNCTIONS

CAMPINAS - SP

2020

ANDRÉ LUIZ PAES DE LIMA

METODOLOGIA DE SINTONIA PARA SISTEMAS COM CONTROLADORES DE
MODELO PREDITIVO UTILIZANDO FUNÇÕES DE SENSIBILIDADE

Dissertação apresentada à Faculdade de Engenharia Química
da Universidade Estadual de Campinas como parte dos requisitos exigidos
para a Obtenção do título de Mestre em Engenharia Química.

Supervisor/Orientador: Prof^a Dr^a Luz Adriana Alvarez Toro

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO ANDRÉ LUIZ PAES DE LIMA, E ORIENTADA
PELA PROF^a. DR^a. LUZ ADRIANA ALVAREZ TORO

CAMPINAS – SP

2020

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

L628m Lima, André Luiz Paes de, 1994-
Metodologia de sintonia para controladores preditivos utilizando funções de sensibilidade / André Luiz Paes de Lima. – Campinas, SP : [s.n.], 2020.

Orientador: Luz Adriana Alvarez Toro.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Controle preditivo. 2. Automação industrial - Simulação. 3. Análise de sensibilidade. 4. Engenharia - Controle automático. I. Alvarez Toro, Luz Adriana, 1982-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Tuning strategy for model predictive control through the use of sensitivity functions

Palavras-chave em inglês:

Predictive control
Industrial automation - Simulation
Sensitivity analysis
Engineering - Automatic control

Área de concentração: Engenharia Química

Titulação: Mestre em Engenharia Química **Banca examinadora:**

Luz Adriana Alvarez Toro [Orientador]

Matheus Souza

Brunno Ferreira dos Santos

Data de defesa: 29-07-2020

Programa de Pós-Graduação: Engenharia Química

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0001-8503-7758>

- Currículo Lattes do autor: <http://lattes.cnpq.br/2455333845154080>

Folha de Aprovação da Dissertação de Mestrado defendida por André Luiz Paes de Lima, em 29 de julho de 2020 pela banca examinadora constituída pelos doutores.

Profa. Dra. Luz Adriana Alvarez Toro - Presidente e Orientadora

FEQ / UNICAMP

Videoconferência

Prof. Dr. Matheus Souza

FEEC / UNICAMP

Videoconferência

Dr. Brunno Ferreira dos Santos

Pontifícia Universidade Católica do Rio de Janeiro

Videoconferência,

Ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

DEDICATÓRIA

*“Dedico essa dissertação aos meus pais, Maria Helena e Renato, à minha irmã,
Aline Cristina e à minha companheira, Deborah”*

AGRADECIMENTOS

Gostaria de aproveitar essa seção do projeto para agradecer às pessoas e grupos que fora de grande importância durante o período de realização desse trabalho. Por isso, ofereço meus agradecimentos:

À Profª Drª Luz Adriana Alvarez Toro, por toda a orientação e aprendizado oferecidos durante os últimos anos, essenciais para a realização dessa etapa vultosa da minha vida. Todo o apoio e atenção que você demonstrou nesses anos foram extremamente importantes para minha pessoa e espero que eu possa seguir o seu exemplo nos próximos anos da minha vida profissional. Te desejo muita saúde e felicidade junto com o seu filho, Gabriel.

Agradeço os constituintes da banca examinadora, por todo o ensinamento providenciado durante a análise e avaliação desse trabalho, que serão carregados por muitos anos além da finalização dessa tese.

Aos membros e professores da Faculdade de Engenharia Química da UNICAMP, em especial aos professores doutores Luís Fernando Mercier Franco, José Vicente Hallak D'Angelo, Roger Josef Zemp e Ângela Maria Moraes, por todas as oportunidades de aprendizado e crescimento pessoal oferecidas durante e após a finalização do meu mestrado.

À minha família, em específico aos meus pais, Maria Helena Dias Paes de Lima e Renato de Lima Júnior, e à minha irmã, Aline Cristina Paes de Lima, por todo apoio moral e emocional apresentado durante os últimos anos em todas as decisões da minha vida.

À minha parceira de vida, Deborah Salles Tortola, por todo o contínuo amor e suporte providenciado durante as etapas mais desafiadoras do meu trajeto pessoal e profissional.

Aos meus colegas e amigos de laboratório, Raíssa Costa de Oiveira, Romero Florentino de Carvalho e Fernando Henrique Marques, por toda amizade, auxílio e carinho que vocês me apresentaram durante essa etapa inédita.

A todos os amigos que me abençoaram com sorrisos e inspiração não apenas durante os últimos anos, mas por grande parte da minha vida. Em especial, ao meu grande amigo e companheiro, Rafael Correa Diniz, que tem mostrado por muito tempo o valor que uma amizade sincera apresenta.

A todos os meus colegas do DESQ que me apoiaram nesses anos de trabalho e realizações, em especial para Giovana Campos Rocha e Tiago Ferreira Souza pelo auxílio apresentado em momentos importantes.

À toda comunidade da UNICAMP, que tem me acolhido e acompanhado desde 2012. Em especial, à equipe Tae Kwon Do – UNICAMP, por ter me ensinado o significado de perseverança, integridade, cortesia, espírito indomável e autocontrole.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

Nesse trabalho, uma metodologia prática de sintonia para controladores preditivos (MPC) é introduzida, sendo que nessa os parâmetros de sintonia são obtidos com o uso de funções de sensibilidade. A metodologia atua na função custo do controlador preditivo, sintonizando os parâmetros de priorização relacionados às ações de minimização do erro e de redução do esforço de controle. Embora a metodologia apresente aplicação universal, o controlador utilizado nesse projeto foi do tipo de predição generalizada (GPC), que possui uma presença considerável na indústria em relação a outros. Uma vez que as funções de sensibilidade representam relações chaves na malha de controle, propõem-se sua utilização na forma de índices, capazes de mensurar individualmente a capacidade da metodologia em minimizar o erro, reduzir o esforço ou rejeitar os distúrbios, para a determinação dos parâmetros do sistema. O problema de otimização da sintonia promove a comparação dos índices com valores de referência adequadas para cada ação promovida pelo controlador. Cada ação é acompanhada por uma variável de penalização definida pelo usuário, sendo que a metodologia é balanceada de forma a permitir uma interação intuitiva. O método é aplicado em sistemas de uma entrada e uma saída (SISO) e de múltiplas entradas e múltiplas saídas (MIMO), sendo que, nesse segundo caso, o conceito de decomposição em valores singulares (SVD) é aplicado para determinar as energias do sistema e promover a sintonia de acordo com o cenário. O método é testado em simulações de problemas típicos da engenharia química, como no controle de um tanque e de um reator CSTR encamisado. Foi observado que a metodologia atuou da maneira esperada, promovendo a minimização do erro, esforço e impacto do distúrbio no sistema de maneira facilmente determinada pelo usuário. Os resultados comprovaram o potencial da metodologia em obter valores adequados para os parâmetros de sintonia ao mesmo tempo que é capaz de ser aplicado de maneira intuitiva e customizada, garantindo a eficiência, praticidade e versatilidade comumente desejada para este tipo de ferramenta matemática.

Palavras-chave: Controlador preditivo; Análise de sensibilidade; Decomposição em valores singulares; Sintonia; Funções de custo.

ABSTRACT

In this work, a practical tuning methodology for model predictive controllers (MPC) is introduced, in which the control parameters are determined using sensitivity functions. The methodology is focused on the predictive controller's cost function, tuning its weighting coefficients related to both error minimization and effort reduction actions. Although the methodology can be applied universally, the controller applied in this project was the generalized predictive controller (GPC), which possesses a considerable presence in the industry, relative to other types. The sensitivity functions represent key relations of the control system. Therefore, we propose their application in the form of indexes capable of individually measuring the methodology capability in minimizing the error, reducing the control effort and rejecting the disturbance, in describing the optimal control parameters. The tuning problem promotes the indexes comparison with reference values adequate for each action promoted by the controller. Each action comes with a numerical weight defined by the user, and the system is balanced, focusing on making the controller's usage intuitive. The method is applied both in single-input and single-output (SISO) as well as multiple-inputs multiple-outputs (MIMO) systems, being that, in this second occasion, the concept of singular value decomposition (SVD) is applied to acquire the system energies and promote the tuning according to the scenario. The method is tested through simulations in typical chemical engineering problems, such as the water level in a tank and a jacketed CSTR reactor control. It was observed that the methodology acted as expected, promoting the minimization of error, effort, and disturbance's impact in the system in a manner that can be easily determined by the user. The results verified the methodology's potential in obtaining desired values for the tuning parameters at the same time it was able to be applied in an intuitive and customizable manner, ensuring the efficiency, practicality and versatility commonly desired for this type of mathematical tool.

Keywords: Predictive Control; Sensitivity analysis; Singular Value Decomposition; Tuning; Cost functions.

LISTA DE ILUSTRAÇÕES

Figura 3.1 – Exemplificação da predição realizada pelo controlador MPC (adaptado de Grüne; Pannek (2017)).	22
Figura 3.2 - Esquematização da atuação do controle MPC (adaptado de Camacho; Bordons (2007)).	23
Figura 3.3– Diagrama de blocos de um sistema em malha fechada.	31
Figura 6.1 – Valor do índice I_{St} em relação aos parâmetros de penalização R e Q.	46
Figura 6.2 – Valor do índice I_{dmt} em relação aos parâmetros de penalização R e Q.	46
Figura 6.3 – Valor do índice I_{s0} em relação aos parâmetros R e Q ($\omega=0,1$ rad/s).	47
Figura 6.4 – Valor do índice I_{s0} em relação aos parâmetros R e Q ($\omega=0,37$ rad/s).	47
Figura 6.5 – Diagrama de Bode para o índice I_{st}.	48
Figura 6.6 – Diagrama de Bode para o índice I_{dMt}.	49
Figura 6.7 – Diagrama de Bode para o índice I_{s0}^A (relacionado ao erro).	50
Figura 6.8 – Diagrama de Bode para o índice I_{s0}^B (relacionado ao esforço).	50
Figura 6.9 – Comportamento da variável controlada diante de distúrbios com frequências diferentes.	51
Figura 6.10 – Comportamento do sistema para $R=Q=1$.	52
Figura 6.11 – Resposta do sistema sintonizado para $w_{St}=I$.	53
Figura 6.12 –Resposta do sistema sintonizado para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 3]$.	55
Figura 6.13 – Variação do valor e da variação da entrada do sistema em função do tempo para os cenários $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 0]$ e $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 3]$.	56
Figura 6.14 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 0]$.	58
Figura 6.15 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [0; 0; 1]$.	58
Figura 6.16 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [0,25; 0; 1]$.	61
Figura 6.17 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [0,5; 0; 1]$.	61
Figura 6.18 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 1]$.	62
Figura 6.19 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 0,5]$.	62
Figura 6.20 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{s0}, w_{dMt}] = [1; 0; 0,25]$.	63
Figura 6.21 – Resposta da sintonia do sistema para $\omega = 0,01$.	64
Figura 6.22 – Resposta da sintonia do sistema para $\omega = 0,1$.	65
Figura 6.23 – Resposta da sintonia do sistema para $\omega = 0,25$.	65
Figura 6.24 – Resposta da sintonia do sistema para $\omega = 0,37$.	66

LISTA DE TABELAS

Tabela 3.1 – Parâmetros de sintonia do controlador GPC.....	29
Tabela 3.2 – Funções de sensibilidade típicas de um sistema em malha fechada.....	31
Tabela 4.1– Funções de sensibilidade utilizadas na metodologia.....	35
Tabela 5.1 – Cenário de simulação do sistema SISO.	42
Tabela 5.2 – Cenário de operação do reator CSTR encamisado.	43
Tabela 5.3 – Cenário de simulação do sistema MIMO.	44
Tabela 6.1 – Resultados das simulações com distúrbios de frequências diferentes.....	51
Tabela 6.2 – Resultados comparativos da simulação antes e após minimização do erro.....	53
Tabela 6.3 – Resultados comparativos da simulação com diferentes valores de w_{dMt}.	54
Tabela 6.4 – análise relativa da simulação com diferentes valores de w_{dMt}.	54
Tabela 6.5 – Resultados comparativos da simulação com diferentes valores e estratégias de w_{s0}.	57
Tabela 6.6 – Resultados das simulações aplicando os índices individualmente.....	59
Tabela 6.7 – Resultados das simulações sem distúrbio.	59
Tabela 6.8 – Comparação entre a performance dos sistemas com e sem distúrbio.	63
Tabela 6.9 – Valores de sintonia para os casos simulados.	66
Tabela 6.10 – Resultados da sintonia com distúrbio para cada frequência.	66

LISTA DE ABREVIATURAS E SIGLAS

CARIMA – *Controller Auto-Regressive Integrated Moving-Average*.

CARMA – *Controller Auto-Regressive Moving-Average*.

CSTR – Reator tipo Tanque Continuamente Agitado (do inglês, *Continued Stirred Tank Reactor*).

GPC – Controlador Preditivo Generalizado (do inglês, *Generalized Predictive Control*).

ISE – Integral do Erro ao Quadrado (do inglês, *Integrated Square Error*).

ISV – Integral da Variação ao Quadrado (do inglês, *Integrated Square Variation*).

MIMO – Múltiplas Entradas e Múltiplas saídas (do inglês, *Multiple Inputs and Multiple Outputs*).

MPC – Controlador de Modelo Preditivo (do inglês, *Model Predictive Control*).

PID – Proporcional, Integral e Derivativo.

SISO – Única Entrada e Única Saída (do inglês, *Single Input and Single Output*).

SVD – Decomposição em Valores Singulares (do inglês, *Singular Value Decomposition*).

LISTA DE SÍMBOLOS

A	Área da secção transversal do tanque cilíndrico.
$A(z^{-1})$	Matriz de polinômios presente na equação do tipo CARIMA.
$B(z^{-1})$	Matriz de polinômios presente na equação do tipo CARIMA.
$C(z^{-1})$	Matriz de polinômios presente na equação do tipo CARIMA.
C_A	Concentração do reagente A no reator CSTR.
C_{inA}	Concentração do reagente A na corrente de entrada do reator CSTR.
CO	Configuração ótima do sistema obtida pela metodologia do projeto.
C_p, C_{pC}	Capacidade calorífica.
C_V	Coefficiente de abertura da válvula.
$d, d(t)$	Distúrbio presente no sistema.
$D(s)$	Função de transferência do problema regulatório do sistema de controle.
$e(t)$	Ruído presente no sistema.
$E(s)$	Função de transferência do problema servo do sistema de controle.
E_A/R	Energia de ativação da reação do sistema.
E_j	Matriz de polinômios representando o ruído futuro do sistema.
E_{ux}	Estado de energia de uma variável de entrada de um sistema “x”.
E_{yx}	Estado de energia de uma variável de saída de um sistema “x”.
$f(t t)$	Resposta livre do sistema.
FI_{dMt}	Função de sensibilidade do índice I_{dMt}
FI_{St}	Função de sensibilidade do índice I_{St}
FI_{So}	Função de sensibilidade do índice I_{So}
F_{inA}	Fluxo de entrada de reagente no reator CSTR.
F_j	Matriz de polinômios representando a resposta livre do sistema.

F_{jo}	Fluxo de entrada do refrigerante na camisa do reator CSTR.
F_o	Fluxo de entrada no tanque cilíndrico.
FT	Valor absoluto do problema de otimização da metodologia.
g	Gravidade (em m/s^2).
$G(Z^{-1})$	Matriz de polinômios da resposta forçada do controlador GPC.
$G_C(s)$	Função de transferência do controlador do sistema de controle.
$G_D(s)$	Função de transferência do distúrbio do sistema de controle.
$G_P(s)$	Função de transferência do processo do sistema de controle.
$G_S(s)$	Função de transferência do sensor do sistema de controle.
h_A	Coefficiente de transferência de calor do reator CSTR encamisado.
H_C	Horizonte de controle do controlador MPC.
H_P	Horizonte de predição do controlador MPC.
I^*	Valor de referência dos índices presentes na metodologia.
$I_{\Delta Mt}$	Índice relacionado ao esforço de controle do sistema.
I_{est}	Índice relacionado à estabilidade das variáveis no sistema MIMO.
I_{est}^A	Valor do índice de estabilidade relacionada à primeira restrição do sistema.
I_{est}^B	Valor do índice de estabilidade relacionada à segunda restrição do sistema.
I_i	Representação dos índices presentes na metodologia.
I_{st}	Índice relacionado à minimização do erro do sistema.
I_{so}	Índice relacionado à rejeição dos distúrbios do sistema.
I_{so}^A	Valor do índice de distúrbio relacionado ao impacto no erro do sistema.
I_{so}^B	Valor do índice de distúrbio relacionado ao impacto no esforço de controle.
J	Resultado da função custo do controlador MPC.
k_o	Taxa de reação no reator CSTR.

L	–	Altura do conteúdo do tanque cilíndrico.
Q	–	Matriz de parâmetros de penalização do erro do controlador GPC.
R	–	Matriz de parâmetros de penalização do esforço do controlador GPC.
s	–	Variável complexa que descreve o sistema considerando tempo contínuo.
$[S]$	–	Matriz de valores singulares obtido pelo método SVD.
t	–	Tempo.
t^*	–	Valor específico de tempo.
T	–	Temperatura do reator CSTR.
$T(z^{-1})$	–	Função de transferência do processo para tempo discreto.
T/D	–	Coeficiente de relação entre os índices I_{S0} e I_{St} .
T/E	–	Coeficiente de relação entre os índices I_{dMt} e I_{St} .
t_d	–	Tempo morto.
t_{est}	–	Valor do tempo de estabilização da curva de referência do sistema.
T_{inA}	–	Temperatura da corrente de entrada do reator CSTR.
T_{jo}	–	Temperatura do refrigerante que adentra a camisa do reator CSTR.
T_S	–	Valor do tempo de amostragem do sistema.
t_{sim}	–	Valor do tempo total de simulação do processo.
$u, u(t)$	–	Variável de entrada do sistema.
$[U]$	–	Matriz de vetores singulares da esquerda.
$[V]$	–	Matriz de vetores singulares da direita.
V	–	Volume do reator CSTR.
w	–	Referência da variável controlada do sistema.
w_{dMt}	–	Parâmetro de penalização do índice I_{dMt} .
w_{S0}	–	Parâmetro de penalização do índice I_{S0} .

- w_{St} – Parâmetro de penalização do índice I_{St} .
- $y, y(t)$ – Variável controlada do sistema.
- z – Variável complexa que descreve o sistema considerando tempo discreto.

Símbolos gregos

- Δ – Expressão de variação de uma certa variável ($\Delta = 1-z^{-1}$).
- ΔH – Calor de reação.
- Δu – Esforço de controle do sistema.
- ρ, ρ_C – Densidade.
- σ – Valor singular.
- ω – Frequência do sistema.
- ω_{crit} – Valor da frequência crítica do sistema.
- ω_{dist} – Valor da frequência apresentada pelo distúrbio do sistema.

SUMÁRIO

1. INTRODUÇÃO	18
2. OBJETIVOS.....	20
3. FUNDAMENTAÇÃO TEÓRICA	21
3.1. Controladores de modelo preditivo (MPC) e a sintonia da função custo	21
3.2. Controlador GPC	25
3.3. Funções de Sensibilidade.....	29
3.4. Decomposição em Valores Singulares (SVD).....	32
4. PROBLEMA DE SINTONIA COM FUNÇÕES DE SENSIBILIDADE	34
4.1. Desenvolvimento e sistema SISO	34
4.2. Sistema MIMO	37
4.2.1. Problema de sintonia para sistema MIMO	38
4.2.2. Índice de estabilização (I_{est})	38
4.2.3. Minimização utilizando a otimização por enxame de partículas.....	40
5. SIMULAÇÃO DO PROCESSO (METODOLOGIA).....	41
5.1. Caso SISO.....	41
5.2. Caso MIMO	42
6. RESULTADOS E DISCUSSÕES	45
6.1. Caso SISO.....	45
6.1.1. Análise dos índices e diagramas de Bode:.....	45
6.1.2. Índice do erro (I_{St}):.....	52
6.1.3. Índice do esforço (I_{dmt}):	53
6.1.4. Índice de rejeição de distúrbio.....	56
6.2. Caso MIMO	57
6.2.1. Atuação individual dos índices (desconsiderando distúrbio)	57
6.2.2. Sintonia híbrida (I_{St} e I_{dmt}) utilizando índice de estabilidade (I_{est}).....	59
6.2.3. Sintonia completa com distúrbio presente:.....	63
7. CONCLUSÕES.....	68
8. SUGESTÕES PARA TRABALHOS FUTUROS	70
9. REFERÊNCIAS	71

1. INTRODUÇÃO

Dentro do campo de engenharia industrial, é possível dizer que o tópico de controle de processos encontra-se em uma posição de destaque, uma vez que esse atua com diversos objetivos que são essenciais para o aprimoramento mecânico e estratégico nesse cenário. Wilkie et al. (2017) descreve a função dos engenheiros dessa área em realizar a otimização de atividades, promovendo uma produção da melhor qualidade pelo menor custo, focando no benefício econômico da profissão. Blondin et al. (2019), por outro lado, compara a evolução que a área apresentou com o aumento da complexidade dos procedimentos industriais utilizados atualmente, demonstrando a relevância dessa na adaptabilidade de sistemas de produção. Albalawi et al. (2016) se dedica em ressaltar a responsabilidade em garantir a execução segura da planta, destacando a necessidade de interligar engenharia de controle com a segurança de sistemas de processo.

Diante de tantas qualidades essenciais no gerenciamento de processos complexos, é essencial que essa área seja cada vez mais explorada em busca da aprimoração de seus fundamentos, incentivando o incremento em eficiência e a aplicação ampla. Duffy et al. (2017) sugeriu uma metodologia de análise das variáveis de entrada e saída de um processo que permite o pareamento ideal entre essas em um sistema de controle de forma a incrementar a eficiência. Saif; On (2017) concebeu uma metodologia híbrida, mesclando a atuação de um sistema utilizando redes de dados com a resposta rápida de um modulador utilizando lógica *fuzzy* para garantir um sistema de ampla capacidade e resposta rápida e estável. Bahita; Belarbi (2016) aplicaram redes neurais para promover o controle adaptativo de uma planta, favorecendo a versatilidade desse diante de incertezas induzidas por não linearidades e complexidades.

Os exemplos mostram o impacto positivo na aplicação de controladores avançados na melhoria de execução de processos, sendo que, dentro deste grupo, vale mencionar os controladores preditivos (MPC). A capacidade desse em trabalhar com problemas de múltiplas variáveis e de atuar em estados próximos às restrições são apenas alguns dos pontos que o torna tão apreciado nessa área (MACIEJOWSKI, 2002). Essas características atribuem aos controladores MPC uma robustez e versatilidade apreciável, incentivando sua utilização tanto em sistemas químicos complexos (Wang et al., 2017), quanto também em sistemas eletrônicos (Vazquez et al., 2017) e em diversas aplicações tecnológicas, como em sistemas anticollisões em carros (Ji et al., 2017).

Tendo dito isso, uma das dificuldades apresentadas por esses está relacionada com o processo de sintonia, pois esses controladores apresentam diversas metodologias que podem ser aplicadas em seu desenvolvimento, sendo que cada uma apresenta sua própria base extensa de parâmetros a serem sintonizados, e afetam o raciocínio por trás da função custo de maneiras diferentes (Alhajeri; Soroush, 2020).

Diversos métodos de sintonia foram e ainda são propostos visando a universalização da aplicação e a possibilidade de lidar com diversas variáveis e cenários. Luzi et al. (2019) incentivou a parametrização de um sistema focando majoritariamente nos aspectos econômicos desse e nos horizontes do controlador. Shadmand et al. (2018) realizou a concepção de uma metodologia automática, na qual os valores dos parâmetros da função custo se adaptam às condições operacionais, garantindo a atuação do problema em uma região desejada. Santos et al. (2019) promoveu o aumento da robustez da sintonia de um processo ao sugerir o uso de múltiplos modelos relacionados com os pontos de operação do projeto. Esses estudos foram apresentados nos últimos anos, mostrando a relevância desse tema atualmente.

O problema em questão torna-se ainda mais complexo uma vez considerados sistemas de múltiplas entradas e saídas (MIMO). Em comparação a outros métodos (como os controladores PID), há diversas variáveis que devem ser sintonizados nos controladores MPC. Horizontes de controle e predição, valores de penalização do esforço de controle e do erro do sistema, e parâmetros de filtração de dados são alguns dos exemplos a serem considerados. Estes pontos, somado ao fato de que a sintonia muitas vezes é promovida manualmente, acabam inviabilizando a ampla utilização (BOEIRA et al., 2018).

A complexidade somada a quantidade de informação que deve ser considerada resultou na concepção de diversos métodos heurísticos para a realização da sintonia dos controladores MPC (Gonzales et al., 2018), apresentando métodos que priorizam praticidade no lugar de acurácia. Infelizmente, este tipo de prática acaba utilizando nenhum conhecimento acerca da dinâmica e comportamento do processo, e prejudica a análise e garantia de tanto a robustez quanto a estabilidade (Abrashov et al., 2017).

Uma forma de obter informações relevantes para o controle de um sistema está na utilização de funções de sensibilidade, permitindo o cálculo de dados que podem ser utilizados para garantir a estabilização e compreensão de um processo através do estudo do comportamento em frequência dessas (Patiño et al., 2018). Com a utilização desses termos, é possível a obtenção de apontadores que permitem a relação entre diferentes variáveis dos

processos para a avaliação de como um desses influencia a magnitude do outro, podendo ser utilizados para assessorar o desenvolvimento e sintonia de controladores específicos (Madiouni et al., 2019).

Nesse cenário, há uma necessidade de utilizar métodos que permitem a extração de dados e valores relevantes para o sistema, como aqueles apresentados pelas funções de sensibilidade, de forma prática e que permita o entendimento do sistema como um todo. A decomposição em valores singulares (SVD) tem se mostrado uma ferramenta matemática precisa e confiável para acessar a informação de sistemas multivariáveis e mensurar os estados de energias dos parâmetros do sistema. Isso garantiu a aplicação desse método em diversos cenários além do industrial, como no caso de *machine learning* (Gu; Wang, 2019), no processamento de imagens e sinais (Shen; On, 2018) sendo aplicado inclusive na área da neurociência, para compreender a dinâmica entre os neurônios no cérebro (Narayanan et al., 2019).

Sendo assim, o seguinte trabalho propõe uma metodologia de sintonia original utilizando funções de sensibilidade, que serão utilizadas na forma de índices em uma equação global que servirá como problema de otimização da proposta. Dentre os diversos controladores MPC que poderiam ser utilizados nesse projeto, optou-se pela utilização do controlador do tipo Modelo Preditivo Generalizado (GPC), uma vez que esse apresenta uma presença considerável tanto nos meio industrial e prático quanto no científico e teórico graças à sua fácil aplicação e capacidade de adequação inerente (Li et al., 2017). O raciocínio cultivado tenta interligar três tipos de objetivos em uma função: a minimização do erro, a redução do esforço de controle e a rejeição de distúrbios. O método foi aplicado em simulações de um sistema de única entrada e saída (SISO) e foi estendido para o cenário com múltiplas entradas e saídas (MIMO) posteriormente.

O projeto apresenta um caráter preliminar, focando na validação da metodologia e de sua aplicabilidade na sintonia de sistemas utilizando controladores preditivos. Tendo isso em mente, sugere-se que os resultados obtidos sejam utilizados na aplicação de sistemas de média complexidade e que a estrutura do método obtido seja investigada e adaptada para englobar processos específicos presentes no cenário industrial moderno.

2. OBJETIVOS

O projeto em questão tem como objetivo geral promover o desenvolvimento de uma metodologia de sintonia dos parâmetros de penalização da função custo do controlador MPC.

Sendo que esse método deve apresentar uma eficiência desejável em relação aos objetivos propostos para a sintonia, uma capacidade de customização adequada para atender as especificações propostas pelo usuário, além de possuir aplicação prática e intuitiva, facilitando sua transferência para um ambiente industrial, onde sua aplicação será relevante. Nesse caso, os seguintes objetivos específicos são determinados:

- Determinar a arquitetura matemática relacionada à metodologia de sintonia a ser proposta.
- Aplicar a metodologia em um tipo de controlador MPC de presença significativa na indústria.
- Avaliar em simulação a capacidade do método em ser tanto efetivo na sintonia quanto intuitivo em sua utilização.
- Promover a sintonia desejada de sistemas de controle MPC tanto para o caso SISO quanto para o MIMO.

3. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, será feita uma revisão bibliográfica referente a conteúdos relevantes no desenvolvimento do projeto em questão. O material é dividido em quatro subseções: Controladores de modelo preditivo (MPC), controladores preditivos generalizados (GPC), com uma sucinta explicação acerca do funcionamento matemático desses. Funções de sensibilidade, revelando o conceito e importância desses para a metodologia. Finalizando com Decomposição de Valores Singulares (SVD) e a sua utilização em processos MIMO.

3.1. Controladores de modelo preditivo (MPC) e a sintonia da função custo

A classe MPC refere-se à um conjunto de controladores que atuam no modo *feedback* e é baseado em otimizações realizadas a cada tempo de amostragem de um sistema discreto. A cada instante, é realizado o cálculo da variável de entrada que mais se adequa ao design desejado de atuação do sistema, sendo que esse resultado é obtido utilizando um modelo matemático que represente o processo em questão e seu comportamento e de uma equação denominada como “função custo”, que será responsável em determinar as prioridades do controlador na realização da otimização (Grüne; Pannek, 2017).

A figura 3.1 representa uma visualização gráfica de como o controlador MPC utiliza o modelo do sistema para obter os valores otimizados nos momentos futuros. Nesse, os valores

apresentados no processo em momentos passados são utilizados para compreender o impacto que as variáveis de entrada vão promover no comportamento da saída. Nesse caso, para cada tempo de amostragem, o controlador MPC resolverá um problema de otimização que obterá a sequência de controle ótima do sistema, garantindo a trajetória futura desejada para o sistema. Os cálculos de otimização são realizados para todo o horizonte de controle, porém apenas o primeiro resultado é repassado para o sistema e essas operações são repetidas inteiramente na próxima amostragem, o que geralmente ocasiona na necessidade de uma alta carga computacional (Fesharaki et al., 2020; Vijayagopal; Zanchetta, 2017).




Figura 3.1 – Exemplificação da previsão realizada pelo controlador MPC (adaptado de Grüne; Pannek (2017)).

O modelo matemático é utilizado para prever o comportamento do sistema, enquanto a função custo é utilizada no otimizador para obter as respostas ótimas. A Figura 3.2 mostra a forma de atuação genérica dos controladores MPC, destacando a relação entre processo e controle. Nesse, o controlador obtém os dados de entrada e saída anteriores, utilizando-os em conjunto com a ação de controle para prever o resultado dessa combinação de fatores no valor futuro da variável controlada, permitindo compará-la com a trajetória de referência, obtendo o erro futuro. Utilizando um otimizador que promove a minimização de uma função custo, além da obediência do sistema em relações às suas restrições, é possível obter os valores ótimos de entrada, que serão utilizados pelo processo físico para a sua devida alteração, e pelo modelo do controlador para calcular resultados posteriores até um certo horizonte de previsão.

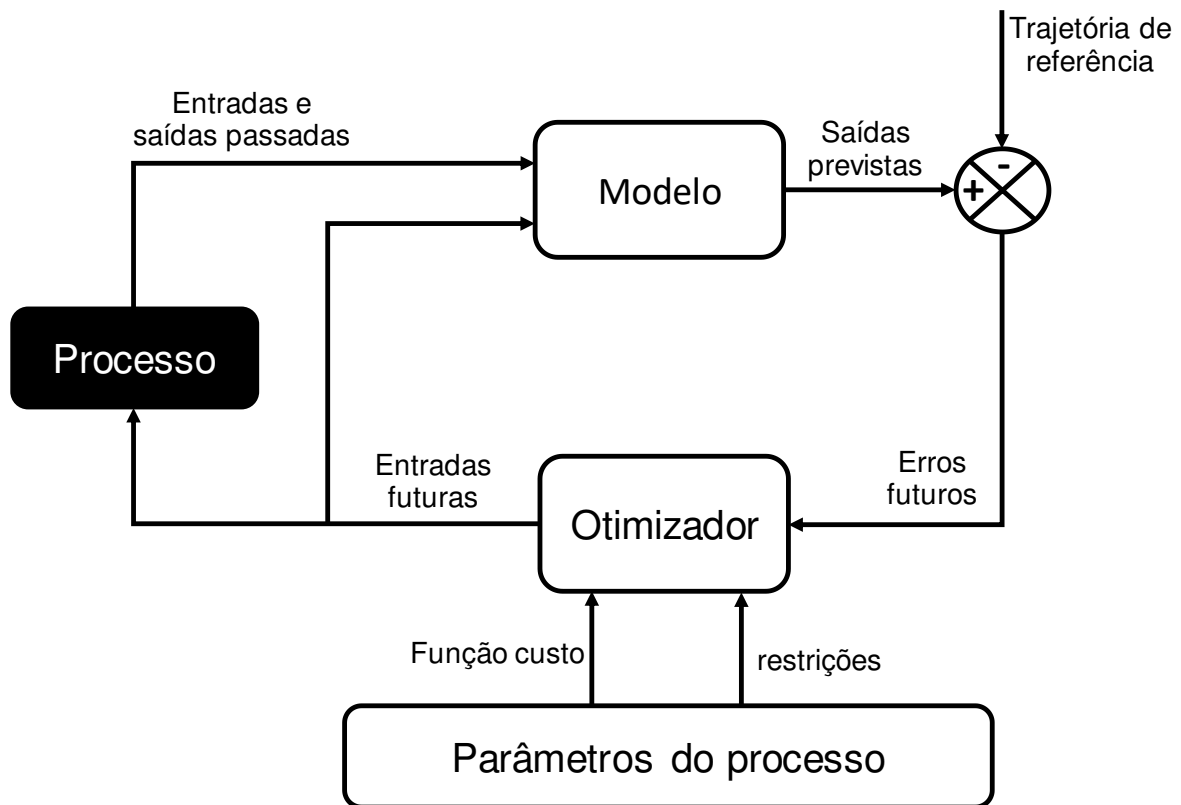


Figura 3.2 - Esquematização da atuação do controle MPC (adaptado de Camacho; Bordons (2007)).

O problema de otimização, equivalente à minimização da função custo dependente dos valores de entradas e saídas futuros, pode ser descrita pela equação 3.1. A função custo, nesse caso, se apresenta como uma forma de balancear a precisão de rastreamento dos valores de referências e o custo energético promovido no controle do sistema (Stluka et al., 2018).

$$u_i = \min_{u_i} \sum_{k=0}^{H_p-1} J(u_k, y_k) \quad (\text{Equação 3.1})$$

Os parâmetros de penalização Q e R servirão como a forma de determinar o impacto que cada uma dessas ações, respectivamente, apresentará na realização da otimização, impactando a performance do controlador no processo. A metodologia de sintonia que será avaliada nesse trabalho atuará nesses parâmetros específicos e, uma vez que esses fazem parte da função custo padrão utilizada no MPC, ela é válida para todos os tipos de controladores preditivos dessa classe, embora nesse projeto será utilizado um tipo de controlador específico (o controlador GPC).

Na literatura, é possível notar o interesse da academia em aprimorar os métodos de sintonia dos parâmetros de penalização da função custo do controlador MPC, uma vez que essa

ainda é comumente promovida através de métodos heurísticos, como a da tentativa e erro. Seguindo um raciocínio similarmente empírico, diversas metodologias utilizam resultados obtidos através de dados relacionados à satisfação do usuário. Mohammadi et al. (2019) aplicou um algoritmo genético iterativo, que reconhece a opinião de uma população relacionada à performance de um certo resultado para compreender as necessidades que devem ser atendidas pelo método e adequar a respostas devidamente. Ira et al. (2020), por outro lado, aplicou o conceito de *machine learning* de forma a aplicar resultados estocados em uma base de dados, representando configurações de parâmetros utilizados por diversos operadores como indicadores dos melhores valores de parâmetros.

Esses métodos, porém, apresentam algumas limitações. Uma delas é a necessidade de um banco de dados extenso, tornando extremamente custoso sua aplicação eficiente. Um segundo problema está relacionado ao fato de que os valores utilizados acabam apresentando uma natureza extremamente subjetiva, não necessariamente indicando o melhor comportamento que o sistema pode apresentar, mas sim aquele que o colaborador acabou adotando através de sua experiência. Finalmente, vale notar que os resultados obtidos apresentam uma resolução única.

A sintonia dos parâmetros de penalização da função custo, assim como todos os problemas de otimização, não é bem-posto, e é representado, nesse caso, pelo fato de que é impossível que ambos os índices de custo representados por cada parâmetro sejam anulados simultaneamente. Além disso, os resultados obtidos pela metodologia de sintonia não necessariamente representam a melhor performance que o sistema pode obter, mas sim a minimização de um índice de performance que tende a refletir a dinâmica do sistema (Bartsch et al., 2017). Nesse contexto, métodos que promovem uma resolução única muitas vezes são incapazes de englobar o melhor comportamento para diversos cenários relacionado ao sistema.

Uma forma de contornar esse problema que tem sido explorado em diversos trabalhos são métodos de sintonia automáticas, que alteram os valores dos parâmetros online de forma a atribuir um dinamismo no comportamento do sistema. Chen et al. (2019) desenvolveu uma função custo dinâmica utilizando lógica Fuzzy, que promovia alteração nos parâmetros de penalização de acordo com o estado do problema servo do sistema. Chin; Rowe (2019) apresentou um algoritmo de parametrização dinâmica, no qual os parâmetros de penalização eram reformulados de acordo com a configuração que promoveu a melhor redução da função custo. Um dos problemas desses métodos, porém, é o incremento da carga de cálculos do

sistema de controle, o que se mostra inadequado, uma vez que os controladores MPC já apresentam um custo computacional significativo.

Vale ainda mencionar algumas metodologias de sintonia que buscam soluções algébricas para o problema estudado. Giraldo et al. (2019) apresentou uma metodologia híbrida que aplica dois métodos em conjunto (alcance de metas e procura de variável vizinha) de forma a obter uma resolução que garantisse a restrição do erro presente no sistema. Mei et al. (2018), por outro lado, concebeu uma função custo única que dispensava a utilização de parâmetros de penalização, descartando completamente o problema de sintonia em troca da aplicação de uma metodologia que a cada instante focava na ação de controle que apresentava o maior comprometimento.

Ainda assim, as metodologias de sintonia para os parâmetros de penalização muitas vezes acabam focando mais em um parâmetro específico (geralmente o erro do sistema) em detrimento do segundo, dependente de restrições do sistema. Nesse cenário, o método desenvolvido nesse trabalho visa contornar grande parte das limitações apresentadas anteriormente. Como por exemplo o fato de que ambas ações de controles de cada parâmetro possam ser igualmente consideradas ou não dependendo do objetivo do usuário. Além disso, a obtenção de uma resposta única garante contornar a necessidade por maior carga computacional apresentada pelos modelos automáticos, mas a possível customização do método garante que o resultado obtido seja adequado para os objetivos do usuário, possibilitando o englobamento de diversos cenários relacionados ao sistema (diferente de outros métodos de resposta única), além de serem determinados unicamente pelo operador, evitando conflito com resultados específicos contidos em bancos de dados usados em outros trabalhos.

3.2. Controlador GPC

O controlador preditivo do tipo GPC foi primeiramente introduzido por Clarke et al. (1987), visando a concepção de uma metodologia de controle de aplicação generalizada no meio industrial, necessitando apresentar um nível de robustez adequado. Pouco tempo após sua proposta, o método já começava a ser aplicado em situações práticas (CLARKE, 1988), devido à versatilidade e grau de precisão apreciáveis. Trabalhos ainda comprovam que a capacidade desse em minimizar o erro era maior que de métodos de controle usualmente optados na indústria, como os controladores PI e PID (Reynoso Meza et al., 2017).

Atualmente, diversos artigos focam na continuação da aplicação do controlador GPC em processos modernos, de forma que esse possa acompanhar o crescente aumento no grau de

complexidade de sistemas de produção atuais. Um dos grandes focos desses trabalhos é garantir que o controlador possa atuar com sistemas não lineares a variáveis, garantindo uma robustez adequada para processos contemporâneos (Boulkaibet et al., 2017; Xie et al., 2018). Além do cenário industrial, porém, o mecanismo GPC também tem encontrado aplicações em diversos cenários, que visam explorar a capacidade do controlador em garantir o funcionamento de um sistema de maneira eficiente sem extrapolar restrições presentes (Liu et al., 2017).

Apresentando características tanto únicas quanto comuns em controladores do tipo MPC, o GPC é uma opção adequada de controle para sistemas com grandes incertezas, tempo morto, instabilidade em malha aberta e sem a presença de fase mínima, tornando uma opção extremamente apropriada em diversos sistemas industriais complexos. Tendo dito isso, uma das complicações que pode surgir no uso desse método é o fato de que esses controladores apresentam uma sensibilidade demasiadamente significativa em relação aos parâmetros do modelo utilizado em sua arquitetura Yang et al. (2020).

A metodologia GPC é explicada detalhadamente em Camacho; Bordons (2007) e Clarke et al. (1987), e sua abordagem prática é resumida por Kwong (2012), sendo que essas referências serão utilizadas para sua explicação teórica. Uma vez que a estratégia do controlador GPC nos casos SISO e MIMO divergem minimamente uma da outra, será feita uma única contextualização global, sendo que os detalhes mais relevantes são destacados durante o texto.

A representação do sistema é feita através de um modelo CARMA (do inglês, *Controller Auto-Regressive Moving-Average*), que pode ser explicitada pela Equação 3.2, na qual $u(t)$ e $y(t)$ são os valores de entrada e da saída em função da progressão temporal, $e(t)$ representa o ruído presente, t_d o tempo morto, e os parâmetros A , B e C são matrizes de polinômios expressas em relação ao inverso da variável z . Essa equação, porém, não é adequada para processos com distúrbios inconstantes, frequentemente presentes no ambiente industrial. Por isso, é atualizada para Equação 3.3, do tipo CARIMA (do inglês, *Controller Auto-Regressive Integrated Moving-Average*), no qual se tem que $\Delta=1-z^{-1}$ e que t^* representa um momento de tempo específico do sistema. A arquitetura do controlador GPC é moldada em torno do modelo CARIMA, e é um dos princípios considerados na sua concepção (Călugăru; Carpathian, 2016).

$$A(z^{-1}) * y(t^*) = z^{-t_d} * B(z^{-1}) * u(t^* - 1) + C(z^{-1}) * e(t^*) \quad (\text{Equação 3.2})$$

$$A(z^{-1}) * y(t^*) = z^{-t_d} * B(z^{-1}) * u(t^* - 1) + \frac{C(z^{-1}) * e(t^*)}{\Delta} \quad (\text{Equação 3.3})$$

O termo $A(z^{-1})$ pode ser definido como uma matriz diagonal, no qual os membros não-nulos são equivalentes à multiplicação entre os divisores dos elementos da mesma linha desses na matriz de funções de transferência do processo ($T(z^{-1})$), como mostrado pela Equação 3.4 e 3.5 para um sistema de n entradas e m saídas. Por outro lado, $B(z^{-1})$, é obtida pela Equação 3.6. $C(z^{-1})$ será igualada à matriz identidade visando simplificação do problema.

$$\begin{cases} A(z^{-1}) = \text{diag}(A_1(z^{-1}), A_2(z^{-1}), \dots, A_m(z^{-1})) & \text{(Equação 3.4)} \\ A_i(z^{-1}) = \prod_{j=1}^n \text{den}(T_{i,j}) & \text{(Equação 3.5)} \\ B(z^{-1}) = z * A(z^{-1}) * T(z^{-1}) & \text{(Equação 3.6)} \end{cases}$$

O método GPC utiliza a Equação 3.7 como modelo de predição para determinar os resultados de saída do sistema, sendo que cada termo pode ser interpretado separadamente. O primeiro representa a resposta forçada do processo, ou seja, o efeito promovido pelos valores de esforço de controle (representados pelo vetor Δu) futuros. Enquanto o segundo refere-se à resposta livre, ou seja, a implicação que os dados de entrada e saída anteriores possuem no comportamento da variável controlada.

$$y(t^* + 1|t^*) = G(z^{-1}) * \Delta u(t^*|t^*) + f(t^*|t^*) \quad \text{(Equação 3.7)}$$

A resposta livre (representada pelo segundo termo da Equação 3.7) pode ser parcialmente obtida através das matrizes E_j e F_j , destacadas na Equação 3.8. Vale ressaltar que a matriz \tilde{A} equivale ao resultado da operação ΔA . E_j e F_j podem, então, ser extraídas da divisão longa de I/\tilde{A} . F_j representa a resposta livre da saída enquanto E_j seria a influência do ruído futuro, que será considerado como igual à 0.

$$I_{m \times m} = E_j(z^{-1})\tilde{A}(z^{-1}) + z^{-j}F_j(z^{-1}) \quad \text{(Equação 3.8)}$$

Porém, os resultados não contêm a resposta livre do esforço de controle, que é obtida junto com a resposta forçada do sistema usando a matriz derivada da Equação 3.9. Após obter ambas, é possível completar o modelo de predição (Equação 3.7), obtendo a Equação 3.10.

$$G_j(z^{-1}) = B(z^{-1})E(z^{-1}) \quad \text{(Equação 3.9)}$$

$$y(t^* + j|t) = G_j(z^{-1}) * \Delta u(t^* + j - 1|t) + F_j(z^{-1})y(t^*) \quad \text{(Equação 3.10)}$$

Com o modelo definido, desenvolve-se a função custo objetivo, que se apresenta na Equação 3.11, na qual w refere-se à referência do processo. Percebe-se nessa que dois critérios são utilizados no problema de otimização: o erro apresentado pelo sistema e o esforço de

controle. Cada um desses apresentam um parâmetro de penalização, que determina a relevância dessa ação quando for feito o tratamento matemático, sendo que a matriz Q relaciona-se com o erro e R com o esforço.

$$J = \sum_{i=1}^{H_p} (y(t^* + i|t^*) - w(t^* + i|t^*))^T Q (y(t^* + i|t^*) - w(t^* + i|t^*)) + \Delta u(t^* + i|t^*)^T R \Delta u(t^* + i|t^*) \quad (\text{Equação 3.11})$$

O problema de otimização, então, promoverá a minimização dessa função para obtenção da ação de controle ótima. Sendo que é possível descrever uma resposta analítica, expressa pela Equação 3.12, para situações nas quais não se considera restrições. Vale ressaltar que os valores dos parâmetros de ambas as matrizes de pesos Q e R devem ser, necessariamente, positivos não-nulos.

$$\Delta u(t^* + 1|t^*) = (G(z^{-1})^T Q G(z^{-1}) + R)^{-1} G(z^{-1})^T Q (w(t^*|t^*) - f(t^*|t^*)) \quad (\text{Eq. 3.12})$$

A sintonia dos controladores GPC, assim como de outros do tipo MPC, é um problema complexo, uma vez que engloba diversos parâmetros que afetam a sua dinâmica. Ainda existe uma falta de trabalhos acadêmicos relacionados com esses tópicos, e aqueles que exploram sugestões e metodologias frequentemente ignoram a influência de cada parâmetro na performance e na robustez do sistema (De Oliveira Júnior et al., 2018). Nesse sentido, o trabalho apresentado também apresenta uma contribuição nessa área específica para o GPC, uma vez que o método considera tanto a otimização do erro quanto do esforço, além da capacidade do sistema em rejeitar distúrbios.

Com o problema descrito, é possível analisar os parâmetros que devem ser sintonizados nesse sistema. A Tabela 3.1 detalha-os de maneira sucinta, além de descrever suas funções no controlador GPC. Nesse trabalho, alguns desses serão pré-definidos antes da simulação, pois esses não são o foco dos objetivos do projeto.

Tabela 3.1 – Parâmetros de sintonia do controlador GPC.

Parâmetros	Símbolo	Descrição
Tempo de amostragem	T_s	Determina o espaçamento do tempo discreto que representa o sistema. Valor não deve ser excessivamente alto (acúmulo do erro) e nem muito baixo (Truncamento e carga computacional).
Horizonte de Controle	H_c	Determina o horizonte no qual a ação de controle é calculada na função custo objetivo. Quando alto, esse aumenta a robustez e a carga computacional.
Horizonte de Predição	H_p	Determina o horizonte no qual o erro da saída é calculado na função custo objetivo, favorecendo sua redução, embora promova o aumento da carga computacional.
Peso do desvio	Q	Determina importância do erro da saída na minimização da função custo.
Peso do esforço	R	Determina importância do esforço de controle na minimização da função custo.
Trajetória de referência	w	Determina o comportamento esperado da saída. Pode ser definida como uma função de primeira ordem, ao invés de uma constante, assim como é determinada geralmente.

3.3. Funções de Sensibilidade.

No campo de sintonia de controladores MPC, o conceito de funções de sensibilidade encontra-se bem definido, com diversos trabalhos aplicando-o na obtenção de métodos adequados (HOSSEINIA; LUNDH, 2016; Rafieishishavan, 2020; FRANCISCO ET AL., 2011), além de outros que as utilizaram de forma a compreender a dinâmica de um processo específico na forma de expressões matemáticas de fácil obtenção e análise (Patiño et al., 2019). Essas podem ser descritas como equações que relacionam dados de entrada do controlador (como distúrbio, referência, ruídos) com os parâmetros de interesse no sistema (variáveis manipulada e controlada). Sendo que é bem frequente a aplicação da razão entre variável de saída e distúrbio como apontador de performance, uma vez que quanto menor for esse, menor será a influência do distúrbio na resposta do processo (MACIEJOWSKI, 2002).

Isso permite a aplicação dessa ferramenta na determinação de valores adequados em parâmetros do controlador. Vale ressaltar, nesse caso, que como as funções de sensibilidade serão utilizadas em um processo paralelo àquela da simulação, sendo aplicadas na sintonia do

processo, o tratamento matemático adotado para essas abrange o campo contínuo, diferindo daquele visto anteriormente no controlador GPC, no qual todos os cálculos foram apresentados no estado discreto.

Pode-se considerar a Equação 3.13, detalhando o valor da saída de uma malha fechada em relação à referência e ao distúrbio do sistema. Nessa, observa-se que é possível isolar o termo que os relaciona, obtendo as funções de sensibilidade expressas nas Equações 3.14 e 3.15:

$$\begin{cases} y(s) = D(s) * d(s) + E(s) * w(s) & \text{(Equação 3.13)} \\ D(s) = \frac{y(s)}{d(s)} & \text{(Equação 3.14)} \\ E(s) = \frac{y(s)}{w(s)} & \text{(Equação 3.15)} \end{cases}$$

Uma vez que essas relações são definidas, deve-se analisar o significado físico e estipular regras acerca do que é esperado da sua conduta. Por exemplo, a Equação 3.15 representa a relação entre a resposta do sistema e a curva de referência, sendo que o objetivo do controlador é manter o primeiro mais próximo possível do seguinte. Nesse contexto, é possível ditar que o valor desejado dessa equação é igual à 1. No caso da Equação 3.14, esse pode ser interpretado como a influência do distúrbio no comportamento da saída. É comum estimar que esse deve apresentar a menor dimensão para que o segundo rejeite ao máximo sua interferência.

Pode-se então expandir esta teoria para um procedimento em malha fechada com controlador, processo e sensor. Considerando o diagrama da Figura 3.1, apresentamos a possibilidade de obter as funções de sensibilidade que relacionam as variáveis controladas com as entradas do sistema. Obtendo as relações apresentadas na Tabela 3.2, sendo importante ressaltar que, para o caso MIMO, os valores “1” são substituídos pela matriz identidade.

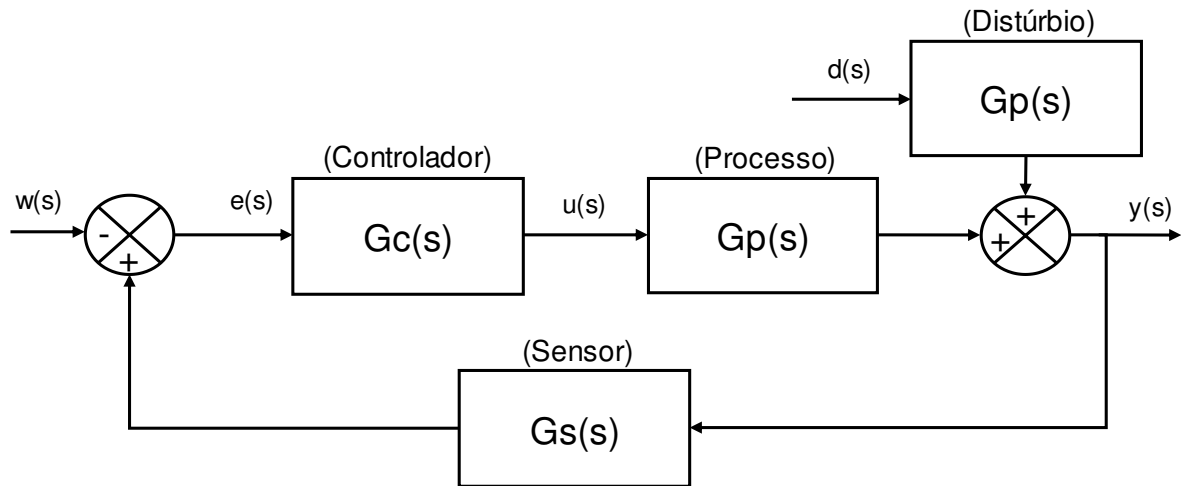


Figura 3.3– Diagrama de blocos de um sistema em malha fechada.

Tabela 3.2 – Funções de sensibilidade típicas de um sistema em malha fechada.

Função de sensibilidade	Descrição
$\frac{y(s)}{d(s)} = \frac{G_d}{G_c G_p G_s + 1}$	Relação entre variável controlada e distúrbio. Representa o quanto o distúrbio impacta o comportamento da saída. Deseja-se que o valor seja próximo de zero.
$\frac{y(s)}{w(s)} = \frac{G_c G_p}{G_c G_p G_s + 1}$	Relação entre variável controlada e referência. Representa a proximidade da referência e a saída. Deseja-se que esses sejam iguais (valor de 1).
$\frac{u(s)}{d(s)} = \frac{G_d G_c G_s}{(G_c G_p G_s + 1)}$	Relação entre variável manipulada e distúrbio. Refere-se ao impacto do distúrbio na entrada. Deseja-se que o valor seja próximo de zero.
$\frac{\Delta u(s)}{w(s)} = \frac{\Delta G_c}{G_c G_p G_s + 1}$	Relação entre esforço de controle e a referência. Refere-se ao empenho aplicado para controlar o sistema. Deseja-se que o valor seja o menor possível.

A informação relevante que está presente nessa análise para o trabalho é o fato de que podemos notar que essas funções de sensibilidade são dependentes dos elementos da malha de controle, em específico, do controlador GPC presente no processo. Uma vez que a relação entre erro e esforço de controle é determinada pela função custo (como visto nas equações 3.11 e 3.12), podemos nesse caso relacionar os parâmetros de penalização Q e R (presente na função custo) com as funções de sensibilidade.

Independentemente do tipo de distúrbio utilizado, sabe-se que a magnitude dos fatores de sensibilidades são afetados majoritariamente pelos mesmos parâmetros (Paszek et al., 2020). Nesse caso, com a relação obtida, podemos configurar uma sintonia dos parâmetros de penalização ao utilizá-los para alterar as magnitudes das funções de sensibilidade de forma a garantir que o sistema atue da forma desejada.

A relação entre as variáveis da função de sensibilidade é possível de ser analisada utilizando suas respostas em frequência. Por exemplo, a função que relaciona distúrbio com a variável controlada pode ser analisada através de um diagrama de Bode, no qual a magnitude dessa irá determinar, por exemplo, se a amplitude do distúrbio está sendo atenuada (para valores abaixo de 0dB) ou ampliada (acima de 0dB) (Landau et al., 2017).

3.4. Decomposição em Valores Singulares (SVD)

Uma ferramenta matemática adequadamente conveniente na identificação de sistemas é a decomposição em valores singulares (SVD). Essa pode ser definida como uma operação algébrica que permite a obtenção da matriz de valores singulares do processo (S), além de definir os vetores singulares desse através de duas matrizes (U e V), assim como demonstrado pela Equação 3.16. Essa metodologia é bastante útil na determinação de normas e na compreensão da atuação do controlador (ZHOU; DOYLE, 1998).

$$M = U * S * V^T \quad (\text{Equação 3.16})$$

Devido a relevância dos valores singulares no sistema, o mecanismo pode ser aplicado de diversas maneiras, apresentando uma versatilidade apreciável. Gómez-Pérez; Espinosa (2017) utilizou a ferramenta na análise de design de um projeto de biorreatores, na qual o método permitiu a obtenção do estado estacionário desse, a partir da avaliação do valor singular nulo que era obtido. Gerkšič et al. (2018) promoveu o controle de um reator Tohamak, que apresenta um grau de complexidade elevada e lida com múltiplas variáveis de entrada e de saída. Para isso, a SVD reduziu a dimensão do problema e favoreceu a identificação das propriedades mais relevantes para o processo. Shahid et al. (2018) propôs a utilização desse método para analisar elementos importantes em um controlador preditivo, como a magnitude e a fase do sistema em malha aberta, além de relacioná-los com parâmetros de sintonia, como os horizontes de controle e de predição.

Parte dessa aplicabilidade apresentada é relacionada ao fato de que o método permite a compreensão da física por trás de um problema ao separar os dados relacionados a cada função

e parâmetro presentes. Essa característica tem sido estudada em diversas áreas, de forma que o método SVD apresenta similaridade significativa com metodologias equivalentes presentes em outros campos de estudo, como a análise de componentes principais (PCA) em estatística e decomposição ortogonal própria em mecânica de fluídos (Azañez et al., 2019).

Na metodologia proposta, espera-se determinar a energia de controle de cada variável de saída e de entrada. Nesse caso, é possível descrever o comportamento do processo multivariável de n entradas e n saídas através da Equação 3.17, na qual as matrizes U , S e V^T representam o resultado do método SVD aplicado na matriz do sistema estudado. A partir dessa, é possível manipular a equação para que apenas um parâmetro de saída ou uma de entrada seja descrita, assim como representado pelas Equações 3.18 e 3.19, respectivamente.

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} U_{11} & U_{12} & \cdots & U_{1n} \\ U_{21} & U_{22} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ U_{n1} & \cdots & \cdots & U_{nn} \end{bmatrix} \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & \cdots & \sigma_n \end{bmatrix} \begin{bmatrix} V_{11} & V_{21} & \cdots & V_{n1} \\ V_{12} & V_{22} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ V_{1n} & \cdots & \cdots & V_{nn} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \quad (\text{Eq. 3.17})$$

$$y_1 = [U_{11} \quad U_{12} \quad \cdots \quad U_{1n}] \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & \cdots & \sigma_n \end{bmatrix} \begin{bmatrix} V_{11} & V_{21} & \cdots & V_{n1} \\ V_{12} & V_{22} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ V_{1n} & \cdots & \cdots & V_{nn} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \quad (\text{Eq. 3.18})$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} U_{11} & U_{12} & \cdots & U_{1n} \\ U_{21} & U_{22} & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ U_{n1} & \cdots & \cdots & U_{nn} \end{bmatrix} \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & \cdots & \sigma_n \end{bmatrix} \begin{bmatrix} V_{11} \\ V_{12} \\ \vdots \\ V_{1n} \end{bmatrix} u_1 \quad (\text{Eq. 3.19})$$

Percebe-se então que as matrizes de vetores singulares (U e V) apresentam uma relação especial com as entradas e saídas. Elas podem ser interpretadas como vetores direcionais de um eixo de coordenadas que representam as variáveis manipuladas e controladas, sendo que os valores singulares atuam como parâmetros de escalonamentos entre cada par de vetores, uma da matriz U e a outra de V (Wang et al., 2020). Por isso, uma vez que as matrizes U e V são multiplicados com a matriz de valores singulares, obtêm-se um resultado que relaciona o impacto que uma variável de entrada promove em uma saída específica, e vice-versa. Utilizando esse conceito, desenvolvem-se as Equações 3.20 e 3.21, na qual o parâmetro E pode ser descrita como o estado de energia de cada elemento do sistema.

$$E_{y_x} = \|[U_{x1}\sigma_1 \quad U_{x2}\sigma_2 \quad \cdots \quad U_{xn}\sigma_n]\|_1 \quad (\text{Equação 3.20})$$

$$E_{u_x} = \|[V_{x1}\sigma_1 \quad V_{x2}\sigma_2 \quad \cdots \quad V_{xn}\sigma_n]\|_1 \quad (\text{Equação 3.21})$$

$$\|A\|_1 = \sum_{i=1}^n |A_i| \quad (\text{Equação 3.22})$$

Os valores de energia obtidos podem ser úteis na sintonia, pois nos permite inferir quais variáveis manipuladas afetam o sistema com maior veemência e quais variáveis controladas são mais sensíveis às perturbações (ALVAREZ; ESPINOSA, 2012; Xu et al., 2016).

4. PROBLEMA DE SINTONIA COM FUNÇÕES DE SENSIBILIDADE

4.1. Desenvolvimento e sistema SISO

A sintonia é aplicada visando o ajuste dos parâmetros de penalização da função custo objetivo, ou seja, das matrizes R e Q , que afetam diretamente a dinâmica e eficiência da resposta do controlador. Nesse caso, o problema de otimização, que será solucionada para obter a configuração ótima (CO), pode ser descrito como a minimização de uma função FT descrita pela Equação 4.1, na qual \mathbf{I} é o conjunto de índices obtidos pelo método proposto, os quais são dependentes das variáveis de interesse (R , Q) e calculados através da resposta em frequência do conjunto de funções de sensibilidade (FI) que são associados com cada um dos índices individualmente.

$$FT(\mathbf{I}(CO)) = \min_{R,Q} FT(\mathbf{I}(R, Q, FI)) \forall R, Q \in \mathbb{R}^{R,Q} \quad (\text{Equação 4.1})$$

Nessa equação, foram aplicados três tipos de índices diferentes, que visavam promover ações distintas no problema de sintonia:

- **Índice do erro (I_{st}):** Esse índice representa a aproximação da saída do sistema com a trajetória de referência, focando apenas na relação entre essas duas e atuando majoritariamente no parâmetro Q .
- **Índice do esforço (I_{amf}):** Representa a redução do empenho do controlador, ou seja, da variação da variável manipulada. Nesse caso, ele atua, primariamente, no parâmetro R .
- **Índice de rejeição do(s) distúrbio(s) (I_{so}):** O último índice representa a redução do efeito promovido pelo distúrbio no desempenho do sistema.

Nesse cenário, define-se para cada índice um valor final desejado e um parâmetro de penalização, sendo que esse último é adicionado possibilitando a customização do problema de otimização, incentivando o usuário a determinar os objetivos de maior relevância.

Nesse caso, descreve-se a função FT do problema de sintonia de acordo com a Equação 4.2, na qual os parâmetros w e \mathbf{I}^* são os pesos e os valores desejados de cada índice, respectivamente:

$$FT = w_{ST} * (\mathbf{I}_{St} - \mathbf{I}_{St}^*)^2 + w_{dMT} * (\mathbf{I}_{dMt} - \mathbf{I}_{dMt}^*)^2 + w_{S0} * (\mathbf{I}_{S0} - \mathbf{I}_{S0}^*)^2 \quad (\text{Equação 4.2})$$

Embora a ideia de substituir a sintonia dos termos do controlador pelo ajuste dos parâmetros de penalização de cada índice possa parecer contraditório, o problema acaba sendo mais intuitivo, uma vez que cada um desses se relaciona com uma ação específica. Além disso, as funções de sensibilidade, antes de serem calculadas, são devidamente escalonadas, visando facilitar a interatividade na decisão dos valores.

Nesse caso, cada índice e a função de sensibilidade que os define podem ser descritos, além dos seus valores esperados. Vale ressaltar que, para obtenção das funções de sensibilidade do controlador e do sensor, é considerado a solução analítica explícita pela Equação 3.11 e, por isso, uma das considerações na metodologia é a de não haver imposição de restrições. A Tabela 4.1 representa cada ação, em conjunto com as metas atribuídas às essas:

Tabela 4.1– Funções de sensibilidade utilizadas na metodologia.

Tipo	Índice	Função (FI)	Meta da função (\mathbf{I}^*)
Minimização do erro	\mathbf{I}_{St}	$\frac{y(s)}{w(s)} = \frac{G_c G_p}{G_c G_p G_s + 1}$	1
Minimização do esforço	\mathbf{I}_{dMt}	$\frac{\Delta u(s)}{w(s)} = \frac{\Delta G_c}{G_c G_p G_s + 1}$	0
Rejeição de distúrbio (Rastreamento)	\mathbf{I}_{S0}^A	$\frac{y(s)}{d(s)} = \frac{G_d}{G_c G_p G_s + 1}$	0
Rejeição de distúrbio (Esforço)	\mathbf{I}_{S0}^B	$\frac{\Delta u(s)}{d(s)} = \frac{\Delta G_d G_s G_c}{(G_c G_p G_s + 1)}$	0

As minimizações do erro e do esforço seguem o mesmo raciocínio que aquele desenvolvido na revisão. O índice \mathbf{I}_{St} serve como uma medida de comparação entre a saída e a referência do sistema e, nesse caso, deseja-se que seus valores sejam iguais e sua relação, consequentemente, igual à um. Já no caso do esforço de controle, é esperado que esse seja o menor possível, justificando o valor desejado de zero.

Em relação ao índice de rejeição de distúrbios, é comum ditar que a minimização desse deve ser o foco do problema de sintonia (FRANCISCO ET AL., 2011; MACIEJOWSKI, 2002),

sendo que esse princípio é aplicado como base para sua determinação. Vale ressaltar, porém, que esse parâmetro atua visando a minimização do efeito do distúrbio tanto no erro quanto no esforço apresentado pelo sistema, e por isso deve ser calculado considerando ambos, sendo esses descritos na tabela 4.1. Nesse caso, o valor final atribuído ao índice \mathbf{I}_{SO} encontra-se descrito na equação 4.3 e considera a soma das ações descritas.

$$\mathbf{I}_{SO} = \mathbf{I}_{SO}^A + \mathbf{I}_{SO}^B \quad (\text{Equação 4.3})$$

Uma vez definidas, as funções de sensibilidade se apresentam como mecanismos adequados para representação da dinâmica do processo. Para a realização desse objetivo, porém, pode-se obter a resposta em frequência desses sistemas, o que permite avaliar como as funções se comportam diante das variações dos parâmetros do controlador.

As frequências submetidas estarão no intervalo entre 0 e ω_{crit} , sendo que o último se refere à frequência máxima que o sistema pode apresentar. Esse valor é facilmente encontrado pela Equação 4.4, na qual, se a frequência introduzida fosse maior que o resultado apresentado, o fenômeno de *aliasing*, na qual não é possível distinguir o sinal oscilatório devido à limitação do tempo de amostragem do controlador (T_s), ocorreria (WILKIE ET AL., 2017).

$$\omega_{crit} = \frac{\pi}{T_s} \quad (\text{Equação 4.4})$$

O comportamento do índice \mathbf{I}_{St} é calculado então no intervalo de operação referido na Equação 4.5, que demonstra a integração da resposta em frequência. Porém, o índice \mathbf{I}_{dMt} deverá ser calculado através da equação 4.6, que insere na fórmula o valor do ganho da função G_P (representado pela variável T/E). O objetivo dessa mudança é de garantir a simetria de magnitude entre os parâmetros \mathbf{I}_{St} e \mathbf{I}_{dMt} , uma vez que a relação entre as variáveis de saída e de entrada (relacionadas com estes índices, respectivamente) é determinada pelo ganho da função de transferência do sistema sendo controlado.

$$\mathbf{I}_{St} = \frac{\int_0^{\omega_{crit}} |FI_{St}(j\omega)| d\omega}{\int_0^{\omega_{crit}} d\omega} = \frac{\int_0^{\omega_{crit}} |FI_{St}(j\omega)| d\omega}{\omega_{crit}} \quad (\text{Equação 4.5})$$

$$\mathbf{I}_{dMt} = \text{ganho}(G_P) \frac{\int_0^{\omega_{crit}} |FI_{dMt}(j\omega)| d\omega}{\omega_{crit}} = T/E \frac{\int_0^{\omega_{crit}} |FI_{dMt}(j\omega)| d\omega}{\omega_{crit}} \quad (\text{Equação 4.6})$$

Além disso, como o sistema descrito irá trabalhar com distúrbios conhecidos, uma variação da forma de cálculo de ambos os termos \mathbf{I}_{SO} é proposto através da Equação 4.7, que recomenda o cálculo do índice feito em um ponto específico do espectro de frequências (ω_{dist}),

correspondente àquela do distúrbio. Vale ressaltar que, semelhante ao feito no cálculo de I_{DM} , iremos inserir na fórmula o parâmetro T/D , que visa também a simetria entre os índices que representam o distúrbio e o erro do sistema. O cálculo aplicado encontra-se detalhado na equação 4.8, no qual os valores máximos de I_{St} e I_{So} são comparados para definir o valor de relação.

$$I_{So} = T/D * |FI_{So}(j\omega_{dist})| \quad (\text{Equação 4.7})$$

$$T/D = \frac{\max(I_{St})}{\max(I_{So})} = \frac{\max\left(\frac{\int_0^{\omega_{crit}} |FI_{St}(j\omega)| d\omega}{\omega_{crit}}\right)}{\max(|FI_{So}(j\omega_{dist})|)} \quad (\text{Equação 4.8})$$

As funções descritas podem ser aplicadas para o cenário SISO, no caso de distúrbio conhecido. Os índices são calculados exatamente como descritos, sendo que o valor obtido são escalares. Nesse caso, é simples relacioná-los com as metas, restando apenas a resolução do problema de otimização. Antes de promover as simulações na qual a metodologia será testada, será feito primeiramente alguns estudos que visam compreender o comportamento dos índices diante dos parâmetros R e Q e da resposta em frequência. Espera-se que os resultados permitam a compreensão de como a sintonia é promovida pelo método e possam ser utilizados para validá-lo.

Uma vez que o problema SISO apresenta poucos parâmetros e um design relativamente simples, a minimização do parâmetro FT e, conseqüentemente, a obtenção dos parâmetros de penalização pode ser feita utilizando o algoritmo de minimização “fmincon” do software MATLAB[®], que se apresenta como uma forma confiável de aplicar a otimização do sistema, sendo utilizado em outros projetos de sintonia de controladores MPC (Yamashita; Zanin et al., 2016). Para esse trabalho, foi utilizado o software MATLAB[®] versão R2018a.

4.2. Sistema MIMO

Nesse novo problema, a presença de várias variáveis de entrada e de saída proporcionam um aumento na complexidade do problema. No caso MIMO, deve-se considerar a forma como as variáveis de entrada são acopladas ao sistema e como as variáveis controladas são afetadas por essas, o que costuma se tornar consideravelmente difícil devido à não-linearidade e incerteza comumente presentes (ABDUL-ADHEEM; IBRAHEEM, 2019; Roy et al., 2019).

Considerando essas características do sistema MIMO, sugere-se que sejam feitas algumas alterações em relação ao problema SISO para acomodar as diferenças descritas.

4.2.1. Problema de sintonia para sistema MIMO

O cenário MIMO, devido ao fato de lidar com propriedades matriciais, não pode ser tratado igualmente como no contexto SISO. Por isso, para promover a conversão dos índices em formato escalar, é proposto a utilização da ferramenta SVD para mensurar a energia contida nas variáveis do processo. A Equação 4.9 exemplifica o cálculo do problema de sintonia para sistemas MIMO com n entradas e saídas, sendo σ os valores singulares da matriz obtida.

$$FT = \sum_{i=St,SO,dMt} \left(w_i * \left(\sum_{j=1}^n \sigma_j (\mathbf{I}_i - \mathbf{I}_i^*) \right)^2 \right) \quad (\text{Equação 4.9})$$

É comum que a quantificação da energia seja feita pela norma H_∞ , que é equivalente ao valor singular do processo de maior medida (Lam et al., 2015; Ahamad et al., 2017). Entretanto, esse método foi descartado uma vez que essa consideração pode resultar no desprezo de valores singulares de módulo absoluto próximo ao máximo, não representando uma medição adequada do conjunto de elementos do sistema.

4.2.2. Índice de estabilização (\mathbf{I}_{est})

Um dos maiores problemas do sistema MIMO é a dificuldade em sintonizar o controlador de forma que nenhuma variável seja priorizada em relação à outra. Ou seja, se o sistema tiver n variáveis controladas, a sintonia deveria garantir que cada uma delas sejam alteradas em intensidades e direção similares pelo controlador, sem favorecer a minimização de um erro específico de maneira diferente de outra.

Portanto, para atingir esse objetivo, foi proposta uma alteração na equação 4.2 através da inserção de um quarto índice de peso único igual, nomeado índice de estabilidade (\mathbf{I}_{est}). O novo cálculo da função FT que deverá ser minimizado pelo problema de sintonia é apresentado na equação 4.10.

$$FT = \sum_{i=St,SO,dMt} \left(w_i * \left(\sum_{j=1}^n \sigma_j (\mathbf{I}_i - \mathbf{I}_i^*) \right)^2 \right) + \mathbf{I}_{est}^2 \quad (\text{Equação 4.10})$$

Esse novo parâmetro deverá ser utilizado para comparar os estados de energia das variáveis de entrada e de saída tanto do controlador quanto do processo, calculadas pelas equações 3.19 e 3.20, para definir os valores adequados que garantem um comportamento padronizado do sistema. Os cálculos descritos pelas equações são realizados através dos vetores

singulares obtidos pela SVD das matrizes que representam a atuação do controlador e do processo.

Uma vez que o novo parâmetro objetiva o equilíbrio de potenciais entre as variáveis de saída e de entrada, cada um desses conjuntos deve ser analisado separadamente. No primeiro caso, tem-se que os valores dos erros das variáveis controladas deveriam impactar o comportamento do sistema em intensidades semelhantes entre si. Para garantir que esse objetivo seja atingido, pode-se utilizar a função de sensibilidade descrita na equação 4.11, que relaciona o erro com a saída do problema. Nessa, os termos U_{CP} , V_{CP} e S_{CP} representam as matrizes de vetores e valores singulares obtidas através da aplicação do método SVD na função de sensibilidade obtida.

$$\frac{y(s)}{e(s)} = G_C G_P = U_{CP} S_{CP} V_{CP} \quad (Eq. 4.11)$$

Aplicando a equação 3.20, pode-se obter os estados de energia dos erros na função de sensibilidade descrita (E_{UCP}), obtendo uma quantificação dos impactos de cada uma no sistema. O objetivo, nesse caso, seria garantir que os valores desses fossem idênticas entre si, proibindo que o sistema priorize uma variável controlada acima de outra. O índice de estabilidade é, então, concebido de forma a forçar esta igualdade, e o parâmetro \mathbf{I}_{est}^A é calculado pela equação 4.12, para ser posteriormente adicionado ao índice \mathbf{I}_{est} .

$$\begin{cases} \mathbf{I}_{est}^A = 10 * \left(\frac{\max(E_{u_{CP}})}{\min(E_{u_{CP}})} - 1 \right) - 0,2; & se \quad \frac{\max(E_{u_{CP}})}{\min(E_{u_{CP}})} \geq 1,02 \\ \mathbf{I}_{est}^A = 0; & se \quad \frac{\max(E_{u_{CP}})}{\min(E_{u_{CP}})} < 1,02 \end{cases} \quad (Eq. 4.12)$$

As variáveis manipuladas do processo também são avaliadas de forma a padronizar seu comportamento para atender o balanço do sistema. Porém, diferente das variáveis controladas, o impacto que cada entrada promove já é determinada pelo processo, sendo necessário alterar esse para balancear os estados de energia.

Para essa situação, é sugerido uma estratégia diferente: ao invés de forçar um esforço de controle similar entre as variáveis de entrada, deseja-se que a relação dos estados de energia das variáveis de entrada determinadas pelo controlador seja inversamente proporcional àquela do impacto de cada entrada. Em outras palavras, se E_{yC} define os estados de energia da saída do controlador (calculados aplicando a equação 3.19 na função de transferência do controlador),

e que E_{uP} define o mesmo, porém para a entrada do processo (calculados aplicando a equação 3.20 na função de transferência do processo), deseja-se que, para cada variável u_i e u_j distintas:

$$\frac{E_{y_{iC}}}{E_{y_{jC}}} = \frac{E_{u_{jP}}}{E_{u_{iP}}} \quad (\text{Equação 4.13})$$

O índice I_{est} é utilizado, então, para forçar que a equação 4.13 seja pelo menos parcialmente atendida, através da aplicação da equação 4.14:

$$\begin{cases} I_{\text{est}}^B = 10 * \left| \frac{E_{y_{iC}}/E_{y_{jC}}}{E_{u_{jP}}/E_{u_{iP}}} - 1 \right| - 0,2; & \text{se} \quad \left| \frac{E_{y_{iC}}/E_{y_{jC}}}{E_{u_{jP}}/E_{u_{iP}}} - 1 \right| \geq 0,02 \\ I_{\text{est}}^B = 0; & \text{se} \quad \left| \frac{E_{y_{iC}}/E_{y_{jC}}}{E_{u_{jP}}/E_{u_{iP}}} - 1 \right| < 0,02 \end{cases} \quad (\text{Eq. 4.14})$$

O valor final do índice de estabilidade é calculado pela soma de ambos os valores obtidos através das equações 4.12 e 4.14, sendo então inserido no problema geral de forma a garantir que sua minimização incentivará a estabilização das variáveis múltiplas presentes no sistema. Equação 4.15 descreve o cálculo final do índice em questão.

$$I_{\text{est}} = I_{\text{est}}^A + I_{\text{est}}^B \quad (\text{Equação 4.15})$$

4.2.3. Minimização utilizando a otimização por enxame de partículas.

Por causa da complexidade do problema MIMO, a aplicação da minimização do sistema aplicando o comando “fmincon”, assim como promovido no caso SISO torna-se pouco confiável. Nesse caso, o problema é solucionado utilizando a técnica da otimização por enxame de partículas, que ao invés de analisar a minimização de um único ponto, analisa o comportamento de uma população de dados, o que permite-o a superar obstáculos geralmente presenciados em métodos mais simples, como mínimos locais.

O método tem encontrado aplicações na sintonia de controladores MPC, atuando não apenas em parâmetros de penalização (Derouiche et al., 2016), mas também no problema de otimização relacionado à minimização da função custo (Rajabi et al., 2016).

5. SIMULAÇÃO DO PROCESSO (METODOLOGIA)

5.1. Caso SISO

Antes de promover a sintonia do caso SISO descrito nessa seção, é importante notar que esse será utilizado anteriormente para a realização de uma análise de magnitude e estabilidade dos índices da metodologia proposta em função da frequência. O objetivo desse procedimento é facilitar a compreensão do comportamento destes parâmetros em relação ao estado do sistema, especialmente no caso do índice I_{S0} , cujo resultado dependerá do valor da frequência de oscilação do distúrbio presente.

Cada modelo aplicado no projeto foi obtido a partir da simulação de um problema característico no campo da engenharia química. No caso SISO, será imaginado o controle do nível de um tanque CSTR, sendo que a variável manipulada será a válvula de abertura da tubulação de saída. A relação entre parâmetros de entrada e saída do processo pode ser exemplificado pela Equação 5.1, na qual L é a altura do conteúdo, F_o a vazão de entrada, A é a área da seção transversal do reator cilíndrico, g é a gravidade e C_v é a abertura da válvula.

$$\frac{dL}{dt} = \frac{1}{A} F_o - \frac{C_v \sqrt{g}}{A} L^{\frac{1}{2}} \quad (\text{Equação 5.1})$$

O modelo obtido pode ser simulado para obter uma função de transferência que represente o sistema, sendo que, nesse caso, a Equação 5.2 é obtida para um processo no qual o valor de C_v varia entre 0 e 100%, e o nível do tanque L está necessariamente contido no intervalo de 0 a 1,4 metros. É possível notar que as dimensões da variável controlada e manipulada não são as mesmas. Como é desejado que a metodologia trabalhe com proporções similares, principalmente na realização da sintonia, será feito o escalonamento de todas as variáveis, de forma que elas possam ser descritas em porcentagem. Nesse caso, o sistema será descrito pela Equação 5.3, que relaciona os elementos do problema em porcentagens.

$$G_P(s) = \frac{-0,0354}{8,69s + 1} \left[m/\% \right] \quad (\text{Equação 5.2})$$

$$G_P(s) = \frac{-0,0354}{8,69s + 1} * \frac{(100 - 0)\%}{(1,4 - 0)m} = \frac{-2,586}{8,69s + 1} \left[\%/ \% \right] \quad (\text{Equação 5.3})$$

Na determinação do desenvolvimento da curva de referência, optou-se por uma tendência exponencial, seguindo algo similar à uma função de primeira ordem. Esse conceito tem sido empregado em trabalhos anteriores e tem mostrado um aumento em eficiência e

desempenho de processos (YAMASHITA ET AL., 2016). O distúrbio aplicado no sistema é descrito pela Equação 5.4 e seu comportamento, oscilatório, apresentado na Equação 5.5. Nesse, a frequência do sistema é ω .

$$G_d(s) = \frac{1,5}{10s + 1} \left[\frac{\%}{\%} \right] \quad (\text{Equação 5.4})$$

$$d(t) = 50 * \sin(\omega t) \quad (\text{Equação 5.5})$$

A Tabela 5.1, nesse caso, descreve o cenário físico aplicado para o processo descrito, sendo que t_{est} é o tempo de estabilização da curva de referência (tempo aproximado para atingir 95% da alteração desejada) e t_{sim} é o tempo total da simulação.

Tabela 5.1 – Cenário de simulação do sistema SISO.

Alteração dos parâmetros de referência com o tempo					
Tempo (min)	0	24	136	200	400
Referência (m)	1,1	0,9	1,0	1,25	1,0
Parâmetros de referência e distúrbio					
$\omega=0,05 \text{ (min}^{-1}\text{)}; t_{est} = 24 \text{ min}; t_{sim}=504 \text{ min};$					
Parâmetros do controlador					
$H_C=15; H_P=10; T_S=8 \text{ min};$					

As simulações são repetidas utilizando quantidades diferentes para os parâmetros de penalização da metodologia de sintonia do controlador, visando identificar as divergências nos comportamentos apresentados. Porém, os valores da Tabela 5.1 são mantidos constantes em todos os cenários.

5.2. Caso MIMO

Para o caso MIMO, o problema a ser solucionado foi inspirado em um sistema contendo um reator CSTR encamisado na qual ocorre uma reação irreversível de primeira ordem, descrito na referência (BAHITA; BELARBI, 2016). Os dados encontram-se detalhados na Tabela 5.2:

Tabela 5.2 – Cenário de operação do reator CSTR encamisado.

Parâmetros	Descrição	Valor nominal
V	Volume do Reator	100 m ³
C _{inA}	Concentração inicial do reagente	1 mol/L
E _{A/R}	Energia de Ativação	8*10 ³ K
k _o	Velocidade da reação	7,2*10 ¹⁰ min ⁻¹
T _{inA}	Temperatura de entrada do reagente	350 K
T _{jo}	Temperatura de entrada do refrigerante	250 K
ΔH	Calor de reação	-2*10 ⁵ cal / mol
C _p , C _{pC}	Capacidades caloríficas	1 cal/(g*K)
ρ, ρ _C	Densidades	10 ³ g/L
h _A	Coeficiente de transferência de calor	7*10 ⁵ cal/(min*K)

No caso descrito, os objetos de controle são a concentração do reagente A (C_A) e a temperatura no reator (T), sendo que as variáveis manipuladas são as vazões de entrada no tanque (F_{inA}) e na camisa (F_{jo}). O modelo matemático do sistema envolve os balanços de massa em função do componente A e de energia global, detalhados pelas Equações 5.6 e 5.7:

$$\frac{dC_A}{dt} = \frac{F_{inA}(t)}{V} [C_{inA}(t) - C_A(t)] - k_o C_A(t) \exp\left[\frac{-E_A}{RT(t)}\right] \quad (\text{Equação 5.6})$$

$$\begin{aligned} \frac{dT}{dt} = & \frac{F_{inA}(t)}{V} [T_o(t) - T(t)] - \frac{(-\Delta H)k_o}{\rho C_p} C_A(t) \exp\left[\frac{-E_A}{RT(t)}\right] \\ & + \frac{\rho_C C_{pC}}{V \rho C_p} F_{jo}(t) \left[1 - \exp\left(\frac{-h_A}{F_j(t) \rho_C C_{pC}}\right)\right] [T_{jo}(t) - T(t)] \end{aligned} \quad (\text{Equação 5.7})$$

O cenário descrito é simulado na extensão Simulink[®] do software MATLAB[®] para obtenção das funções de transferência a partir da linearização do sistema utilizando variações degrau, e o modelo do sistema não escalonado é exemplificado pela matriz descrita na Equação 5.8, na qual a ordem das variáveis é concentração e temperatura do reator no caso das controladas, e vazão do tanque e da camisa para as manipuladas. Já o distúrbio do processo apresenta a função de transferência representada na Equação 5.9 e o comportamento apresentado pela Equação 5.10:

$$G_p(s) = \begin{bmatrix} G_{11} & G_{12} \\ G_{21} & G_{22} \end{bmatrix}$$

$$\left\{ \begin{array}{l} G_{11} = 0,514 * \frac{8,58 * 10^{-3} s^2 + 0,284s + 1}{1,18 * 10^{-2} s^3 + 0,223s^2 + 1,022s + 1} \\ G_{12} = 4,38 * 10^{-3} * \frac{0,865s^2 - 0,135s + 1}{1,18 * 10^{-2} s^3 + 0,223s^2 + 1,022s + 1} \\ G_{21} = 0,467 * \frac{6,18 * 10^{-2} s^2 + 0,88s + 1}{1,18 * 10^{-2} s^3 + 0,223s^2 + 1,022s + 1} \\ G_{22} = -0,506 * \frac{5,70 * 10^{-2} s^2 + 0,818s + 1}{1,18 * 10^{-2} s^3 + 0,223s^2 + 1,022s + 1} \end{array} \right. \quad (\text{Equação 5.8})$$

$$G_d(s) = \begin{bmatrix} \frac{0,003}{10s + 1} \\ \frac{1,5}{8s + 1} \end{bmatrix} \quad (\text{Equação 5.9})$$

$$d(t) = 3 * \sin(\omega t) \quad (\text{Equação 5.10})$$

Pode-se então descrever o cenário de simulação do sistema através da Tabela 5.3, utilizando o mesmo conceito aplicado na formulação da tabela anterior.

Tabela 5.3 – Cenário de simulação do sistema MIMO.

Alteração dos parâmetros de referência com o tempo (1=Concentração; 2=Temperatura)											
Tempo (min)	0	300	330	500	550	750	900	1100	1200	1350	1450
Referência 1 (mol/L)	0,88	0,88	0,92	0,92	0,83	0,83	0,96	0,96	0,96	0,85	0,89
Referência 2 (K)	290	305	305	275	275	300	300	265	310	275	275
Parâmetros de referência e distúrbio											
$\omega=0,05 \text{ (min}^{-1}\text{)}; t_{\text{est}1} = t_{\text{est}2}=60 \text{ min}; t_{\text{sim}}=1500 \text{ min};$											
Parâmetros do controlador											
$H_C=3; H_P=2; T_S=5 \text{ min};$											

Mais uma vez, as simulações são repetidas variando apenas os valores dos parâmetros de penalização da função FT , visando mensurar o impacto de cada uma no sistema. Essa etapa ainda está para ser completada e, portanto, não apresenta resultados disponíveis no momento.

6. RESULTADOS E DISCUSSÕES

6.1. Caso SISO

O cenário SISO será utilizado para verificar se a aplicação dos índices na metodologia proposta promove os resultados esperado. A partir da confirmação desses dados, é possível iniciar o processo de sintonia de um controlador mais complexo, como será utilizado no caso MIMO.

6.1.1. Análise dos índices e diagramas de Bode:

Antes de promover a simulação do caso SISO, esse será utilizado de forma a validar e compreender o comportamento da metodologia de sintonia diante de alterações nos parâmetros Q e R . Nesse caso, primeiramente será estudado a magnitude e a resposta em frequência dos índices que representam as funções de sensibilidade utilizadas pelo método

No caso da magnitude, pode-se obter uma visualização gráfica de como os índices atuam na sintonia do sistema através de um gráfico destacando a relação entre esses e os parâmetros de penalização R e Q . O sistema SISO com um distúrbio definido descrito em seguida pode ser utilizado para atingir esse objetivo.

$$\begin{cases} G_p(s) = \frac{-2,586}{8,69s + 1} \\ G_d(s) = \frac{1,5}{10s + 1} \end{cases}$$

Primeiramente, é possível comparar o efeito das matrizes de penalização no valor final de cada índice. Nas figuras 6.1 até 6.4, foram feitos cálculos da diferença entre cada um dos índices isolados e seus valores de meta em função dos parâmetros R e Q , detalhados em gráficos tridimensionais.




Figura 6.1 – Valor do índice I_{st} em relação aos parâmetros de penalização R e Q .

Na figura 6.1, percebe-se que o índice I_{st} é diminuído com o aumento do parâmetro Q e a redução do R , sendo que seu objetivo é quantificar o erro natural apresentado pelo sistema. Nesse caso, quando o índice I_{st} é minimizado, ele prioriza a penalização do erro, através do incremento do parâmetro Q , e menospreza aquele relacionado ao esforço de controle, decrementando o parâmetro R .




Figura 6.2 – Valor do índice I_{dmt} em relação aos parâmetros de penalização R e Q .

Por outro lado, na figura 6.2 o contrário é observado, pois o índice I_{dmt} , que em contraste ao I_{st} , prioriza o esforço de controle, é minimizado com o aumento do parâmetro R e a

diminuição de Q , forçando o sistema a apresentar uma consideração maior para a variação das variáveis de entrada.




Figura 6.3 – Valor do índice I_{s0} em relação aos parâmetros R e Q ($\omega=0,1$ rad/s).




Figura 6.4 – Valor do índice I_{s0} em relação aos parâmetros R e Q ($\omega=0,37$ rad/s).

Embora os outros índices tenham mantido uma relação trivial com os parâmetros de penalização, I_{s0} apresenta uma relação única. Uma vez que esse considera o impacto do distúrbio tanto no erro quanto no esforço do controlador, sua relação com as variáveis R e Q dependerá exclusivamente da forma como essa atua no sistema.

Na figura 6.3, percebe-se que o índice I_{s_0} atua em favor da minimização do erro, aumentando o parâmetro Q para minimizar o valor da função FT . Porém, na figura 6.4, o contrário é observado, e a minimização do esforço se torna a nova prioridade do índice. A única diferença entre as duas simulações foi o valor da frequência do distúrbio, mostrando como esse desempenhará um papel fundamental na forma como a metodologia deverá desempenhar a sintonia do problema.

Uma vez compreendido a forma como a magnitude é alterada durante a sintonia, foram obtidos os diagramas de Bode de cada um dos índices relacionados com a metodologia. Essa análise é feita para detalhar o comportamento dos índices com os diversos valores de frequência, além de providenciar a informação necessária para que a tendência promovida pela minimização desses indicadores seja esclarecida. As figuras 6.5 até 6.8 resumem os resultados obtidos. Nesses gráficos, foram traçadas quatro curvas de resposta em frequência, sendo que cada uma representa uma configuração dos parâmetros de penalização na qual Q foi mantido em um valor constante e R foi alterado:




Figura 6.5 – Diagrama de Bode para o índice I_{st} .

A figura 6.5 detalha a forma como o índice de minimização do erro se comporta com a frequência. Como visto antes, o valor desejado para esse é de um (ou zero decibéis), o que o sistema apresenta para frequências baixas. Para valores maiores, porém, o índice se afasta do set-point, indicando um afastamento entre os valores de saída e de referência. Percebe-se,

também, que a curva se mantém mais próxima do valor desejado quanto maior for Q em relação a R , assim como era esperado, uma vez que o primeiro prioriza a penalização do erro no sistema.




Figura 6.6 – Diagrama de Bode para o índice I_{dMt} .

Na figura 6.6, percebe-se que um comportamento semelhante ao do índice de minimização do erro é apresentado. Porém, diferente desse, o parâmetro I_{dMt} , cujo objetivo é ser o menor possível, aumenta em magnitude com o aumento da frequência, e apresenta resultados melhores quando o parâmetro R é maior que Q , assim como é perceptível analisando o diagrama para valores de frequência maiores.

Os diagramas de Bode para o parâmetro I_{s0} , diferente daqueles apresentados pelos outros índices, mostraram que o comportamento desse não segue uma lógica contínua. Tanto na figura 6.7, relacionada ao afastamento do set-point, quanto a seguinte, que quantifica o esforço adicionado pelo distúrbio, aumentam com a frequência até um determinado ponto, a partir da qual iniciam uma redução de magnitude.




Figura 6.7 – Diagrama de Bode para o índice IS_0^A (relacionado ao erro).




Figura 6.8 – Diagrama de Bode para o índice IS_0^B (relacionado ao esforço).

Análises adicionais mostram que esse comportamento condiz com a realidade do sistema, como é possível ver na figura 6.9, que resume simulações feitas mantendo-se a referência constante e aplicando a mesma configuração, alterando-se apenas a frequência do distúrbio presente. A tabela 6.1 resume os resultados mostrados na imagem mostrando os valores da integral do quadrado do erro (*ISE*), da *ISV* (*Integral Square Variation*), cujo cálculo encontra-se descrito na equação 6.1, além dos parâmetros R e Q aplicados.

$$ISV = \int_0^{t_{sim}} \Delta u^2 dt = \sum_{i=1}^{t_{sim}/T_S} T_S * \Delta u_i^2 \quad (\text{Equação 6.1})$$

Tabela 6.1 – Resultados das simulações com distúrbios de frequências diferentes.

Parâmetros	Simulação 1	Simulação 2	Simulação 3	Simulação 4
R	9998,89			
Q	516,84			
Frequência	0,01	0,1	0,25	0,37
ISE	0,61	15,75	7,89	5,99
ISV	0,06	1,96	2,01	1,81




Figura 6.9 – Comportamento da variável controlada diante de distúrbios com frequências diferentes.

Os resultados mostram como o erro do sistema apresenta-se mais significativo em um ponto específico (frequência = 0,1) ao invés de apresentar um acréscimo ou decréscimo característico, o que condiz com o comportamento ressaltado pelo diagrama de Bode do parâmetro I_{s0} . Isso prova que o índice apresenta uma representação adequada do efeito que o distúrbio aplica no sistema, e pode servir de base para determinar valores de sintonia desejados para os parâmetros de penalização do controlador.

6.1.2. Índice do erro (I_{St}):

Nessa seção, será analisado se o índice atinge a meta de promover a minimização do erro. Nesse caso, após realizar a simulação utilizando o valor de $w_{ST}=1$ e os valores $w_{SO}=w_{DM}=0$, será comparado o resultado obtido com aquela de uma simulação padrão ($R=Q=1$). Vale ressaltar que para as simulações dessa seção, a sintonia foi obtida utilizando o comando “fmincon” atuando com uma restrição para obtenção de valores entre 10^{-3} e 10^4 .

Os resultados detalhados nas figuras 6.10 e 6.11 demonstram que, com a ativação do índice de minimização do erro, o sistema foi capaz de operar de acordo com a referência, apresentando o comportamento esperado. Para avaliar o método mais detalhadamente, a Tabela 6.2 mostra os valores da integral do quadrado do erro (ISE), além dos parâmetros Q e R .




Figura 6.10 – Comportamento do sistema para $R=Q=1$.




Figura 6.11 – Resposta do sistema sintonizado para $w_{St}=1$.

Tabela 6.2 – Resultados comparativos da simulação antes e após minimização do erro.

Parâmetros	Simulação Padrão	Sintonia para $w_{St}=1$
R	1	0,991
Q	1	9999,01
ISE	24,729	$2*10^{-6}$

Ao ativar o parâmetro w_{St} na sintonia, o sistema promove a redução do erro ao priorizar a sua penalização, assim como demonstrado com o aumento do parâmetro Q e da minimização do ISE , provando a atuação esperada do método sob as condições descritas.

6.1.3. Índice do esforço (I_{dmt}):

Serão comparadas as respostas da simulação obtidas para valores de w_{dMt} de 0, 0,25, 0,5, 1 e 3, sendo que o valor de w_{ST} será 1 e de w_{SO} é 0 em todos os casos, exceto no último, onde apenas o índice do esforço será considerado na sintonia. Os resultados dessa comparação estão presentes na Tabela 6.3.

Tabela 6.3 – Resultados comparativos da simulação com diferentes valores de w_{dMt} .

Simulação	R	Q	ISE	ISV
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0]$	0,991	9999,010	$2 \cdot 10^{-6}$	147,466
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,25]$	9995,398	1758,290	96,223	28,952
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,5]$	9986,574	738,236	172,840	20,270
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 1]$	9998,375	299,706	309,124	13,915
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 3]$	9996,884	66,865	789,356	7,125
$[w_{ST}; w_{SO}; w_{dMt}] = [0; 0; 1]$	9998,533	0,008	5948,759	$4 \cdot 10^{-6}$

Os resultados nos permitem afirmar que a inclinação do índice em minimizar o esforço promovido pelo sistema foi satisfeita com o incremento do parâmetro w_{dMt} , através de uma redução consistente do módulo de ISV. Porém, deve-se também analisar se a relação entre os parâmetros I_{St} e I_{dMt} estão devidamente padronizados, garantindo a praticidade do uso da metodologia. Nesse caso, pode-se comparar os valores de *ISE* e *ISV* em cada simulação com os valores obtidos para esses nos casos onde a minimização do erro e do esforço, respectivamente, foram completamente desprezados (ou seja, no caso do erro, na simulação onde $w_{St}=0$, e no caso do esforço, $w_{dMt}=0$). A tabela 6.3 mostra os valores obtidos para essa comparação:

Tabela 6.4 – análise relativa da simulação com diferentes valores de w_{dMt} .

Valores máximos de <i>ISE</i> e <i>ISV</i>		
ISE	5948,759	
ISV	147,466	
Simulação	ISE (% valor máximo)	ISV (% valor máximo)
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,25]$	1,62	19,63
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,5]$	2,91	13,75
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 1]$	5,20	9,44
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 3]$	13,27	4,83

O resultado mostra que para a sintonia com importância iguais para a minimização do erro e do esforço resultou em valores relativos de *ISE* e *ISV* próximos um do outro, simbolizando que ambas as ações estão sendo consideradas pelo método de forma similar. Isso indica que o objetivo de manter uma padronização nos parâmetros de penalização no problema

de sintonia, facilitando a interação com o usuário, aparenta estar sendo respeitada pela metodologia.

Para possibilitar o paralelo visual, a Figura 6.12 relata a resposta obtida pelo sistema após a sintonia no cenário com maior penalização do esforço ($w_{dMt}=3$), sendo que na Figura 6.13 é mostrado uma comparação entre este e o comportamento resultado da utilização única do índice do erro. Nesse, é possível notar a redução na intensidade de variação com o aumento do peso w_{dMt} , facilmente visualizada ao atentar-se para a amplitudes dos picos gerados.




Figura 6.12 –Resposta do sistema sintonizado para o cenário $[w_{ST}, w_{S0}, w_{dMt}] = [1; 0; 3]$.

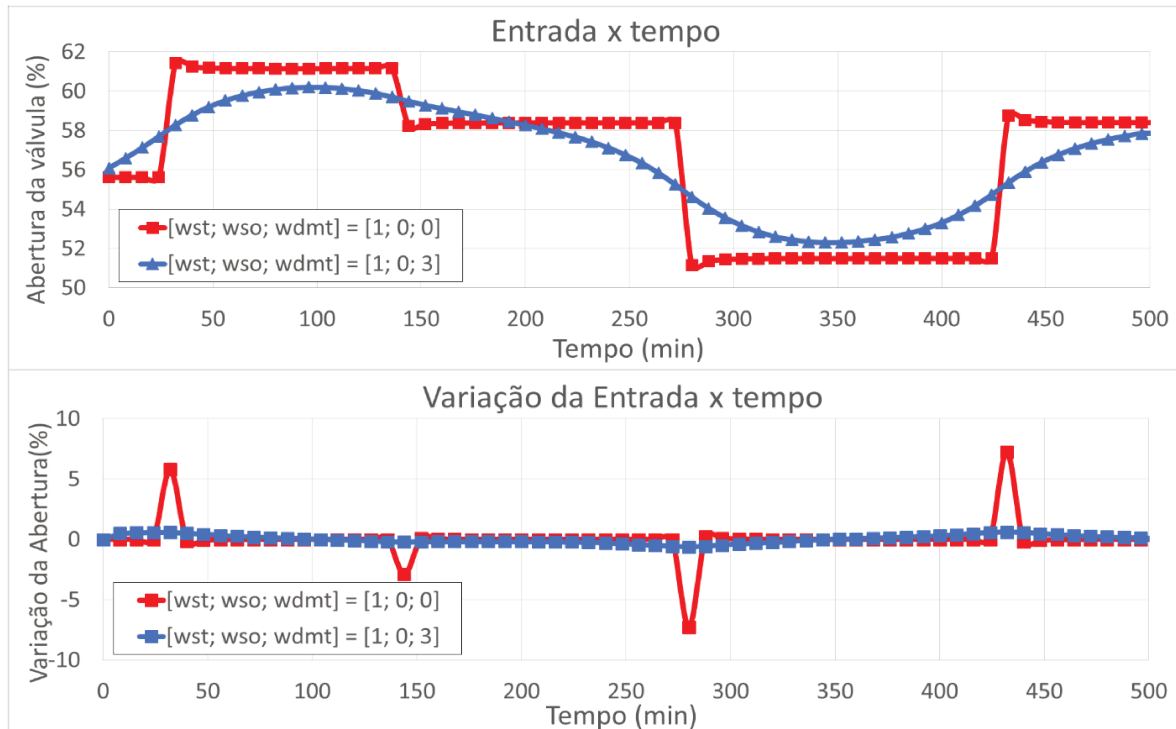


Figura 6.13 – Variação do valor e da variação da entrada do sistema em função do tempo para os cenários $[w_{st}, w_{so}, w_{dm}] = [1; 0; 0]$ e $[w_{st}, w_{so}, w_{dm}] = [1; 0; 3]$.

6.1.4. Índice de rejeição de distúrbio

Por último, será verificado o índice de rejeição de distúrbios. O conceito desse é de promover a melhoria do sistema sob a influência do problema servo e regulatório simultaneamente, favorecendo a minimização do erro ou do esforço, dependendo de qual promover a melhor minimização. Nesse sentido, será aplicado ao sistema diferentes valores de frequência no qual o distúrbio atuará e será verificado o seu impacto nos parâmetros ISE e ISV . Espera-se que aquele que for relativamente mais afetado seja a prioridade da minimização do índice I_{SO} .

Todas as simulações serão feitas com os parâmetros w_{St} e w_{dMt} iguais à um. Para cada frequência descrita na seção 6.1.1 (frequências de 0,01/ 0,1/ 0,25/ 0,37), serão feitas duas sintonias, uma considerando o peso $w_{SO}=1$, e outra considerando-o nulo. Espera-se que a introdução do índice I_{SO} promova uma melhoria relativa em um dos parâmetros (erro ou esforço) melhor que o comprometimento relativo causado no segundo. Em outras palavras, espera-se que o decréscimo relativo de um desses seja maior que o acréscimo relativo causado no outro.

A Tabela 6.4 demonstra detalhadamente os resultados obtidos nas simulações. É possível verificar que o índice foi capaz de promover uma melhoria em todos os casos aplicados, sendo capaz de auxiliar o parâmetro mais comprometido pelo distúrbio sem

promover uma alteração de intensidade similar ou maior no outro. Isso é confirmado uma vez que em todos os casos, o decréscimo de uma das variáveis (*ISE* e *ISV*) superou o acréscimo causado no segundo.

Tabela 6.5 – Resultados comparativos da simulação com diferentes valores e estratégias de w_{s0} .

Frequência	ISE (antes / após inserção de I_{s0})	ISV (antes / após inserção de I_{s0})	Variação ISE (%)	Variação ISV (%)
0,01	760,539 / 672,276	36,633 / 37,796	-11,61	+3,17
0,1	6264,687 / 6524,353	375,223 / 343,758	+4,14	-8,39
0,25	2873,464 / 3324,097	379,372 / 226,869	+15,68	-40,20
0,37	2167,522 / 2602,853	342,338 / 187,832	+20,08	-45,13

6.2. Caso MIMO

No caso do cenário MIMO, serão avaliados a capacidade do método ao ser aplicado em sistemas multivariáveis e como esse se comporta diante de problemas mais complexos, focando na determinação da eficiência e capacidade em atuar de maneira semelhante em todas as variáveis do processo.

A presença de distúrbio no sistema será considerada apenas nas simulações envolvendo o estudo do índice I_{s0} , sendo que nas demais, o sistema atua sem presença de perturbações externas, visando destacar o comportamento demais. Uma vez que a capacidade da metodologia em trabalhar com os limites do método de otimização foi observada no caso SISO, nesse cenário o algoritmo de minimização por enxame de partículas trabalhará com um limite mais restrito, sendo que os valores dos parâmetros são limitados para valores entre 1 e 500.

6.2.1. Atuação individual dos índices (desconsiderando distúrbio)

Primeiramente, foram aplicados a metodologia de sintonia para o caso MIMO aplicando os índices de minimização do erro (I_{st}) e do esforço (I_{amt}) isoladamente. Esperava-se que tal sintonia forçasse os parâmetros R e Q aos seus valores máximos ou mínimos dependendo do objetivo do índice. As figuras 6.14 e 6.15 mostram os resultados obtidos nessa etapa:




Figura 6.14 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{SO}, w_{AMt}] = [1; 0; 0]$.




Figura 6.15 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{SO}, w_{AMt}] = [0; 0; 1]$.

A partir das figuras, é possível confirmar que cada índice promoveu seu objetivo. No caso da sintonia com o índice I_{St} , nota-se que ambas as variáveis controladas se comportaram de maneira praticamente igual à curva de referência, exemplificando a minimização do erro, enquanto no segundo caso, o esforço foi reduzido de forma que a variação das manipuladas se encontrava em uma ordem desprezível em comparação ao primeiro cenário, demonstrando como o parâmetro I_{AMt} atuou da forma esperada.

Na tabela 6.5 encontram-se detalhados os resultados obtidos na simulação de ambos os casos, destacando como a sintonia resultou nos valores extremos determinados para as variáveis R e Q, assim como esperava-se que fosse feito, na minimização do erro. Para o caso de redução do esforço, porém, os valores de R não atingiram o valor de 500. Mesmo assim, a razão para tal evento encontra-se no fato de que o parâmetro FT atingiu valores menores que a precisão do simulador, explicando o resultado encontrado.

Tabela 6.6 – Resultados das simulações aplicando os índices individualmente.

Simulação	R	Q	ISE	ISV	FT
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0]$	[0,01; 0,01]	[500; 500]	[0,00002; 0,00004]	[196,55; 2617,52]	0,690
$[w_{ST}; w_{SO}; w_{dMt}] = [0; 0; 1]$	[415,76; 410,16]	[0,01; 0,01]	[21315,33; 10256,88]	[0,00003; 0,00000]	0,000

6.2.2. Sintonia híbrida (I_{st} e I_{dMt}) utilizando índice de estabilidade (I_{est}).

A seguinte seção tem como objetivo avaliar a capacidade da metodologia em proporcionar uma sintonia que abrange tanto a minimização do erro quanto a do esforço, de maneira equilibrada em relação às múltiplas variáveis do sistema e intuitiva em relação à aplicação dos parâmetros de penalização. A tabela 6.6 resume os resultados obtidos nas simulações realizadas:

Tabela 6.7 – Resultados das simulações sem distúrbio.

Simulação	R	Q	ISE	ISV	FT
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,25]$	[0,01; 77,21]	[101,91; 456,11]	[192,11; 142,65]	[250,26; 1228,43]	1,699
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 0,5]$	[4,92; 108,22]	[103,03; 452,10]	[344,74; 259,54]	[227,48; 1049,73]	1,980
$[w_{ST}; w_{SO}; w_{dMt}] = [1; 0; 1]$	[6,98; 133,44]	[116,66; 500,00]	[394,72; 310,56]	[223,74; 993,74]	2,298
$[w_{ST}; w_{SO}; w_{dMt}] = [0,5; 0; 1]$	[42,17; 300,44]	[124,23; 499,86]	[1108,30; 981,11]	[199,58; 567,80]	1,364
$[w_{ST}; w_{SO}; w_{dMt}] = [0,25; 0; 1]$	[108,17; 499,54]	[84,60; 324,52]	[2293,40; 2385,33]	[179,14; 200,18]	0,781

Os resultados mostram que o comportamento da metodologia atingiu vários pontos desejados. Em relação à performance, nota-se o aumento da relação entre minimização do erro em relação ao esforço promove aumento nos parâmetros Q e redução de R , ocasionando em uma diminuição do ISE e incremento do ISV .

Em relação ao índice de estabilização (I_{est}), tem-se que seu trabalho foi notável em relação às variáveis controladas, podendo ser percebido uma similaridade profunda entre os valores de ISE obtidos tanto para y_1 quanto para y_2 em todas as simulações feitas. Em relação às manipuladas, é possível perceber que a influência de u_1 sobre o sistema é maior que de u_2 . Isso é explicado quando se leva em conta que as entradas impactam o sistema com intensidades distintas, e que o índice leva esse fato em consideração na hora de promover a sintonia.

Para melhor visualização, observa-se os valores dos estados de energia para as variáveis de entrada da função de transferência do processo. Nesse caso, observamos os seguintes valores:

$$E_{u_1} = 0,5405$$

$$E_{u_2} = 0,1751$$

O resultado revela que a primeira entrada possui um impacto maior no sistema em relação à segunda, indicando que, caso essas sofressem uma variação idêntica nos seus valores, a primeira apresentaria um impacto maior nas variáveis de saída do processo. Isso significa que a segunda variável teria que, logicamente, apresentar um esforço de controle maior para apresentar a mesma performance, o que foi observado nos resultados obtidos na sintonia através do parâmetro ISV_2 .

As figuras 6.16 a 6.20 demonstram os resultados gráficos das simulações descritas na tabela 6.6, sendo perceptível no conjunto dessas como a relação dos parâmetros de penalização afetam a sintonia apresentada pelo sistema.




Figura 6.16 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{S0}, w_{dMt}] = [0,25; 0; 1]$.




Figura 6.17 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{S0}, w_{dMt}] = [0,5; 0; 1]$.




Figura 6.18 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{S0}, w_{dMt}] = [1; 0; 1]$.




Figura 6.19 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{S0}, w_{dMt}] = [1; 0; 0,5]$.




Figura 6.20 – Resposta do sistema MIMO para o cenário $[w_{ST}, w_{SO}, w_{dMt}] = [1; 0; 0,25]$.

6.2.3. Sintonia completa com distúrbio presente:

Por último, é realizado a sintonia do sistema com a introdução do problema servo. Nesse caso, o funcionamento do índice I_{S0} será avaliado para o caso MIMO, sendo que se espera que esse promova a suavização na variação dos parâmetros mais afetados pelo distúrbio. Assim como no caso anterior, a sintonia será realizada para quatro valores de frequências diferentes, e os resultados são exemplificados nessa seção.

Primeiramente, a configuração obtida na seção anterior para os pesos de $[w_{ST}, w_{SO}, w_{dMt}] = [1; 0; 1]$ foi reaplicada para os cenários com distúrbio em todas as frequências estudadas. Os resultados são simplificados na tabela 6.7, na qual são comparados os valores de ISE e ISV obtidos com aqueles resumidos no caso sem problema regulatório.

Tabela 6.8 – Comparação entre a performance dos sistemas com e sem distúrbio.

Frequência (ω)	ISE	ISV	Incremento [ISE_1/ISE_2 ; ISV_1/ISV_2]
Sem distúrbio	[394,72; 310,56]	[223,74; 993,74]	[0/0; 0/0]
$\omega = 0,01$	[485,22; 382,52]	[232,86; 1204,36]	[90,50/71,96; 9,12/210,62]
$\omega = 0,1$	[478,76; 382,96]	[585,58; 1211,03]	[84,04/72,40; 361,84/217,29]
$\omega = 0,25$	[432,41; 347,87]	[1023,52; 1175,19]	[37,69/37,31; 799,78/ 181,45]
$\omega = 0,37$	[414,78; 333,03]	[1022,74; 1143,40]	[20,06/22,47; 799/149,66]

A partir desses resultados, pode-se fazer alguns paralelos em relação ao observado no caso SISO. Por exemplo, pode-se notar que os valores de *ISE* sofrem um aumento significativo com a adição do distúrbio, mas acabam diminuindo com o aumento de ω_{dist} . Por outro lado, os valores de *ISV* variam para as duas variáveis de entrada. No caso da primeira, apenas aumenta, e para a segunda, apresenta um pico para a frequência de $\omega=0,1$.

Com isso em mente, foram realizados a sintonia do sistema considerando todos os pesos em intensidades iguais (i.e. $[w_{ST}, w_{SO}, w_{dM}] = [1; 1; 1]$) para definir a performance do índice de distúrbio. Os resultados são detalhados nas figuras 6.21 até 6.24, descrevendo o comportamento das sintonias realizadas para cada frequência de distúrbio. Em conjunto com os gráficos, as tabelas 6.8 e 6.9 demonstram uma descrição dos principais resultados adquiridos:




Figura 6.21 – Resposta da sintonia do sistema para $\omega = 0,01$.




Figura 6.22 – Resposta da sintonia do sistema para $\omega = 0,1$.

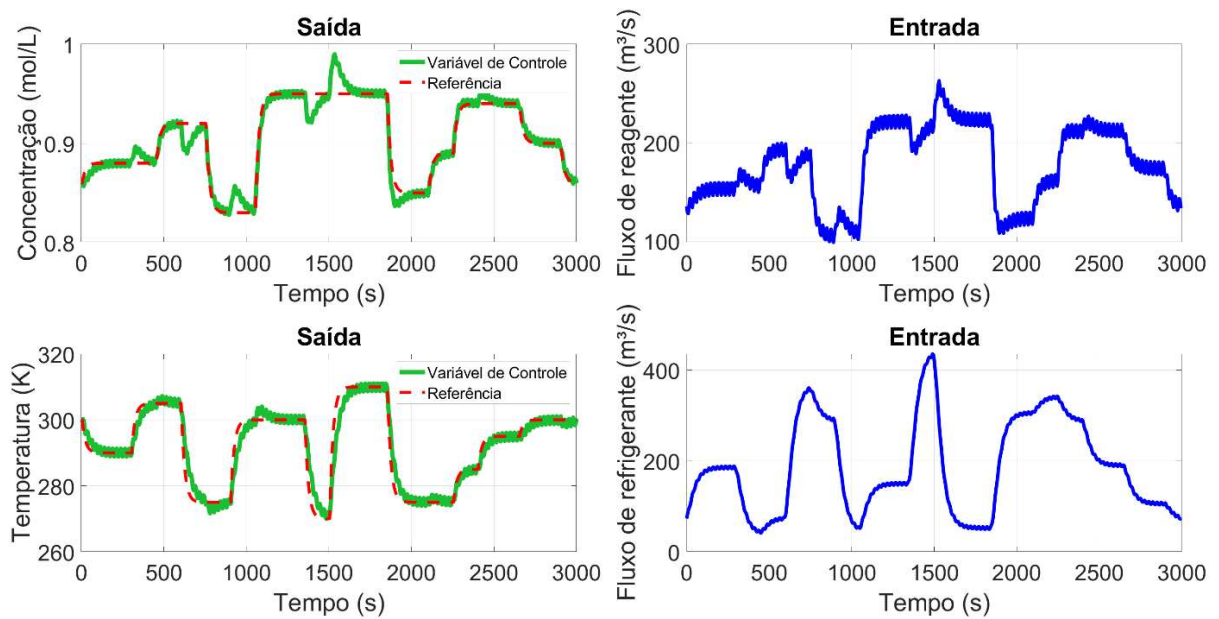


Figura 6.23 – Resposta da sintonia do sistema para $\omega = 0,25$.




Figura 6.24 – Resposta da sintonia do sistema para $\omega = 0,37$.

Tabela 6.9 – Valores de sintonia para os casos simulados.

Frequência (ω)	R	Q	Varição em % [R ₁ / R ₂ ; Q ₁ / Q ₂]
Sem distúrbio	[6,98; 133,44]	[116,66; 500,00]	[0/0; 0/0]
$\omega = 0,01$	[5,43; 123,34]	[115,04; 496,22]	[-22,21%/-7,57%; -1,38%/-0,76%]
$\omega = 0,1$	[9,53; 147,84]	[117,00; 496,66]	[36,53%/10,79%; 0,29%/-0,67%]
$\omega = 0,25$	[10,21; 152,33]	[118,00; 499,89]	[46,28%/14,16%; 1,15%/-0,02%]
$\omega = 0,37$	[4,45; 77,74]	[65,34; 278,97]	[-36,25%/-41,74%; -43,99%/-44,21%]

Tabela 6.10 – Resultados da sintonia com distúrbio para cada frequência.

Frequência (ω)	ISE	ISV	Varição (dados sem distúrbio)	Varição (dados sem I_{S0})
$\omega = 0,01$	[434,69; 339,47]	[236,38; 1244,36]	[39,97/28,91; 12,64/250,62]	[-50,53/-43,05; +3,52/+40,00]
$\omega = 0,1$	[547,15; 445,14]	[585,56; 1119,62]	[152,43/134,58; 361,82/125,88]	[+68,39/+62,18; -0,02/-91,41]
$\omega = 0,25$	[514,13; 422,44]	[997,77; 1070,78]	[119,41/111,88; 774,03/ 77,04]	[+81,72/+74,57; -25,75/ -104,41]
$\omega = 0,37$	[440,24; 355,77]	[1010,17; 1110,78]	[45,52/45,21; 786,43/117,04]	[25,46/22,74; -12,57/-32,62]

A tabela 6.8 detalha a tendência no comportamento do índice I_{s0} quando esse é adicionado no sistema. É possível notar que para as menores frequências, o valor de R acaba sendo reduzido, visando favorecer a minimização do erro. Porém, com o aumento da frequência, a tendência se inverte e o esforço se torna o foco da minimização. Esse padrão é compatível com aquele observado na tabela 6.7, no qual os valores de ISE diminuem com a frequência, diferente de ISV .

Os resultados da tabela 6.9, em boa parte, sustentam o comportamento observado nos dados anteriores, mostrando variações semelhantes entre esses. Porém, um detalhe importante a se notar foi a incapacidade do sistema em promover a redução do parâmetro ISV_I de forma proporcional ao aumento apresentado por esse, mesmo com o valor de R_I sendo favorecido em relação aos outros parâmetros para frequências a partir de $\omega = 0,1$. Isso possivelmente ocorre devido ao efeito dos outros índices, sendo possível obter uma resposta mais aprimorada com o aumento do parâmetro w_{s0} . De qualquer forma, o parâmetro I_{s0} alterou o sistema na direção desejada para esse, além de priorizar os parâmetros mais afetados.

7. CONCLUSÕES

Neste projeto, foi proposto uma estratégia de sintonia de controladores MPC, na qual funções de sensibilidade do sistema foram utilizadas para este fim. O método obtém três índices de ação diferenciadas: Minimização do erro, do esforço e rejeição dos distúrbios, cujas influências na metodologia são determinadas através dos parâmetros de penalização sendo sintonizados. Os apontadores refletem a integral da resposta em frequência das funções de sensibilidade, e são comparadas com um valor de meta.

O método é aplicado em um cenário SISO, apresentando resultados que satisfazem os objetivos determinados. O índice de minimização de erro promoveu uma aproximação efetiva entre a variável controlada e a referência. A penalização do esforço não só realizou a redução da variação da variável controlada, mas também mostrou uma relação de proporção adequada com o primeiro apontador, uma vez que sua atuação se tornou visível conforme os valores desses se aproximaram um do outro. Finalmente, a rejeição do distúrbio foi incentivada com a aplicação do devido índice, garantindo a focalização da ação de controle na variável mais prejudicada pelo distúrbio.

No cenário MIMO, os conceitos de valores singulares foram utilizados visando facilitar a obtenção de resultados que englobassem múltiplas variáveis, obtendo os estados de energia de todo o sistema. Além disso, foi introduzido um índice extra que visava garantir que esses estados se relacionassem de forma a garantir um comportamento equilibrado entre as entradas e saídas do processo. Os resultados obtidos para essa etapa destacaram a capacidade da metodologia em compreender as variáveis mais afetadas pelo processo e promover a sintonia de formar a considerar o balanceamento no controle do processo.

A metodologia apresentou características que a destacam em relação a métodos semelhantes presentes na literatura. A customização e a praticidade presenciadas garantem que essa obtenha resultados eficientes sem prejudicar o custo computacional ou necessitar de um banco de dados extenso do sistema e de forma a englobar diversos cenários possíveis. Além disso, o método abrange uma consideração universal para as ações de controles descritas, garantindo a obtenção de resultados adequados aos objetivos do usuário.

Embora a capacidade da metodologia foi comprovada, percebe-se que essa ainda pode ser aprimorada. Temos que no caso MIMO, observou-se que uma das variáveis manipuladas foi significativamente alterada pela introdução do distúrbio, mas que a aplicação do índice I_{S0} , embora tenha promovido a diminuição do esforço da variável em questão, não promoveu uma

diminuição tão acentuada quanto esperada. Incentiva-se nesse caso que o estudo da relação entre os problemas servos e regulatórios seja realizado no contexto da aplicação da metodologia, de forma a otimizar a sua aplicação.

Nesse contexto, concluiu-se que a metodologia apresenta potencial adequado para ser aplicada eficientemente na sintonia de sistemas de MPC complexos de forma prática e objetiva. Percebe-se que os conceitos de funções de sensibilidade e valores singulares podem ser utilizados de forma a descrever a atuação do sistema e identificar o desvio do comportamento das entradas e saídas do ideal, permitindo ditar a forma como o controlador deve ser aplicado para balanceá-los. O foco a partir desse instante deveria ser o aprimoramento da metodologia, visando aplicação e alteração dessa de forma a conseguir englobar problemas mais complexos e que apresentem dinâmicas abstrusa.

8. SUGESTÕES PARA TRABALHOS FUTUROS

O trabalho realizado nesse projeto objetivou a formulação e comprovação de uma metodologia de sintonia para controladores do tipo MPC e, por isso, não pode abranger todo o potencial e utilidades dessa, que devem ser explorados em atividades futuras.

Um desses exemplos seria a aplicação e alteração dessa metodologia para abranger projetos com distúrbios e ruídos de natureza estocásticos ao invés de conhecidos, assim como aqueles utilizados nas simulações realizadas nesse trabalho. Esse tipo de interferência aleatória pode inviabilizar a aplicação de controladores MPC, além de prejudicar sua performance consideravelmente caso não seja considerado. Nesse caso, a mesclagem dos resultados obtidos com a aplicação de métodos estatísticos para solucionar o problema descrito é encorajado (BRADFORD; IMSLAND, 2018).

Deve ser notado também que os processos sintonizados nesse trabalho foram casos típicos presentes na engenharia química e possam não representar a complexidade encontrada em alguns sistemas contemporâneos. O intuito do projeto foi conceber uma metodologia que possuísse aplicabilidade na arquitetura típica de controladores preditivos. Sugere-se que para trabalhos futuros sejam estudadas formas de traduzir a metodologia de sintonia para sistemas que adaptem a aplicação de controladores preditivos para sistemas complexos, como aqueles relacionados à variação de ganho (Grimble; Majecki, 2018) ou a sistemas instáveis (Santana et al., 2020).

Outro ponto de interesse que poderia ser expandido seria a aplicação da metodologia na sintonia de outros parâmetros essenciais para a aplicação adequada do controlador MPC, como os horizontes de controle e de predição. Embora o foco da metodologia seja a performance do controlador em relação à priorização dos parâmetros de pesagem, a ideia de utilizá-la em conjunto com outras formas de sintonia não deveria ser descartada.

Finalmente, a metodologia foi aplicada para um sistema com números de entradas e saídas idênticas, além de apresentar distúrbio de frequência conhecida. A expansão do método para englobar distúrbios desconhecidos de comportamento variável, além de sistemas diversos com números de entradas e saídas diferentes, poderiam ser estudados, uma vez que a metodologia apresenta uma praticidade apreciável, incentivando a adaptação dessa para problemas mais dinâmicos que aqueles estudados nesse projeto.

9. REFERÊNCIAS

- ABDUL-ADHEEM, W. R.; IBRAHEEM, I. K. Decoupled control scheme for output tracking of a general industrial nonlinear MIMO system using improved active disturbance rejection scheme. **Alexandria Engineering Journal**, v. 58, n. 4, p. 1145–1156, 2019.
- ABRASHOV, S.; AIRIMITOAI, T. B.; LANUSSE, P.; et al. Model Predictive Control Tuning: Methods and Issues. Application to steering wheel position control. **IFAC-PapersOnLine**, v. 50, n. 1, p. 11331–11336, 2017.
- AHAMAD, N.; SINGH, G.; KHAN, S.; SIKANDER, A. Design and performance analysis of optimal reduced order H-infinity controller: L1 norm based genetic algorithm technique. 2017 International Conference on Power and Embedded Drive Control (ICPEDC). **Proceedings...** . p.8–13, 2017. IEEE.
- ALBALAWI, F.; ALANQAR, A.; DURAND, H.; CHRISTOFIDES, P. D. Simultaneous control of safety constraint sets and process economics using economic model predictive control. 2016 American Control Conference (ACC). **Proceedings...** . p.5062–5067, 2016. IEEE.
- ALHAJERI, M.; SOROUSH, M. Tuning Guidelines for Model-Predictive Control. **Industrial and Engineering Chemistry Research**, v. 59, n. 10, p. 4177–4191, 2020.
- ALVAREZ, L.; ESPINOSA, J. Methodology based on SVD for control structure design. **Latin American applied research**, v. 42, n. 3, p. 245–250, 2012.
- AZAÑEZ, M.; LESTANDI, L.; REBOLLO, T. C. Low Rank Approximation of Multidimensional Data. **High-Performance Computing of Big Data for Turbulence and Combustion**. p.187–250, 2019. Springer, Cham.
- BAHITA, M.; BELARBI, K. Model Reference Neural-Fuzzy Adaptive Control of the Concentration in a Chemical Reactor (CSTR). **IFAC-PapersOnLine**, v. 49, n. 29, p. 158–162, 2016.
- BARTSCH, A. G.; NEGRI, G. H.; CAVALCA, M. S. M.; DE OLIVEIRA, J.; NIED, A. Cost function tuning methodology for FCS-MPC applied to PMSM drives. 14th Brazilian Power Electronics Conference, COBEP 2017. **Proceedings...** . p.1–6, 2017. IEEE.
- BLONDIN, M. J.; SANCHIS SÁEZ, J.; PARDALOS, P. M. Control Engineering from Classical to Intelligent Control Theory—An Overview. **Computational Intelligence and**

Optimization Methods for Control Engineering, p. 1–30, 2019. Springer, Cham.

BOEIRA, E.; BORDIGNON, V.; ECKHARD, D.; CAMPESTRINI, L. Comparing MIMO Process Control Methods on a Pilot Plant. **Journal of Control, Automation and Electrical Systems**, v. 29, n. 4, p. 411–425, 2018.

BOULKAIBET, I.; BELARBI, K.; BOUOUDEN, S.; MARWALA, T. A new TS fuzzy model predictive control for nonlinear processes. **Expert Systems with Applications**, v. 88, p. 132–151, 2017.

BRADFORD, E.; IMSLAND, L. Stochastic Nonlinear Model Predictive Control Using Gaussian Processes. 2018 European Control Conference, ECC 2018. **Anais...** . p.1027–1034, 2018. IEEE.

CĂLUGĂRU, G.; CARPATHIAN, E. D. Improved aircraft attitude control using generalized predictive control method. 17th International Carpathian Control Conference (ICCC). **Proceedings...** . p.101–106, 2016. IEEE.

CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. Springer-Verlag, 2007.

CHEN, Z.; TU, W.; YAN, L.; LUO, G. Dynamic cost function design of finite-control-set model predictive current control for PMSM drives. 2019 IEEE International Symposium on Predictive Control of Electrical Drives and Power Electronics (PRECEDE). **Proceedings...** . p.1–6, 2019. IEEE.

CHIN, R.; ROWE, J. E. Re-parametrising Cost Matrices for Tuning Model Predictive Controllers. 2019 IEEE Congress on Evolutionary Computation, CEC 2019 - Proceedings. **Proceedings...** . p.2856–2863, 2019. IEEE.

CLARKE, D. W. Application of Generalized Predictive Control to Industrial Processes. **IEEE Control Systems Magazine**, v. 8, n. 2, p. 49–55, 1988.

CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. Generalized predictive control-Part I. The basic algorithm. **Automatica**, v. 23, n. 2, p. 137–148, 1987.

DEROUICHE, M. L.; BOUALLÈGUE, S.; HAGGÈGE, J.; SANDOU, G. LabVIEW Perturbed Particle Swarm Optimization Based Approach for Model Predictive Control Tuning. **IFAC-PapersOnLine**, v. 49, n. 5, p. 353–358, 2016.

DUFFY, G.; MILLS, P.; LI, Q.; ... L. V. N. Z. C.; 2017, U. A methodology to determine the

dynamic relationship between process and manipulated variables. 2017 Australian and New Zealand Control Conference (ANZCC). **Proceedings...** . p.89–94, 2017. IEEE.

FESHARAKI, S. J.; SHEIKHOLESLAM, F.; KAMALI, M.; TALEBI, A. Tractable robust model predictive control with adaptive sliding mode for uncertain nonlinear systems. **International Journal of Systems Science**, p. 1–13, 2020.

FRANCISCO, M.; VEGA, P.; ÁLVAREZ, H. Robust Integrated Design of processes with terminal penalty model predictive controllers. **Chemical Engineering Research and Design**, v. 89, n. 7, p. 1011–1024, 2011.

GERKŠIČ, S.; PREGELJ, B.; PERNE, M.; et al. Model predictive control of ITER plasma current and shape using singular-value decomposition. **Fusion Engineering and Design**, v. 129, p. 158–163, 2018.

GIRALDO, S. A. C.; MELO, P. A.; SECCHI, A. R. Tuning of model predictive control based on hybrid optimization. IFAC-PapersOnLine. **Proceedings...** . v. 52, p.136–141, 2019.

GÓMEZ-PÉREZ, C. A.; ESPINOSA, J. The design analysis of continuous bioreactors in series with recirculation using Singular Value Decomposition. **Chemical Engineering Research and Design**, v. 125, p. 108–118, 2017.

GONZALES, O.; CELA, A.; HERRERA, M. Model predictive control tuning based on Extended Kalman Filter. 2017 IEEE 2nd Ecuador Technical Chapters Meeting (ETCM). **Proceedings...** . p.1–6, 2017. IEEE.

GRIMBLE, M. J.; MAJECKI, P. Restricted structure predictive control for linear and nonlinear systems. **International Journal of Control**, v. 93, n. 8, p. 1175–1799, 2018.

GRÜNE, L.; PANNEK, J. Nonlinear Model Predictive Control. **Nonlinear Model Predictive Control**. p.45–69, 2017. Springer, Cham.

GU, L.; WANG, G. Z. Quantum Higher Order Singular Value Decomposition. ieeexplore.ieee.org. **Proceedings...** . p.1166–1171, 2019. IEEE.

HOSSEINNIA, S. H.; LUNDH, M. A general robust MPC design for the state-space model: Application to paper machine process. **Asian Journal of Control**, v. 18, n. 5, p. 1891–1907, 2016.

IRA, A. S.; MANZIE, C.; SHAMES, I.; et al. Tuning of multivariable model predictive

controllers through expert bandit feedback. **International Journal of Control**, p. 1–9, 2020.

JI, J.; KHAJEPOUR, A.; MELEK, W. W.; HUANG, Y. Path planning and tracking for vehicle collision avoidance based on model predictive control with multiconstraints. **IEEE Transactions on Vehicular Technology**, v. 66, n. 2, p. 952–964, 2017. IEEE.

KWONG, W. **Introdução ao Controle Preditivo com Matlab**. EdUFSCar, 2012.

LAM, Q. L.; BRATCU, A. I.; RIU, D.; MONGKOLTANATAS, J. Multi-variable H-infinity robust control applied to primary frequency regulation in microgrids with large integration of photovoltaic energy source. Proceedings of the IEEE International Conference on Industrial Technology. **Proceedings...** . p.2921–2928, 2015.

LANDAU, I. D.; AIRIMITOAIIE, T. B.; CASTELLANOS-SILVA, A.; CONSTANTINESCU, A. Digital control strategies for active vibration control-the bases. **Advances in Industrial Control**. p.121–151, 2017. Springer, Cham.

LI, Z.; INSTITUTE, G. W.-J. OF THE F.; 2017, U. Generalized predictive control of linear time-varying systems. **Journal of the Franklin Institute**, v. 354, n. 4, p. 1819–1832, 2017.

LIU, K.; LI, K.; SOURCES, C. Z. Constrained generalized predictive control of battery charging process based on a coupled thermoelectric model. **Journal of Power Sources**, v. 347, p. 145–158, 2017.

LUZI, M.; VACCARINI, M.; LEMMA, M. A tuning methodology of Model Predictive Control design for energy efficient building thermal control. **Journal of Building Engineering**, v. 21, p. 28–36, 2019.

MACIEJOWSKI, J. **Predictive control: with constraints**. Pearson Education Limited, 2002.

MADIOUNI, R.; BOUALLÈGUE, S.; HAGGÈGE, J.; SIARRY, P. Epsilon-multiobjective particle swarm optimization-based tuning of sensitivity functions for polynomial control design. **Transactions of the Institute of Measurement and Control**, v. 41, n. 13, p. 3688–3704, 2019.

MEI, X.; ZU, R.; WANG, F.; KENNEL, R. Variable cost functions' sequence design for model predictive control of IPMSM without weighting factor. 2018 IEEE International Conference on Information and Automation, ICIA 2018. **Proceedings...** . p.500–505, 2018. IEEE.

- MOHAMMADI, A.; ASADI, H.; MOHAMED, S.; NELSON, K.; NAHAVANDI, S. Multiobjective and Interactive Genetic Algorithms for Weight Tuning of a Model Predictive Control-Based Motion Cueing Algorithm. **IEEE Transactions on Cybernetics**, v. 49, n. 9, p. 3471–3481, 2019. IEEE.
- NARAYANAN, V.; LI, J. S.; CHING, S. N. Biophysically interpretable inference of single neuron dynamics. **Journal of Computational Neuroscience**, v. 47, n. 1, p. 61–76, 2019.
- DE OLIVEIRA JÚNIOR, J. A.; ASSUNÇÃO, W. K. G.; JERONYMO, D. C. Multi-objective tuning of generalized predictive controller: A trade-off between performance and robustness. VIII Brazilian Symposium on Computing System Engineering (SBESC). **Proceedings...** . p.178–183, 2018. IEEE.
- PASZEK, S.; BOBOŃ, A.; BERHAUSEN, S.; et al. Analysis of the Sensitivity of Generating Unit Simulation Waveforms to Changes of Model Parameters. **Synchronous Generators and Excitation Systems Operating in a Power System**. p.53–69, 2020. Springer, Cham.
- PATIÑO, J.; LÓPEZ, J. D.; ESPINOSA, J. Analysis of control sensitivity functions for power system frequency regulation. Workshop on Engineering Applications. **Proceedings...** . p.606–617, 2018. Springer, Cham.
- PATIÑO, J.; LÓPEZ, J. D.; ESPINOSA, J. Sensitivity analysis of frequency regulation parameters in power systems with wind generation. **Advanced Control and Optimization Paradigms for Wind Energy Systems**. p.67–87, 2019. Springer, Singapore.
- RAFIEISHISHAVAN, S. **Integration of design and control for large-scale applications: a back-off approach**. 2020.
- RAJABI, F.; REZAIE, B.; RAHMANI, Z. A novel nonlinear model predictive control design based on a hybrid particle swarm optimization-sequential quadratic programming algorithm: Application to an evaporator system. **Transactions of the Institute of Measurement and Control**, v. 38, n. 1, p. 23–32, 2016.
- REYNOSO MEZA, G.; BLASCO FERRAGUD, X.; SANCHIS SAEZ, J.; HERRERO DURÁ, J. M. Comparing control structures from a multiobjective perspective. **Controller Tuning with Evolutionary Multiobjective Optimization**. p.123–144, 2017. Springer, Cham.
- ROY, T.; BARAI, R. K.; DEY, R. Generalized LFT modeling of an uncertain MIMO system.

Modelling and Simulation in Science, Technology and Engineering Mathematics. p.677–693, 2019. Springer, Cham.

SAIF, A.; ON, M. A. Network-based process control and improvements with fuzzy time delay modulator. 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). **Proceedings...** . p.1281–1285, 2017. IEEE.

SANTANA, D. D.; MARTINS, M. A. F.; ODLOAK, D. One-layer gradient-based MPC + RTO strategy for unstable processes: a case study of a CSTR system. **Brazilian Journal of Chemical Engineering**, v. 37, n. 1, p. 173–188, 2020. Springer.

SANTOS, J. E. W.; TRIERWEILER, J. O.; FARENZENA, M. Robust Tuning for Classical MPC through the Multi-scenarios Approach. **Industrial and Engineering Chemistry Research**, v. 58, n. 8, p. 3146–3158, 2019.

SHADMAND, M. B.; JAIN, S.; BALOG, R. S. Autotuning Technique for the Cost Function Weight Factors in Model Predictive Control for Power Electronic Interfaces. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, v. 7, n. 2, p. 1408–1420, 2018.

SHAHID, M.; ABBASI, M.; TELKOMNIKA, S. A.-; 2018, U. Asymptotic features of Hessian Matrix in Receding Horizon Model Predictive Control with Medium Sized Prediction Frames. **Telkomnika**, v. 16, n. 3, p. 1174–1182, 2018.

SHEN, M.; ON, R. W. A new singular value decomposition algorithm for octonion signal. 24th International Conference on Pattern Recognition (ICPR). **Proceedings...** . p.3233–3237, 2018.

STLUKA, P.; PARTHASARATHY, G.; GABEL, S.; SAMAD, T. Architectures and algorithms for building automation—An industry view. **Intelligent Building Control Systems**. p.11–43, 2018. Springer, Cham.

VAZQUEZ, S.; RODRIGUEZ, J.; RIVERA, M.; FRANQUELO, L. G.; NORAMBUENA, M. Model Predictive Control for Power Converters and Drives: Advances and Trends. **IEEE Transactions on Industrial Electronics**, v. 64, n. 2, p. 935–947, 2017. IEEE.

VIJAYAGOPAL, M.; ZANCHETTA, P. Control of a direct matrix converter with modulated model-predictive control. **IEEE Transactions on Industry Applications**, v. 53, n. 3, p. 2342–2349, 2017.

WANG, J.; WANG, K.; JIA, R.; CHEN, X. Research on Load Clustering Based on Singular

Value Decomposition and K-means Clustering Algorithm. 2020 Asia Energy and Electrical Engineering Symposium (AEEES). **Proceedings...** . p.831–835, 2020. IEEE.

WANG, T.; LU, H.; WANG, J.; et al. Recent progress of continuous crystallization. **Journal of Industrial and Engineering Chemistry**, v. 54, p. 14–29, 2017.

WILKIE, J.; JOHNSON, M.; KATEBI, R. **Control Engineering: An introductory course**. Palgrave Macmillan, 2017.

XIE, S.; XIE, Y.; HUANG, T.; ... W. G. Generalized predictive control for industrial processes based on neuron adaptive splitting and merging RBF neural network. **IEEE Transactions on Industrial Electronics**, v. 66, n. 2, p. 1192–1202, 2018.

XU, K.; MINONZIO, J. G.; TA, D.; et al. Sparse SVD Method for High-Resolution Extraction of the Dispersion Curves of Ultrasonic Guided Waves. **IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control**, v. 63, n. 10, p. 1514–1524, 2016.

YAMASHITA, A. S.; ALEXANDRE, P. M.; ZANIN, A. C.; ODLOAK, D. Reference trajectory tuning of model predictive control. **Control Engineering Practice**, v. 50, p. 1–11, 2016.

YAMASHITA, A. S.; ZANIN, A. C.; ODLOAK, D. Tuning the Model Predictive Control of a Crude Distillation Unit. **ISA Transactions**, v. 60, p. 178–190, 2016.

YANG, Y.; JIAO, S.; LI, J. Vision-based optimization of the generalized predictive active disturbance rejection controller. **Journal of Visual Communication and Image Representation**, v. 71, n. 102728, p. 1–6, 2020.

ZHOU, K.; DOYLE, J. **Essentials of robust control**. Prentice-Hall, 1998.