



Universidade Federal da Bahia
Instituto de Computação / Escola Politécnica

Programa de Pós-Graduação em Mecatrônica

**CONTROLE PREDITIVO BASEADO EM
MODELO FUZZY EMBARCÁVEL PARA
POÇOS DE PETRÓLEO EQUIPADOS COM
BOMBEIO CENTRÍFUGO SUBMERSO**

Victor Santos Matos

DISSERTAÇÃO DE MESTRADO


Salvador
16 de maio de 2023

VICTOR SANTOS MATOS

**CONTROLE PREDITIVO BASEADO EM MODELO FUZZY
EMBARCÁVEL PARA POÇOS DE PETRÓLEO EQUIPADOS COM
BOMBEIO CENTRÍFUGO SUBMERSO**

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Mecatrônica da Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Mecatrônica.

Orientador: Prof. Dr. Márcio André Fernandes Martins
Coorientador: Prof. Dr. Thiago Pereira das Chagas



Salvador
16 de maio de 2023

S237 Santos, Victor Matos

Controle preditivo baseado em modelo fuzzy embarcável para poços de petróleo equipados com bombeio centrífugo submerso/ Victor Santos Matos. -- Salvador, 2023.

64 f.: il. color.

Orientador: Prof. Dr. Márcio André Fernandes Martins.

Coorientador: Prof. Dr. Thiago Pereira das Chagas.

Dissertação (Mestrado) - Programa de Pós-Graduação em Mecatrônica - Universidade Federal da Bahia, Universidade Federal da Bahia - Escola Politécnica, 2023.

1. Controle Preditivo. 2. Fuzzy. 3. Controle Embarcado. 4. Elevação Artificial. 5.BCS. 6. Óleo e Gás. I. Martins, Márcio André Fernandes. II.Chagas, Thiago Pereira. III. Universidade Federal da Bahia. IV. Título.

CDD: 621.3

TERMO DE APROVAÇÃO¹

Victor Santos Matos

Controle preditivo baseado em modelo fuzzy embarcável para poços de petróleo equipados com bombeio centrífugo submerso.

Esta Dissertação de Mestrado foi julgada adequada à obtenção do título de Mestre em Mecatrônica e aprovada em sua forma final pelo Programa de Pós-graduação em Mecatrônica da Universidade Federal da Bahia.

Salvador, 16 de maio de 2023.



Documento assinado digitalmente
MARCIO ANDRE FERNANDES MARTINS
Data: 23/05/2023 14:27:43-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. Márcio André Fernandes Martins
(Orientador-PPGM)



Documento assinado digitalmente
THIAGO PEREIRA DAS CHAGAS
Data: 18/05/2023 05:46:03-0300
Verifique em <https://validar.it.gov.br>

Prof. Dr. Thiago Pereira das Chagas (Co-orientador -UESC)



Documento assinado digitalmente
Daniel Martins Lima
Data: 16/05/2023 18:00:52-0300
CPF: ***.552.736-**
Verifique as assinaturas em <https://v.ufsc.br>

Pr... (UFSC)

Prof. Dr. Flávio Vasconcelos da Silva (Unicamp)

Documento assinado eletronicamente por **Flavio Vasconcelos da Silva, COORDENADOR DE EXTENSÃO**, em 17/05/2023, às 11:47 horas, conforme Art. 10 § 2º da MP 2.200/2001 e Art. 1º da Resolução GR 54/2017.



A autenticidade do documento pode ser conferida no site:
sigad.unicamp.br/verifica, informando o código verificador:
77DC8F52 A3B94D7F 8CA6E53E A76B1C78



Dedico este trabalho a minha família, em especial aos meus pais, Jailton e Cássia, e a minha companheira de vida, Raquel.

AGRADECIMENTOS

A **Deus** pela força e guia pelos caminhos dessa empreitada em uma realidade tão delicada.

À **Santa Rita de Cássia** pela proteção e intercessão sobre mim e minha família.

Aos meus pais, **Jailton** e **Cássia**, por serem minha base e meu exemplo.

À minha companheira, **Raquel**, que mesmo com a distância esteve sempre presente, apoiando e torcendo.

Aos meus orientadores, **Prof. Dr Márcio André Fernandes Martins** e **Prof. Dr. Thiago Pereira das Chagas**, pelos ensinamentos para o desenvolvimento deste trabalho e no caminhar do peculiar mundo acadêmico.

Aos colegas de pesquisa por todas críticas construtivas, suporte e experiência. Em especial a **Bruno A. Santana** por toda contribuição e parceria.

Por fim, agradeço à Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (**ANP**), na forma do Programa de Recursos Humanos nº 35.1 (**PRH 35.1**) pelo apoio financeiro necessário para realização deste trabalho. Agradeço também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (**CAPES**) - Código Financiamento 001 aplicado ao PPGM e ao uso do Periódicos CAPES.

A ciência é, portanto, uma perversão de si mesma, a menos que tenha como fim último, melhorar a humanidade.

—NIKOLA TESLA

RESUMO

Técnicas de controle avançado ainda não são uma realidade consolidada no setor de elevação artificial de petróleo e gás natural, principalmente em sistemas de bombeio centrífugo submerso (BCS). Os controladores preditivos baseados em modelo (MPC) requerem modelos representativos do sistema, sendo uma tarefa dispendiosa na abordagem fenomenológica, em virtude da complexidade fluidodinâmica e termodinâmica em um poço de petróleo e gás. Por isso, as abordagens orientadas a dados são alternativas viáveis para encontrar um equilíbrio entre precisão e tempo para obtenção do modelo dinâmico desses processos produtivos. Os sistemas de inferência *fuzzy* Takagi-Sugeno-Kang (TSK) têm essa característica, sendo capazes de aproximar as dinâmicas não lineares mediante um conjunto de submodelos lineares. Agregando essa abordagem ao MPC, é possível utilizar uma estrutura de controle linear e, portanto, numérico-computacionalmente simplificada, porém, com a precisão e representatividade adequadas ao processo. Formando-se uma condição favorável para o uso nos sistemas de elevação artificial, que comumente apresentam instalações isoladas e dependentes de sistemas dedicados de controle. A proposta deste trabalho caracteriza-se como a síntese de um controlador preditivo com garantia de factibilidade encapsulando um modelo de predição *fuzzy* TSK para sistemas de elevação do tipo BCS com baixo custo computacional. O foco é a aplicação direta da técnica através do embarque em microcontroladores, simulando a infraestrutura de controle industrial. Os estudos de caso implementados sobre um sistema BCS através da abordagem *hardware-in-the-loop* (HIL) apresentaram uma redução de mais de 15 % no custo de controle, um rendimento superior a 10 % sobre a restrição de envelope operacional e um tempo de cômputo do problema de otimização embarcado cerca de 20 vezes menor que o período de amostragem do sistema. Atestou-se a representatividade do modelo TSK e a capacidade de controle e factibilidade da técnica, frente ao conjunto de restrições típicas e ao número reduzido de variáveis medidas.

Palavras-chave: Controle Preditivo; Fuzzy; Controle Embarcado; Elevação Artificial; BCS; Óleo e Gás.

ABSTRACT

Advanced control techniques have not yet been a consolidated reality in the oil and natural gas artificial lift sector, particularly in electric submersible pumping (ESP) systems. Model-based predictive controllers (MPC) require representative system models, which can be a costly task using a phenomenological approach due to the fluid-dynamic and thermodynamic complexity of an oil and gas well. Therefore, data-driven approaches are viable alternatives to achieve a balance between accuracy and time in obtaining the dynamic model of these production processes. Takagi-Sugeno-Kang (TSK) fuzzy inference systems have this characteristic, as they can approximate nonlinear dynamics through a set of linear submodels. By combining this approach with MPC, it is possible to use a simplified linear control structure that is computationally efficient, while still providing the necessary accuracy and representativeness for the process. This forms a favorable condition for use in artificial lift systems, which often have isolated installations and depend on dedicated control systems. The proposal of this work is the synthesis of a predictive controller with guaranteed feasibility, encapsulating a TSK fuzzy prediction model for ESP-type lifting systems with low computational cost. The focus is on the direct application of the technique through embedding it in microcontrollers, simulating the industrial control infrastructure. The implemented case studies on a BCS system using the hardware-in-the-loop (HIL) approach demonstrated a reduction of over 15 % in control costs, an improvement of more than 10 % in operational envelope constraint, and a computational time for the embedded optimization problem approximately 20 times shorter than the system's sampling period. The representativeness of the TSK model and the control capability and feasibility of the technique were verified in the face of typical constraints and a reduced number of measured variables.

Keywords: Predictive Control; Fuzzy; Embedded Control; Artificial Elevation; ESP; Oil and gas.

SUMÁRIO

Lista de Figuras	xiii
Lista de Tabelas	xiv
Lista de Abreviações e Siglas	xv
Lista de Símbolos	xvii
Capítulo 1—Introdução	1
1.1 Controle avançado em bombeio centrífugo submerso	2
1.2 Objetivos	5
1.3 Contribuições	6
1.4 Organização do trabalho	6
Capítulo 2—Referencial Teórico	8
2.1 Elevação Artificial por Bombeio Centrífugo Submerso	8
2.2 Identificação de Sistemas Dinâmicos Não Lineares	10
2.3 Modelagem <i>fuzzy</i> de sistemas dinâmicos não lineares	14
2.3.1 Topologia Takagi-Sugeno-Kang (TSK)	15
2.3.2 Modificação multimodelos em espaço de estados	15
2.3.3 Estratégia de identificação do modelo com base em dados	17
2.3.3.1 Determinação dos antecedentes	17
2.3.3.2 Determinação dos consequentes	18
2.4 MPC com garantia de estabilidade nominal e factibilidade	20
2.4.1 Descrição do modelo para sistemas estáveis	20
2.4.2 IHMPC com garantia de estabilidade e factibilidade para sistemas estáveis	21
2.5 Implementação de controladores em sistemas embarcados	23
Capítulo 3—Fuzzy MPC factível por faixa	26
3.1 <i>Fuzzy</i> MPC de Horizonte Infinito (FIHMPC)	27

Capítulo 4—Metodologia	31
4.1 Identificação da planta	32
4.2 Projeto e sintonia do FIHMPC	35
4.3 Implementação e validação	36
Capítulo 5—Resultados	38
5.1 Extração de dados da planta	38
5.2 Identificação da planta por modelo TSK	38
5.3 FIHMPC	45
5.3.1 Otimização econômica	51
5.3.2 Avaliação Computacional	53
Capítulo 6—Considerações finais	56
6.1 Conclusão	56
6.2 Trabalhos futuros	57

LISTA DE FIGURAS

1.1	Distribuição temporal dos trabalhos relacionados a MPC aplicado a BCS.	3
1.2	Distribuição da literatura acerca das abordagens de modelo de predição e aplicação do controlador ao sistema BCS.	5
2.1	Esquema do sistema BCS.	9
2.2	Estrutura interna do sistema de inferência <i>fuzzy</i>	14
2.3	Topologia TSK indicando cada operação por meio de camadas.	16
2.4	Mapeamento <i>fuzzy</i> das regiões de operação.	17
2.5	Diagrama da metodologia de projeto de <i>software</i> embarcado - modelo V.	25
3.1	Diagrama da proposta de controle <i>fuzzy</i> MPC.	28
4.1	Diagrama da simulação HIL do FIHMPC por faixa proposto para o sistema BCS.	36
5.1	Sinais APRBS para a identificação da BCS pelo modelo TSK.	39
5.2	Dados coletados da BCS de p_{wh} , p_{in} e H para o sinal de excitação aplicado.	39
5.3	Combinação das entradas em regime para mapeamento do sistema nos diversos pontos de operação possíveis - dados para clusterização <i>fuzzy</i> . . .	40
5.4	Análise do índice <i>RMSE</i> sob variação do número de regras do modelo <i>fuzzy</i> TSK.	41
5.5	Funções de pertinência das variáveis preditas p_{wh} , p_{in} e H	41
5.6	Funções de pertinência das variáveis manipuladas f_{ref} e $z_{c_{ref}}$	42
5.7	Predição infinitos passos a frente da pressão de cabeça de poço para os dados de teste.	43
5.8	Predição infinitos passos a frente da pressão de entrada de poço para os dados de teste.	43
5.9	Predição infinitos passos a frente da altura manométrica para os dados de teste.	44
5.10	Pressão de entrada da BCS para o FIHMPC e IHMPC.	46
5.11	Esquema de controle por faixa da altura manométrica da BCS para FIHMPC e IHMPC.	47
5.12	Trajetórias sobre o envelope operacional sobre a aplicação dos controladores FIHMPC e IHMPC.	47
5.13	Variáveis de folga dos controladores FIHMPC e IHMPC.	48
5.14	Variáveis manipuladas dos controladores FIHMPC e IHMPC.	48
5.15	Atualização do modelo <i>fuzzy</i> usado no controlador FIHMPC.	49
5.16	Função custo dos controladores FIHMPC e IHMPC.	50

5.17 Pressão de entrada do controlador FHMPC com e sem o uso do <i>target</i> econômico.	51
5.18 Trajetórias sobre o envelope operacional obtida da aplicação do controlador FHMPC sobre análise econômica.	52
5.19 Variáveis manipuladas na comparação econômica do FHMPC.	52
5.20 O número médio, máximo e mínimo de iterações para cada passo de tempo do FHMPC embarcado no ESP32.	54
5.21 O tempo computacional médio, mínimo e máximo para cada passo de tempo do FHMPC embarcado no ESP32.	54
5.22 Análise estatística da distribuição do tempo computacional do controlador embarcado.	55

LISTA DE TABELAS

5.1	Regras <i>fuzzy</i> TSK identificadas para caracterizar os espaços de operação do sistema BCS.	42
5.2	Comparação de predição em simulação livre entre modelo <i>fuzzy</i> TSK LPV e modelo linear para os dados de teste.	42
5.3	Controller parameters.	45
5.4	Comparação normalizada entre os controladores pela integral da função custo (ICF), tempo fora do envelope (T_{out}) e volume de óleo produzido (V_T).	49

LISTA DE ABREVIACOES E SIGLAS

- ANP - Agncia Nacional de Petrleo, Gs e Biocombustiveis
- APRBS - *Amplitude Modulated Pseudo-Random Bit Sequences*
- BCS - Bombeio centrfugo submerso
- CLP - Controlador lgico programvel
- CV - Variveis controladas
- E&P - Explorao e produo
- FCM - *Fuzzy Cognitive Maps*
- FIS - *Fuzzy Inference System*
- FMPC - *Fuzzy Model Predictive Controller*
- GA - *Genetic Algorithm*
- HIL - *Hardware-in-the-loop*
- IHMPC - *Infinite Horizon Model Predictive Control*
- IDE - *Integrated Development Environment*
- LPV - Linear de parmetros variveis
- MQ - Mnimos quadrados
- MPC - *Model Predictive Control*
- MV - Variveis manipuladas
- NARMAX - *Nonlinear Auto-regressive Moving Average with eXogenous inputs*
- NMPC - *Nonlinear model predictive control*
- O&G - leo e gs
- OPOM - *Output Prediction Oriented Model*
- PID - Controle proporcional, integral e derivativo

PRBS - *Pseudo-Random Bit Sequences*

PRH - Programa de Recursos Humanos

PSO - *Particle Swarm Optimization*

SDCD - Sistema Digital de Controle Distribuído

SIL - *Software-in-the-loop*

TSK - Takagi Sugeno Kang

LISTA DE SÍMBOLOS

$\mathbf{A}, \mathbf{B}, \mathbf{C}$ - Matrizes do modelo em espaço de estados

$\mathbf{A}_i, \mathbf{B}_i$ - Matrizes dos submodelos da topologia *fuzzy*

$\bar{\mathbf{A}}, \bar{\mathbf{B}}$ - Matrizes resultantes do modelo *fuzzy*

$G(s)$ - Função de transferência

s - Variável complexa no domínio da frequência

\mathbf{u} - Vetor de variáveis manipuladas

$b_{0,1,2,\dots,nb}$ - Parâmetros do numerador da função de transferência

na - Número de polos da função de transferência

t - Tempo

nb - Grau do numerador da função de transferência

$r_{1,2,\dots,na}$ - Polos da função de transferência

$d_{i,j}^0$ - Coeficientes da expansão em frações parciais da resposta degrau do sistema, referentes aos termos constantes no tempo

$d_{i,j,l}^d$ - Coeficientes da expansão em frações parciais da resposta degrau do sistema, referentes aos termos variantes no tempo

k - Instante de amostragem

Δt - Intervalo de amostragem

\mathbf{x}^s - Vetor de estados integradores artificiais introduzidos pela forma incremental

\mathbf{x}^{st} - Vetor de estados estáveis

\mathbf{u}_{\max} - Valores máximos para as variáveis manipuladas

\mathbf{u}_{\min} - Valores mínimos para as variáveis manipuladas

$\Delta \mathbf{u}_{\max}$ - Valores máximos para a variação das variáveis manipuladas

\mathbf{y}_{sp} - Referências para as variáveis controladas

V_k - Função objetivo em um dado instante de tempo k

$\mu_{i,j}$ - Grau de pertinência

z_i - Variáveis de entradas do modelo *fuzzy*

$Z_{i,j}$ - Regiões *fuzzy*

$c_{i,j}$ - Centro das funções de pertinência gaussianas

$\sigma_{i,j}$ - Desvio padrão das funções de pertinência gaussianas

w_i - Pesos normalizados das regras *fuzzy*

J - Custo do problema de mínimos quadrados

ϕ_i - Matriz de parâmetros de cada submodelo *fuzzy*

Φ - Matriz de todos os parâmetros do consequente

\mathbf{W}_i - Matriz diagonal dos pesos normalizados das regras *fuzzy*

M - Número de amostras de dados

n - Número de variáveis de estado

p - Número de regras *fuzzy*

nu - Número de entradas do sistema

ny - Número de saídas do sistema

nst - Número de estados estáveis do sistema

nx - Número total de estados do modelo em espaço de estados

\mathbf{I}_{ny} - Matriz identidade de ordem ny

\mathbf{F}^{st} - Submatriz da matriz \mathbf{A} contendo os polos estáveis

\mathbf{B}_0^s - Submatriz do modelo OPOM referente aos estados integradores

\mathbf{B}_0^{st} - Submatriz do modelo OPOM referente aos estados estáveis

\mathbf{D}^{st} - Matriz diagonal das constantes das funções de transferência no domínio do tempo

Ψ^{st} - Submatriz da matriz \mathbf{C} relacionada aos estados estáveis

\mathbf{Q}_y - Matriz de ponderação das saídas

\mathbf{R} - Matriz de ponderação das entradas

\mathbf{S}_y - Matriz de ponderação das variáveis de folga da saída

$\bar{\mathbf{Q}}$ - Matriz de peso terminal

h_c - Horizonte de controle

$\delta_{y,k}$ - Vetor das variáveis de folga calculadas no instante k

$\Delta \mathbf{u}_k$ - Vetor das ações de controle calculadas no instante k

\mathbb{R} - Conjunto dos números reais

\mathbb{C} - Conjunto dos números complexos

\mathbb{R}^n - Espaço real n -dimensional

$\|\cdot\|_2$ - Norma euclidiana

p_{wh} - Pressão de cabeça de poço do sistema BCS

p_{bh} - Pressão de fundo de poço do sistema BCS

p_{in} - Pressão de entrada do sistema BCS

p_m - Pressão de *manifold* de poço do sistema BCS

p_r - Pressão de reservatório do sistema BCS

q_p - Vazão média da coluna produção do sistema BCS

q_c - Vazão média na válvula *choke* do sistema BCS

P - Potência elétrica consumida pela bomba do sistema BCS

H - *Head* ou altura manométrica do sistema BCS

f, f_{ref} - Frequência de rotação medida da bomba do sistema BCS e seu valor de entrada

$z_c, z_{c,ref}$ - Nível de abertura da válvula *choke* medido dos sistema BCS e seu valor de entrada

Δf_{\max} - Máxima variação de frequência do sistema BCS

$\Delta z_{c,\max}$ - Máxima variação da abertura de válvula do sistema BCS

H_{ut} - *Head* de *upthrust*

H_{dt} - *Head* de *downdthrust*

Capítulo

1

Neste capítulo é apresentado a proposta do projeto e sua contextualização e justificativa, assim como a organização deste documento.

INTRODUÇÃO

A produção de petróleo é um dos setores mais importantes da economia mundial, responsável por suprir uma grande parte da demanda de energia global. No Brasil, a produção de petróleo tem sido uma das principais fontes de receita para a economia, sendo fortemente explorada nas últimas décadas, com um crescimento superior a 50% no período de 2010 a 2020 (ANP, 2020). Em 2022, a produção média anual de petróleo no Brasil foi de 3.021 milhões de barris por dia, um aumento de 2,47% em relação ao recorde registrado em 2020, quando a produção atingiu 2,948 milhões de barris por dia. Já a produção média anual de gás natural em 2022 bateu um novo recorde, alcançando 138 milhões de metros cúbicos por dia, representando um aumento de 2,98% em relação a 2021. Destaca-se que a maior parte da produção foi proveniente de águas profundas, como o reservatório do pré-sal, que representa em média 75,2% da produção nacional (ANP, 2023).

Este perfil de produção intensa no Brasil e no mundo indica a importância de ferramentas avançadas para o controle e monitoramento da produção desse recurso, com foco na máxima continuidade operacional das unidades produtoras (CAMPOS et al., 2013). Contudo, com a diminuição da produção natural (surgência) de petróleo em reservatórios existentes, a elevação artificial de petróleo se torna necessária para manter a produção em níveis aceitáveis. Dentre os métodos, o bombeio centrífugo submerso (BCS) se destaca, especialmente para aplicações em águas profundas (DELOU, 2019) e poços de alta produção (PAVLOV et al., 2014).

Salienta-se que o controle aplicado a sistemas de elevação artificial de petróleo e gás pode ser considerado desatualizado em comparação a outros ramos como refino e petroquímicas (CAMPOS et al., 2013), os quais são pioneiros no estudo, desenvolvimento e aplicação de diversas técnicas de controle e automação (CAMPOS et al., 2009) como o controle preditivo. O setor de elevação ainda utiliza técnicas clássicas, ainda que de forma eficaz, como o controlador proporcional integral e derivativo (PID) (KRISHNAMORTHY; FJALESTAD; SKOGESTAD, 2019a) ou aplica controle em malha aberta por

operadores humanos, que dependem de profundo conhecimento do processo para garantir sua continuidade operacional (PAVLOV et al., 2014).

Contudo, a presença de muitos distúrbios e não-linearidades nos processos, além das faltas de instrumentos nas plantas e especialistas no setor criam oportunidades de atualização nestes sistemas. Surgindo, portanto, o conceito de “*Smart oilfield*”, que agrega o uso de sensores inteligentes, redes de sensores sem fio, sistemas de controle avançado e tecnologias de análise de dados em tempo real (CHOI; PARK, 2020).

Se observado na literatura, a aplicação de técnicas de controle avançado e inteligência artificial em elevação ainda está em desenvolvimento acadêmico e sua validação no setor necessita de garantias de rendimento e confiabilidade, uma vez que o setor apresenta resistência a mudanças que podem afetar a produção (BAHALOO; MEHRIZADEH; NAJAFI-MARGHMALEKI, 2022). Contudo, seu uso visa maximizar a produção, a estabilidade, a lucratividade e a eficiência operacional e energética (CAMPOS et al., 2013; BAHALOO; MEHRIZADEH; NAJAFI-MARGHMALEKI, 2022), abrindo-se um caminho para utilização de técnicas de controle avançado em união com sistemas inteligentes, particularmente no contexto de produção de petróleo offshore, onde as condições ambientais e operacionais podem ser mais desafiadoras.

1.1 CONTROLE AVANÇADO EM BOMBEIO CENTRÍFUGO SUBMERSO

Os sistemas BCS são bombas capazes de aumentar a pressão do fluido e facilitar seu escoamento para a superfície. Sendo compostas de múltiplos estágios, onde estruturas, como o impulsor, transferem energia para o fluido na forma de pressão e energia cinética; e o difusor, converte uma parte da energia cinética em aumento de pressão. Sua operação necessita que as restrições da bomba e do poço não sejam violadas e consiste em ajustar coordenadamente a velocidade de rotação da bomba mediante um inversor de frequência em combinação com a regulação da abertura da válvula de produção - *choke*, localizada no topo do poço que alimenta o *manifold* (DELOU, 2019).

O mau funcionamento do sistema BCS pode impactar na vida útil da bomba e causar impactos financeiros indesejados (PAVLOV et al., 2014). Nesta perspectiva, destacam-se os controladores preditivos baseados em modelo (MPC), que constituem um amplo conjunto de técnicas de controle avançado altamente consolidadas e se destacam pela sua eficiência e otimalidade (CAMACHO; BORDONS, 2007). O tratamento sistemático de restrições, a multivariabilidade, a compensação de tempos mortos e a facilidade de implementar ação antecipatória para compensar distúrbios medidos, são características que destacam estratégias MPC dentre as demais técnicas de controle (CAMACHO; BORDONS, 2007) e indicam sua potencialidade para uso em sistemas BCS.

A literatura acerca do MPC aplicado aos sistemas BCS pode ser analisada segundo a linha do tempo da Figura 1.1. Iniciando-se em 2014 com trabalhos abordando técnicas de MPC com modelo de predição linear e avançando, até os dias atuais, para uso de modelos adaptativos e não lineares, em busca de abarcar a devida segurança e eficiência desejada para os sistemas BCS.

Pioneiramente, Pavlov et al. (2014) aplicaram a formulação MPC para rastrear a pressão de entrada e minimizar o consumo energético da BCS - ao incluir um *target*




Figura 1.1: Distribuição temporal dos trabalhos relacionados a MPC aplicado a BCS.

Fonte: Autor.

econômico para a abertura da válvula *choke*. Este trabalho considerou as restrições de envelope operacional em sua formulação e aplicou o controlador proposto em uma planta BCS de teste em escala real, contudo, utilizando apenas um modelo linear de resposta ao degrau como preditor. Binder et al. (2014) propuseram uma formulação similar, destacando-se como a primeira abordagem de MPC embarcada em um controlador lógico programável (CLP) para BCS. Porém, o objetivo era de rastrear a vazão de produção e minimizar, indiretamente, o consumo energético da bomba pela regulação de sua corrente elétrica, considerando apenas as restrições de vazão no problema de otimização. Estas aplicações indicaram a necessidade de estimar variáveis e parâmetros pouco acessíveis do sistema BCS, levando Binder, Pavlov e Johansen (2015) a proporem um estimador de estados de horizonte móvel para prever variáveis como vazão, viscosidade do fluido produzido e o índice de produtividade do poço. Esse trabalho também estende e define em detalhes características do modelo dinâmico para BCS proposto inicialmente por Pavlov et al. (2014), indicando que, na prática, muitas variáveis e parâmetros não estão acessíveis para compor a proposta de controle.

Novamente, com base nos mesmos objetivos de controle de Pavlov et al. (2014), Krishnamoorthy et al. (2016) propuseram um MPC com modelo de predição linearizado a partir de dados obtidos em um simulador de alta fidelidade de um sistema BCS operando com óleo de alta viscosidade, em que se avaliou a robustez de controle frente a variações de viscosidade do fluido. A primeira implementação prática de MPC em um campo com elevação com BCS foi apresentado em Patel et al. (2018), com resultados indicando uma redução energética significativa e tendo como base o uso de modelo linear de resposta ao degrau obtido por dados. A lei de controle objetiva o rastreamento de trajetória da vazão, combinada com as restrições práticas do sistema BCS e utilizando a rotação e a tensão elétrica da bomba, e a abertura da válvula *choke* como as variáveis manipuladas do controlador.

Os trabalhos já comentados apresentaram formulações de MPC convencionais com base em modelos lineares locais para uma única região de operação do sistema BCS, portanto, não caracterizando as não linearidades presentes. Esse fato aponta para abordagens com representações mais fiéis da dinâmica do sistema, como a linha de pesquisa de MPC adaptativo, iniciada em Delou et al. (2019). Esse trabalho objetivou estender a

região de operação utilizando a combinação de dois modelos lineares locais de resposta ao degrau, associados a regiões de operação típicas: baixo ganho (válvula *choke* praticamente aberta) e alto ganho (válvula *choke* aproximadamente fechada). Delou, Souza e Secchi (2019) propuseram uma extensão superior com o uso de múltiplos modelos em conjunto a um estimador de estados, tornando um controlador robusto a perdas de medição das variáveis de estado. Contudo, nestes trabalhos não foram explicitamente consideradas as restrições de *downthrust* e *upthrust*, que, com a mínima e máxima frequência de rotação da bomba, formam o envelope operacional dos sistemas BCS. Posteriormente, Delou, Souza e Secchi (2020) compararam estratégias de interpolação de modelos com resultados equivalentes para compor a versão do MPC adaptativo múltiplos modelos.

É importante ressaltar que as técnicas citadas até o momento não apresentam garantias de implementação nas leis de controle. Para isso, Fontes et al. (2020) introduziram um MPC estabilizante para instalações BCS com factibilidade garantida (uma lei de controle que sempre produzirá uma solução para o problema de otimização), na forma de MPC de horizonte infinito (IH MPC) com variáveis de folga (*slack*) e usando um esquema de controle por faixa para incluir explicitamente as restrições do envelope operacional e suavizar o problema de otimização com o uso de *set-points* artificiais (GONZÁLEZ; ODLOAK, 2009). O controlador incorpora um objetivo econômico de minimizar o consumo de energia da BCS, embora seja baseado em um modelo linear para região de operação única. Esse trabalho foi estendido por Santana et al. (2021), buscando mais rendimento mediante uma formulação adaptativa, que consiste na linearização sucessiva do modelo fenomenológico não linear, necessitando de um conhecimento *a priori* sobre este modelo. Outra extensão de Fontes et al. (2020) foi apresentada em Fontes, Santana e Martins (2022) como uma nova abordagem econômica de sintonia online de MPC para campos petrolíferos com instalações BCS. O método visa avaliar o impacto de diferentes objetivos econômicos para encontrar sistematicamente parâmetros adequados de ajuste do MPC, como maximização da produção, minimização do consumo de energia e maximização do lucro, sem comprometer a segurança operacional da BCS.

A linha de pesquisa mais recente está associada ao MPC não linear (NMPC). Jordano et al. (2022) propuseram o uso de uma estratégia baseada em dados com redes neurais de estado de eco (*echo state networks*) como modelos de predição em duas formulações NMPC. No entanto, as restrições do envelope operacional da BCS não foram consideradas explicitamente nas formulações do controlador e o tempo médio de execução para resolver a lei NMPC em um ambiente de simulação foi superior a cinco vezes o tempo de amostragem adotado, atingindo a ordem de segundos. Este fato indica uma implementação embarcada possivelmente impraticável em tempo real. Paralelamente, Santana, Fontes e Martins (2022) apresentaram uma formulação NMPC por faixa para sistemas BCS, caracterizada por sua aplicabilidade em tempo real, apresentando um processamento na ordem de milissegundos. As restrições do envelope operacional da BCS são incluídas pela abordagem de controle por faixa e a capacidade de acomodar a falta de medições, através do uso de um estimador de estados não linear.

Os trabalhos apresentam, no geral, um processo de exploração de técnicas de controle avançado para o sistema BCS, naturalmente partindo das estruturas lineares em direção às estruturas não lineares. Levando-se a formação de casos extremos, quando se com-

para a abordagem de modelo (e sua capacidade de representação da dinâmica), com o custo prático de validar essa tecnologia. Dessa problemática surge um compromisso entre propor uma técnica de controle suficientemente representativa e menos custosa em sua implementação e maturidade, além da necessidade de agregar garantias de sua eficiência e implementação. A Figura 1.2 permite visualizar a distribuição dos principais trabalhos comentados sobre essa problemática, trazendo destaque para as técnicas adaptativas, em especial para as que se baseiam em modelos dinâmicos extraídos de dados, capazes de absorver características dinâmicas dificilmente modeladas nas abordagens fenomenológicas, como a operação multifásica, não abordada nos trabalhos citados.

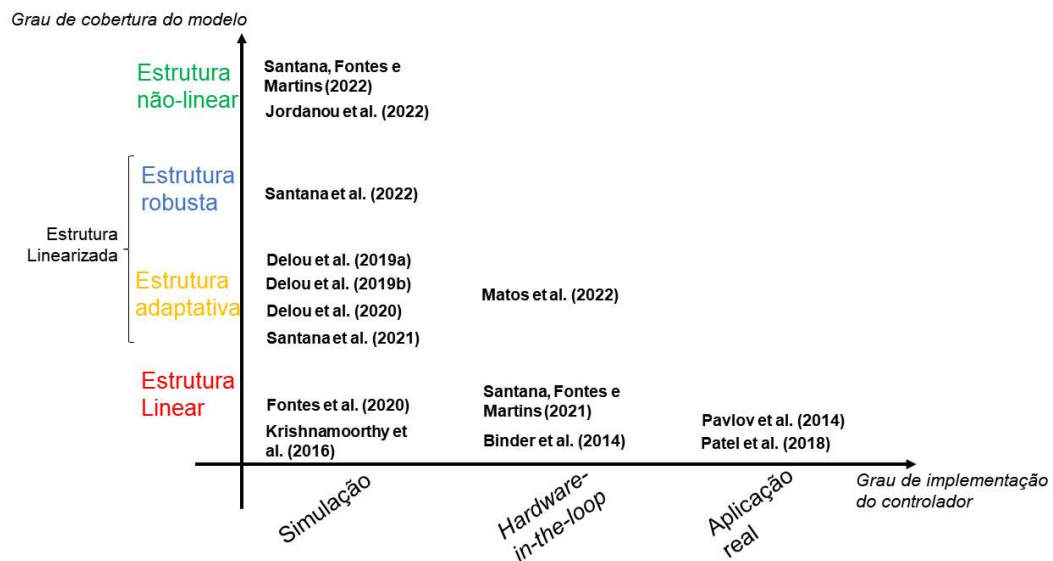


Figura 1.2: Distribuição da literatura acerca das abordagens de modelo de previsão e aplicação do controlador ao sistema BCS.

Fonte: Autor.

A proposta de controle apresentada aqui inicia o desenvolvimento do uso de dados para modelagem em conjunto a um problema de controle que pode ser implementado em tempo real, utilizando para isso, uma abordagem adaptativa, equilibrando o custo computacional entre abordagens lineares e não lineares. Descreve-se aqui, mais detalhadamente, uma técnica de MPC adaptativo composto de um modelo de previsão na forma *fuzzy*, o qual foi obtido por meio de dados do sistema BCS. A lei de controle em questão agrega as características do IHMPC proposto por Fontes et al. (2020) e estende o trabalho de Santana et al. (2021), sem a necessidade de linearizações sucessivas de um modelo não linear fenomenológico previamente conhecido. Além disso, mantém a garantia de factibilidade da lei de controle, o que permitiu validar sua implementação em uma plataforma embarcada relevante.

1.2 OBJETIVOS

Desenvolver uma técnica de MPC adaptativo para aplicação direta em sistemas de produção de petróleo e gás do tipo BCS, utilizando o controle preditivo em conjunto com modelo

fuzzy para embarque em sistema de controle dedicado.

Alguns objetivos específicos deste trabalho são:

- Definir uma topologia *fuzzy* para representar dinâmicas e restrições típicas na elevação artificial de petróleo do tipo BCS;
- Determinar o algoritmo adequado para treinamento do modelo *fuzzy*;
- Sintetizar uma lei de controle preditivo baseada no modelo *fuzzy* com garantia de factibilidade;
- Propor uma arquitetura para embarcar o controlador proposto em um microcontrolador;
- Testar e validar o sistema de controle por simulação *hardware-in-the-loop*.

1.3 CONTRIBUIÇÕES

Durante a realização desta pesquisa foram compilados os resultados relevantes na forma de publicações científicas, tais quais:

- Matos, Victor S. and Chagas, Thiago P. and Martins, Márcio A.F. Integração de modelo fuzzy tsk em um controlador preditivo com região viável estendida. In: *15^o Simpósio Brasileiro de Automação Inteligente*. Rio Grande: [s.n.], 2021.
- MATOS, V. S. et al. Embedded predictive controller based on fuzzy linear parameter-varying model: A hardware-in-the-loop application to an esp-lifted oil well system. *Digital Chemical Engineering*, v. 5, p. 100054, 2022. ISSN 2772-5081. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772508122000448>.
- SANTANA, B. et al. Robust Model Predictive Control Applied to an ESP-lifted Oil Well System. In: *Anais do Congresso Brasileiro de Automática 2022*. sba-bra, 2022. Disponível em: https://www.sba.org.br/cba2022/wp-content/uploads/artigos_cba2022/paper_4456.pdf.

1.4 ORGANIZAÇÃO DO TRABALHO

Esse texto está organizado por cinco capítulos, sendo eles:

- **Capítulo 1** - Contextualiza o projeto, apresenta suas motivações, objetivos e contribuições;
- **Capítulo 2** - Apresenta o referencial teórico do trabalho;
- **Capítulo 3** - Propõe-se a técnica de controle avançado;
- **Capítulo 4** - Determina-se as etapas de teste e validação do projeto;

- **Capítulo 5** - Apresenta-se resultados da técnica proposta aplicada sobre o sistema BCS;
- **Capítulo 6** - Comenta-se as considerações finais e são apresentadas as propostas consecutivas.

Neste capítulo é apresentado o embasamento teórico do projeto, com detalhamento do sistema BCS, da técnica de modelagem e do problema de controle MPC de horizonte infinito no qual a técnica proposta se baseará.

REFERÊNCIAL TEÓRICO

2.1 ELEVAÇÃO ARTIFICIAL POR BOMBEIO CENTRÍFUGO SUBMERSO

O sistema de bombeio centrífugo submerso adiciona energia ao fluido, permitindo sua extração dos poços. Um motor elétrico é acoplado mecanicamente a uma bomba centrífuga, que cria uma diferença de pressão entre a entrada e saída da bomba. O fluido emerge do reservatório para o fundo do poço, e a bomba impulsiona o fluido para a superfície do poço, despejando-o no *manifold* que interliga aos demais poços existentes no sítio de produção. Um diagrama típico de um sistema BCS pode ser visto na Figura 2.1.

A dinâmica que caracteriza o funcionamento de um sistema BCS foi inicialmente proposta por Pavlov et al. (2014) e estendido por Binder, Pavlov e Johansen (2015) na forma de um modelo fenomenológico a parâmetros concentrados e será usado como objeto de estudo deste trabalho. As equações diferenciais são apresentadas

$$\begin{cases} \frac{dp_{wh}(t)}{dt} = 1.54 \times 10^8 (q_p(t) - q_c(t)), \\ \frac{dp_{bh}(t)}{dt} = 0.8584 (p_r(t) - p_{bh}(t)) - 3.7 \times 10^8 q_p(t), \\ \frac{dq_p(t)}{dt} = 5.02 \times 10^{-9} [p_{bh}(t) - p_{wh}(t) - 6.30 \times 10^8 q_p(t)^{1.75} \\ + 9.32 \times 10^3 (H(t) - 1 \times 10^3)], \\ \frac{df(t)}{dt} = (f_{ref}(t) - f(t)) \cdot \Delta f_{max}, \\ \frac{dz_c(t)}{dt} = (z_{c_{ref}}(t) - z_c(t)) \cdot \Delta z_{c,max}. \end{cases} \quad (2.1)$$

e equações algébricas auxiliares

$$q_c(t) = 2 \times 10^{-5} z_c(t) \sqrt{p_{wh}(t) - p_m(t)}, \quad (2.2)$$

$$\begin{aligned} P(t) &= 4.77 \times 10^{-1} f^3(t) + 1.41 \times 10^3 q_p(t) f^2(t) - 3.74 \times 10^5 q_p^2(t) f(t) \\ &\quad - 3.12 \times 10^9 q_p^3(t), \end{aligned} \quad (2.3)$$




Figura 2.1: Esquema do sistema BCS.
Fonte: Adaptado de Fontes et al. (2020).

Segundo Binder, Pavlov e Johansen (2015), apenas algumas saídas são comumente mensuradas no sistema, tais como

$$\begin{cases} p_{in}(t) = p_{bh}(t) - 1.85 \times 10^8 q_p^{1.75}(t) - 1.9 \times 10^6, \\ H(t) = 0.2664 f(t)^2 + 133.09 f(t) q_p(t) - 1.41 \times 10^6 q_p^2(t), \end{cases} \quad (2.4)$$

onde p_m , p_{wh} , p_{in} , p_{bh} e p_r são as pressões de *manifold*, cabeça do poço, entrada, fundo do poço e reservatório em Pa, respectivamente; f é a frequência de rotação real da bomba em Hz, f_{ref} é a entrada de frequência de referência; z_c é a abertura da válvula *choke* de produção em % e $z_{c_{ref}}$ é seu valor de entrada; H é a altura manométrica da bomba em m; q_p e q_c são as vazões medias da coluna de produção e da válvula *choke*, respectivamente, em m^3/s ; P é a potência elétrica consumida pela bomba em watts que pode ser usada para avaliar aspectos econômicos do funcionamento da BCS. O sistema tem dinâmica

restrita nos atuadores (motor elétrico e válvula), como a máxima variação de frequência Δf_{max} e a máxima variação de abertura da válvula *choke* $\Delta z_{c,max}$.

As premissas adotadas para a composição desse modelo são:

- $p_{wh} > p_m$: Sem fluxo de retorno pela válvula *choke*;
- O fluido é considerado incompressível;
- As propriedades do fluido não se alteram ao longo do interior da bomba;
- A vazão média é considerada a vazão por todas as partes do sistema;
- Fatores de correção de viscosidade foram incluídos em Binder, Pavlov e Johansen (2015) na forma de curvas e já estão integrados ao modelo apresentado, sendo responsáveis por corrigir a potência, a altura manométrica e a vazão média em função da mudança de viscosidade do fluido conforme seu valor de operação, aqui adotado como 25 cP (ou 0,025 Pa·s).

A região de operação segura da BCS é conhecida como o envelope operacional (região em vermelho na Figura 2.1), determinada pelas curvas de frequências mínima e máxima de rotação e também pelas curvas de *upthrust* e *downthrust*, resultando em uma restrição variável no tempo. Outras restrições como a variação máxima de frequência Δf_{max} e a variação máxima de abertura da válvula *choke* $\Delta z_{c,max}$ precisam ser consideradas. Além disso, os sistemas de produção de poços de petróleo estão sujeitos a distúrbios operacionais típicos, tais como pressões de *manifold* e de reservatório, ou nas propriedades do fluido (e.g. densidade, viscosidade, número de fases) (SANTANA et al., 2021), e precisam ser considerados pelo projeto de controle.

Como comentado na Seção 1.1, algumas abordagens de controle foram propostas para a BCS com diferentes escolhas das variáveis manipuladas (MV) e controladas (CV). Dentre as MVs, podem ser utilizadas a frequência rotacional da bomba e a abertura da válvula *choke* (PAVLOV et al., 2014), corrente elétrica (BINDER et al., 2014), ou até tensão elétrica na bomba (KRISHNAMOORTHY et al., 2016). Como o principal objetivo do controle de sistemas BCS é ajustar a sua taxa de produção, para isso já foi utilizado o controle da pressão de entrada e diretamente a vazão de produção (KRISHNAMOORTHY et al., 2016). De forma geral, a escolha das variáveis de controle depende da disponibilidade de sensores e dos objetivos de controle considerados.

2.2 IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS NÃO LINEARES

Sistemas não lineares, tal qual o sistema BCS, são a caracterização do mundo físico real. No geral, eles apresentam comportamentos complexos que podem não ser facilmente modeláveis, levando-se em consideração a abordagem fenomenológica do problema. Portanto, para caracterizar um sistema não linear é preciso identificar a estrutura ou os parâmetros que melhor modelam sua dinâmica. O objetivo desta seção é apresentar os principais conceitos acerca da identificação de sistemas não lineares.

A identificação de sistemas não lineares pode ser amplamente classificada em três categorias: métodos paramétricos, não paramétricos e híbridos (NELLES, 2020). Os

métodos paramétricos assumem uma estrutura de modelo específica e visam a estimar os parâmetros do modelo (LJUNG, 1999). Exemplos comuns de métodos paramétricos incluem o Filtro de Kalman Estendido, o Filtro de Kalman *Unscented* e o Filtro de Partículas. Os métodos não paramétricos, por outro lado, não assumem uma estrutura de modelo específica e estimam o comportamento do sistema com base em dados (BILLINGS, 2013). Exemplos de métodos não-paramétricos incluem redes neurais, sistemas de inferência *fuzzy* e processos gaussianos. Os métodos híbridos combinam métodos paramétricos e não paramétricos, para melhor modelar o sistema em estudo. Dentre os métodos híbridos, temos o modelo NARMAX (*Nonlinear AutoRegressive Moving Average with eXogenous inputs*) (BILLINGS, 2013).

As etapas comuns na identificação de sistemas não lineares incluem:

1. Coleta de dados: obtenção de dados de entrada e saída do sistema em estudo, com o objetivo de extrair informações do mesmo em todo o universo de operação de suas variáveis. Para isso, injetam-se em suas entradas sinais persistentemente excitantes, ricos em frequência e em variações de amplitude. Estes sinais precisam satisfazer algumas condições (AGUIRRE, 2015), tais como:
 - Sinal rico em frequência: pela interpretação numérica, busca-se o uso de sinais menos constantes, ou seja, com mais aleatoriedade possível, de forma que o problema de identificação seja numericamente melhor condicionado. No sentido dinâmico, o sinal de excitação deve ter energia suficiente na faixa de frequência dominante do sistema, ou seja, é preciso excitar os modelos dominantes que se deseja identificar, por isso indica-se o uso de sinais de característica similar a um ruído branco.
 - Amplas variações de amplitude: dizem respeito à necessidade de observar as características estáticas e dinâmicas do sistema não linear, atingindo diferentes condições de operação do sistema.
 - Entradas não correlacionadas: para a identificação de sistemas com múltiplas entradas é necessário que os sinais de excitação usados não sejam correlacionados entre si, de forma que o efeito de cada entrada sobre a saída seja perceptível pelo algoritmo de identificação.

Os sinais de excitação mais comumente usados para identificação de sistemas não lineares são sinais periódicos, sinais multissenoidais e sinais binários (PINTELO; SCHOUKENS, 2012). Sinais periódicos, tais como sinais senoidais e sinais de *chirp* têm um espectro de frequência bem definido e são fáceis de gerar. Entretanto, eles podem não excitar toda a dinâmica do sistema, particularmente as não linearidades, e podem não fornecer informações suficientes para estimar com precisão os parâmetros do sistema. Os sinais multissenoidais, por outro lado, são sinais de banda larga que podem excitar uma ampla gama de frequências e são particularmente adequados para sistemas lineares. Entretanto, eles podem não ser adequados para sistemas não lineares invariantes no tempo, não sendo capazes de excitar todas as não-linearidades do sistema. Sinais binários, tais como sequências binárias

pseudo-aleatórias (PRBS), têm um espectro de potência bem definido e demonstram ser particularmente eficazes para a identificação de sistemas não lineares (BILLINGS, 2013). Deste grupo surgem variações, como a Sequência pseudo-aleatórias moduladas em amplitude (*Amplitude Modulated Pseudo-Random Bit Sequences - APRBS*), que inclui uma componente de modulação de amplitude adicional. A modulação de amplitude permite que os sinais APRBS tenham um maior conteúdo de energia em baixas frequências, o que pode ajudar a excitar estes modos de um sistema de forma mais eficaz, como na identificação de sistemas e estruturas mecânicas (PINTELO; SCHOUKENS, 2012).

2. Seleção de estrutura de modelos: processo de seleção de uma estrutura de modelo apropriada para o sistema em estudo. Diversas abordagens podem ser empregadas para representar um sistema não linear, levando em consideração a forma de processar o problema de identificação e o nível de conhecimento especialista *a priori* sobre o sistema, resultando na nomenclatura caixa preta, cinza e branca, conforme o uso desse conhecimento. Algumas abordagens de representação típicas para sistemas não lineares são (AGUIRRE, 2015; PINTELO; SCHOUKENS, 2012; NELLES, 2001; BILLINGS, 2013):

- Média móvel auto-regressiva não linear com entradas exógenas (*Nonlinear Auto-regressive Moving Average with exogenous inputs - NARMAX*): uma abordagem popular de caixa preta para identificação de sistemas não lineares. O modelo NARMAX consiste de um conjunto de termos não lineares auto-regressivos e média móvel, juntamente com entradas exógenas. O modelo é estimado usando métodos baseados em dados, tais como estimativas de mínimos quadrados ou máxima probabilidade.
- Série Volterra: A série Volterra é uma abordagem de caixa cinza que modela um sistema não linear como uma série de termos lineares e não lineares. Os termos lineares representam a resposta de impulso do sistema, enquanto os termos não lineares representam as não linearidades de ordem superior do sistema. A série Volterra pode ser estimada usando métodos mínimos quadrados ou baseados em kernel.
- Modelos Hammerstein-Wiener: Os modelos Hammerstein-Wiener são uma abordagem de caixa cinza que combina uma função estática não linear com um sistema dinâmico linear. A não linearidade estática pode ser modelada usando uma rede neural ou uma função polinomial, enquanto o sistema dinâmico linear pode ser modelado usando a função de transferência ou modelos de espaço de estado.
- Modelos de espaço de estado: Os modelos de espaço de estado são uma abordagem de caixa cinza que representa um sistema não linear usando um conjunto de equações diferenciais. O modelo de espaço-estado pode ser estimado usando métodos como a estimativa de máxima probabilidade ou a filtragem de Kalman.

- Redes Neurais: As redes neurais são uma abordagem popular de caixa-preta para identificação de sistemas não lineares. Esta abordagem utiliza um mapeamento não linear entre as entradas e saídas de um sistema, onde o mapeamento é representado por um conjunto de neurônios artificiais interconectados organizados em múltiplas camadas. Os pesos e desvios da rede neural são ajustados para minimizar a diferença entre as saídas previstas e reais do sistema, sendo o processo de treinamento, prioritariamente realizado por retropropagação do erro entre os dados e o modelo.
 - Sistema de inferência *fuzzy*: Baseado em lógica nebulosa, é uma abordagem popular para identificação de sistemas não-lineares, inicialmente apresentado para esse fim em Takagi e Sugeno (1985). Esta técnica pode ser considerada caixa cinza e que se baseia em um conjunto de regras *fuzzy* para descrever a relação entre as variáveis de entrada e saída. Estas regras são construídas usando um conjunto de variáveis linguísticas (o que permite agregar interpretabilidade e conhecimento especialista ao modelo) e funções de pertinência, que descrevem o grau de adesão das variáveis de entrada a diferentes termos linguísticos (BEZDEK, 2013), permitindo lidar com incerteza e imprecisão nos dados de entrada e saída (AGUIRRE, 2015).
3. Estimativa de parâmetros do modelo: obter numericamente os parâmetros do modelo a partir dos dados de entrada/saída. De forma geral, a obtenção dos parâmetros ocorre paralelamente à definição ou estudo da estrutura do modelo, dentre as técnicas comumente empregadas para obtenção dos parâmetros destacam-se os estimadores derivados do estimador de mínimos quadrados (MQ). Contudo, estes tem aplicação válida somente para modelos aos quais os parâmetros são linearmente dependentes. Em caso de estruturas com parâmetros não lineares, tais quais redes neurais multicamadas, faz-se necessário técnicas de otimização não lineares, como citadas por Aguirre (2015).
 4. Teste do modelo: avaliação do desempenho do modelo usando dados de teste, separados dos dados usados para a estimativa de parâmetros. É necessário garantir a capacidade de generalização do modelo, de forma que esse seja capaz de estimar o comportamento do sistema de forma independente para novos dados de entrada aplicados. Isso se dá através da separação dos dados usados na identificação, de forma que essa parcela dos dados de teste seja independente e nunca utilizada na identificação, podendo ser uma parcela dos dados experimentais ou um segundo experimento dedicado. De forma estatística, pode-se empregar técnicas como a validação cruzada *k-fold*, que envolve dividir o conjunto de dados em k subconjuntos (ou “dobras”) e usar $k - 1$ subconjuntos para treinar o modelo e o subconjunto restante para teste. Este processo é repetido k vezes, com cada subconjunto usado para teste uma vez. O desempenho do modelo é então avaliado com base na média dos k resultados da teste (LJUNG, 1999).

Além disso, o processo de teste de um modelo obtido precisa ser realizado para infinitos passos a frente, ou seja, o modelo sendo utilizado independentemente do

sistema original, resultando em resposta similar para uma mesma entrada do sistema real. Não é prudente, portanto, apenas estimar o próximo instante, uma vez que isso não mede a capacidade de estimação e uso do modelo (AGUIRRE, 2015; NOWAK, 2002).

5. Refinamento do modelo: modificação da estrutura do modelo ou o ajuste dos parâmetros do modelo se o modelo não tiver um bom desempenho sobre os dados de teste.

De forma geral, a identificação de sistemas não lineares pode apresentar um aumento significativo no custo e necessidade de processamento se comparado a abordagens com elementos lineares, o que gera um especial destaque para as abordagens híbridas, que aproximam dinâmicas não lineares por subelementos lineares, podendo ou não incorporar o conhecimento *a priori*, agregando-o com a capacidade de representação de dados. A próxima Seção 2.3 abordará uma técnica com essas características.

2.3 MODELAGEM FUZZY DE SISTEMAS DINÂMICOS NÃO LINEARES

Os sistemas de inferência *fuzzy* (do inglês *Fuzzy Inference System* - FIS) são baseados na lógica difusa e têm a capacidade de representar de forma interpretável, com base na linguagem e na lógica humanas, o conhecimento sobre determinado sistema (WANG, 1997). Essa capacidade de representação do FIS o torna um aproximador universal de funções, para o número de regras irrestrito (JANG; SUN; MIZUTANI, 1997; SCHNITMAN, 2001).

A estrutura básica do FIS é composta pela base de regras, que contém as regras na forma SE-ENTÃO; pelo banco de dados, que contém as funções de pertinência caracterizadoras dos conjuntos *fuzzy* associados às variáveis; e pelo mecanismo de raciocínio, que aplica o procedimento de inferência (JANG; SUN; MIZUTANI, 1997). Essa estrutura é realizada conforme Figura 2.2, na qual as variáveis de entrada se associam com as regiões *fuzzy* conforme o antecedente de cada regra, enquanto as saídas são definidas pelas regiões *fuzzy* correspondentes.

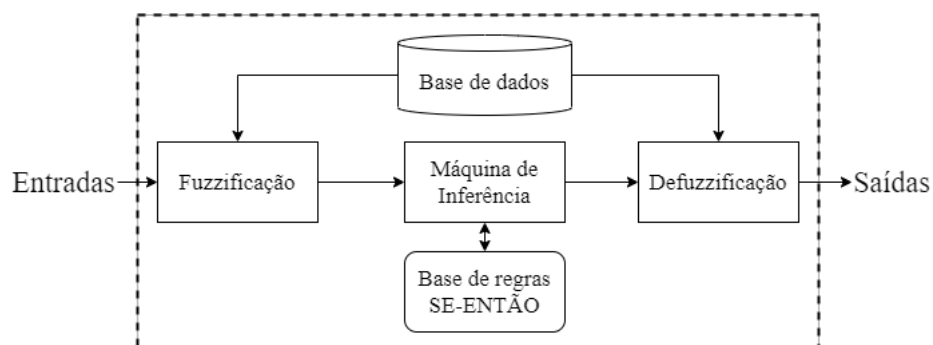


Figura 2.2: Estrutura interna do sistema de inferência *fuzzy*.

Fonte: Autor.

2.3.1 Topologia Takagi-Sugeno-Kang (TSK)

Dentre as topologias de FIS existentes, a proposta em Takagi e Sugeno (1985) e em Sugeno e Kang (1988) tem como consequentes de suas regras equações lineares.

A forma da regra TSK é

$$R_i : \text{SE } z_1 \text{ é } Z_{i,1} \text{ e } \dots \text{ e } z_q \text{ é } Z_{i,q} \text{ ENTÃO } \hat{y}_i = f_i(z_1, \dots, z_q), \quad (2.5)$$

em que R_i indica i -ésima regra (para $i = 1, 2, \dots, p$), formada pelo termo antecedente (SE) que caracteriza a região *fuzzy* $Z_{i,j}$ das j -ésimas entradas z_j (para $j = 1, 2, \dots, q$), representada por seu grau de pertinência $\mu_{i,j}(z_j)$ (valor entre 0 e 1 que indica o grau de pertencimento do valor da respectiva entrada àquela região, representada pela função de pertinência). O consequente da regra (ENTÃO) indica a correspondência à saída \hat{y}_i aproximada pelo FIS, sendo que f_i pode ser uma função linear constante (TSK de ordem zero) ou afim (TSK de ordem 1) (WANG, 1997).

As funções de pertinência, que definem o grau de inclusão dos dados em determinada partição (ou grupo), podem ter diversas formas, sendo as mais comuns, as gaussianas, em que

$$\mu_{i,j}(z_j) = e^{\left(-\frac{(z_j - c_{i,j})^2}{2\sigma_{i,j}^2}\right)}, \quad (2.6)$$

sendo os centros $c_{i,j}$ e os desvios-padrão $\sigma_{i,j}$ de cada $\mu_{i,j}(z_j)$. Os formatos triangulares e retangulares também são possíveis.

O antecedente de cada regra quando computado, gera um peso de ativação decorrente do produto das pertinências de cada entrada (TAKAGI; SUGENO, 1985). Esse peso é normalizado

$$\bar{w}_i(\mathbf{z}) = \frac{\prod_{j=1}^q \mu_{i,j}(z_j)}{\sum_{i=1}^p \prod_{j=1}^q \mu_{i,j}(z_j)}, \quad (2.7)$$

posteriormente, multiplicado pela função do respectivo consequente e por fim, todas as contribuições são somadas, gerando a saída correspondente equivalente à soma ponderada das saídas individuais

$$\hat{y} = \sum_{i=1}^p \bar{w}_i(\mathbf{z}) \hat{y}_i. \quad (2.8)$$

2.3.2 Modificação multimodelos em espaço de estados

Se os consequentes das regras na topologia TSK forem substituídos por modelos dinâmicos lineares, o FIS se torna capaz de aproximar um sistema não linear por múltiplos modelos lineares (MENDES, 2008). Dessa forma, pode ser tratado como um modelo linear de parâmetros variáveis (*Linear Parameter Varying* - LPV) (MENDES; YONEYMA, 2007).

Um destaque desse sistema é a possibilidade de agregar conhecimento empírico da planta a ser modelada junto aos dados da sua dinâmica, ampliando as possibilidades de identificação. Dentre suas topologias, a apresentada em Takagi e Sugeno (1985) se baseia em dividir um sistema não linear em submodelos lineares, cujas contribuições individuais são ponderadas à medida que as variáveis de entrada se associam com tais regras.

Um sistema não linear escrito na forma discreta

$$\mathbf{x}(k+1) = f(\mathbf{x}(k), \mathbf{u}(k)), \quad (2.9)$$

sendo \mathbf{x} suas variáveis de estado (assumindo-se que são medidas) e \mathbf{u} , as variáveis de entrada ou variáveis manipuladas. A regra *fuzzy* pode assumir a forma

$$\begin{aligned} R_i : \quad & SE \ z_1(k) \text{ is } Z_{i,1} \text{ e... e } z_q(k) \text{ é } Z_{i,q} \\ & ENTÃO \ \delta\hat{\mathbf{x}}_i(k+1) = \mathbf{A}_i\delta\mathbf{x}(k) + \mathbf{B}_i\delta\mathbf{u}(k), \end{aligned} \quad (2.10)$$

onde $i = 1, \dots, p$. A componente *SE* da regra está relacionada com as entradas e seus respectivos conjuntos *fuzzy* $Z_{i,j}$, representados pelas funções de pertinência, que, na prática, podem definir as regiões de operação do sistema dinâmico. A componente *ENTÃO* é relacionada com os submodelos lineares das regiões de operação *fuzzy*. Na forma espaço de estados, o $\delta\hat{\mathbf{x}}_i$ é a variação estimada do estado em torno do ponto de operação do respectivo submodelo $(\mathbf{x}_i^{ss}, \mathbf{u}_i^{ss})$. Aqui, considera-se o ponto de operação como a média da função de pertinência Gaussiana. $\mathbf{A}_i \in \mathbb{R}^{n \times n}$ é a matriz de transição de estados, $\mathbf{B}_i \in \mathbb{R}^{n \times nu}$ é a matriz de entradas. A estrutura aqui apresentada pode ser disposta conforme diagrama da Figura 2.3, em que cada camada realiza uma das operações apresentadas da seção anterior. A camada 1 é a camada de fuzzificação dos dados de entrada, a camada 2 implica os antecedentes de cada regra, a camada 3 normaliza os pesos, a camada 4 agrega as saídas das regras e a camada 5 defuzzifica.




Figura 2.3: Topologia TSK indicando cada operação por meio de camadas.

Fonte: Mendes (2008)

A estrutura *fuzzy* agrega cada regra e resulta em:

$$\begin{aligned}\hat{\mathbf{x}}(k+1) &= \sum_{i=1}^p \bar{w}_i(\mathbf{z}(k)) \mathbf{A}_i \delta \mathbf{x}(k) + \bar{w}_i(\mathbf{z}(k)) \mathbf{B}_i \delta \mathbf{u}(k) + \bar{w}_i(\mathbf{z}(k)) \mathbf{x}_i^{ss} \\ &= \bar{\mathbf{A}}(k) \delta \mathbf{x}(k) + \bar{\mathbf{B}}(k) \delta \mathbf{u}(k) + \bar{\mathbf{x}}^{ss}\end{aligned}\quad (2.11)$$

onde as variáveis de entrada *fuzzy* são $\mathbf{z}(k) = [z_1(k), \dots, z_q(k)]$, e \bar{w}_i são o peso normalizado de cada regra. O modelo resultante é um modelo LPV, no qual as matrizes $\bar{\mathbf{A}}(k)$ e $\bar{\mathbf{B}}(k)$ são atualizadas pela topologia TSK. De forma geral, nesta estrutura de modelo o espaço antecedente mapeia o espaço de estados do sistema em p regiões, e, através das regras, correspondem a p modelos lineares locais. Estes modelos formam uma estrutura de politopo, no qual os possíveis modelos resultantes da combinação *fuzzy* estão contidos nessa região, conforme diagrama da Figura 2.4.

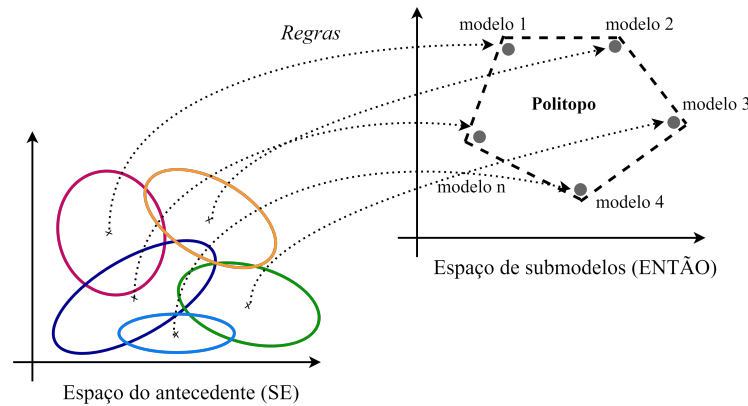


Figura 2.4: Mapeamento *fuzzy* das regiões de operação.

Fonte: Adaptado de Babuška (1998).

Para mais informações sobre modelos *fuzzy* e aspectos de modelagem, considerar as seguintes referências Babuška (1998), Nelles (2001) e Abonyi (2003).

2.3.3 Estratégia de identificação do modelo com base em dados

Identificar o modelo TSK é equivalente a definir as regiões *fuzzy* correspondentes a cada variável de entrada do FIS e a cada regra, assim como definir as matrizes \mathbf{A}_i e \mathbf{B}_i de cada submodelo.

2.3.3.1 Determinação dos antecedentes

A definição dos antecedentes se baseia, de modo geral, em particionar o espaço dos dados das variáveis de entrada *fuzzy* (\mathbf{z}) para melhor englobá-los e representar essas partições através das funções de pertinência correspondentes, determinando os parâmetros que as caracterizam.

O procedimento de determinação dos antecedentes das regras pode ser feito através do particionamento em grade (*grid partitioning*) ou por algum método de clusterização

(BABUŠKA, 1998), que agrupa os dados com base em métricas e definem, por exemplo, os centros e os desvios-padrão de funções de pertinência gaussianas. É importante salientar que os métodos de clusterização têm a tendência de reduzir o número de regras geradas, em comparação ao método de grade, evitando a chamada “maldição da dimensionalidade” (ABONYI, 2003).

É possível utilizar os resultados do agrupamento como valores iniciais para uma sintonia fina do modelo através da otimização dos parâmetros das funções de pertinência (ABONYI, 2003). Nesse contexto, os algoritmos que aplicam o conceito de retropropagação do erro, comum em redes neurais, podem ser utilizados para ajustar estes termos a fim de minimizar o erro entre o modelo e o sistema real. Esses algoritmos podem ser baseados em gradiente ou técnicas livre de derivadas (JANG; SUN; MIZUTANI, 1997). Segundo Karaboga e Kaya (2019), se destacam como algoritmos de otimização aplicados na identificação de modelos *fuzzy* o algoritmo de Levenberg-Marquardt (LEVENBERG, 1944), o algoritmo genético (*Genetic Algorithm* - GA) e o algoritmo de enxame de partículas (*Particle Swarm Optimization* - PSO) (KENNEDY; EBERHART, 2016).

2.3.3.2 Determinação dos consequentes

O processo de identificação do consequente de cada regra equivale a determinar os submodelos e seus parâmetros definidos na rede TSK. É usual incluir essa busca no problema de otimização indicado na Seção 2.3.3.1 (KARABOGA; KAYA, 2019). Contudo, como os submodelos são lineares é possível empregar a técnica de MQ para determinar os parâmetros (BABUŠKA, 1998; JANG; SUN; MIZUTANI, 1997; ABONYI, 2003). Além disso, o uso da técnica dos mínimos quadrados é indicada pela sua simplicidade, uma vez que para a modificação com modelos em espaço de estados é preciso determinar as matrizes A_i e B_i que podem apresentar dimensão extensa.

Na estrutura em questão, a técnica MQ determina os N termos que compõem todos os submodelos. A aplicação dessa técnica pode considerar dois contextos, a identificação local, capaz de aproximar dinâmicas lineares locais, baseadas em pontos de operação reais; e a identificação global, que objetiva aproximar a dinâmica geral da planta em questão e que se relaciona com pontos de operação sem significado físico (BABUŠKA, 1998; MENDES, 2008). Ambos contextos podem ser aplicados a depender da dinâmica de processo a ser modelado e sua utilização.

A identificação local permite aumentar a interpretabilidade do modelo, conferindo ao mesmo a possibilidade de inclusão de conhecimento especialista, em caso de utilização de modelos lineares obtidos anteriormente da dinâmica do sistema e sua região aproximada de operação. Se o objetivo for a identificação o sistema com base em dinâmicas em pontos de operações específicos com significado físico, faz-se necessário coletar um conjunto de dados correspondente à dinâmica nesses pontos. Dessa forma, serão ajustados os $N_i = n \times (n+m)$ parâmetros que compõem $\phi_i = [A_i \ B_i]^T$ com base no problema de otimização

$$\min_{\phi_i} J = (\delta \mathbf{x} - \delta \hat{\mathbf{x}}_i(\phi_i))^T \mathbf{W}_i (\delta \mathbf{x} - \delta \hat{\mathbf{x}}_i(\phi_i)), \quad (2.12)$$

que visa minimizar o erro de trajetória entre planta

$$\delta \mathbf{x} = \begin{bmatrix} \delta \mathbf{x}(k+1)^T \\ \vdots \\ \delta \mathbf{x}(k+M)^T \end{bmatrix}_{M \times n} \quad (2.13)$$

e submodelo

$$\delta \hat{\mathbf{x}}_i(\boldsymbol{\phi}_i) = \begin{bmatrix} \delta \hat{\mathbf{x}}_i(k+1, \boldsymbol{\phi}_i)^T \\ \vdots \\ \delta \hat{\mathbf{x}}_i(k+M, \boldsymbol{\phi}_i)^T \end{bmatrix}_{M \times n} \quad (2.14)$$

no correspondente ponto de operação, $\delta \mathbf{x}(k) = \mathbf{x}(k) - \mathbf{x}_i^{ss}$ e $\delta \mathbf{u}(k) = \mathbf{u}(k) - \mathbf{u}_i^{ss}$. A matriz de pesos, que representam o índice de ativação da regra i , definidos ao longo de M instantes de amostragem é na forma de

$$\mathbf{W}_i = \text{diag}\left([w_i(k), \dots, w_i(M)]\right)_{M \times M}. \quad (2.15)$$

A predição $\delta \hat{\mathbf{x}}_i(k+1, \boldsymbol{\phi})$ é realizada através de

$$\delta \hat{\mathbf{x}}_i(k+1, \boldsymbol{\phi})^T = [\delta \mathbf{x}(k)^T \quad \delta \mathbf{u}(k)^T] \begin{bmatrix} \mathbf{A}_i^T \\ \mathbf{B}_i^T \end{bmatrix} = \delta \mathbf{z}(k) \boldsymbol{\phi}_i \quad (2.16)$$

simplificada pelo vetor $\delta \mathbf{z}(k) = [\delta \mathbf{x}(k)^T \quad \delta \mathbf{u}(k)^T]$. Assim, $\delta \hat{\mathbf{x}}_i(\boldsymbol{\phi}_i)$ assume a forma

$$\delta \hat{\mathbf{x}}_i(\boldsymbol{\phi}_i) = \begin{bmatrix} \delta \mathbf{x}(k)^T & \delta \mathbf{u}(k)^T \\ \vdots & \vdots \\ \delta \mathbf{x}(k+M-1)^T & \delta \mathbf{u}(k+M-1)^T \end{bmatrix}_{M \times (n+m)} \begin{bmatrix} \mathbf{A}_i^T \\ \mathbf{B}_i^T \end{bmatrix}_{(n+m) \times n} = \delta \mathbf{z} \boldsymbol{\phi}_i \quad (2.17)$$

e transforma (2.12) em

$$\min_{\boldsymbol{\phi}_i} J = (\delta \mathbf{x} - \delta \mathbf{z} \boldsymbol{\phi}_i)^T \mathbf{W}_i (\delta \mathbf{x} - \delta \mathbf{z} \boldsymbol{\phi}_i). \quad (2.18)$$

A fim de obter a expressão que calcula o valor de $\boldsymbol{\phi}_i$ que minimiza (2.18), simplifica-se essa expressão e faz $\frac{\partial J}{\partial \boldsymbol{\phi}_i} = 0$, levando a solução dos mínimos quadrados para

$$\boldsymbol{\phi}_i = (\delta \mathbf{z}^T \mathbf{W}_i \delta \mathbf{z})^{-1} \delta \mathbf{z}^T \mathbf{W}_i \delta \mathbf{x}, \quad (2.19)$$

resultado conhecido como MQ ponderados. Esta técnica é indicada para obtenção de modelos lineares a partir de dados de uma ampla faixa de não linearidades, de forma que a contribuição do dado no problema é ponderada pela distância do ponto de operação do modelo (AGUIRRE, 2015).

Essa abordagem pode ser implementada e calculada através da solução (2.19) pelo cálculo da pseudo-inversa (ABONYI, 2003), resultando nas correspondentes matrizes dos submodelos locais.

2.4 MPC COM GARANTIA DE ESTABILIDADE NOMINAL E FACTIBILIDADE

Para que o MPC seja considerado apto e seguro para ampla aplicação em diversos sistemas é interessante que tenha como características as garantias de estabilidade e factibilidade (SANTANA, 2020). Dentro das vertentes de estudo de MPC estabilizante, Odloak (2004) desenvolveu uma vertente na linha de custo e restrições terminais e propôs uma técnica do tipo MPC com horizonte infinito (*Infinite Horizon Model Predictive Control - IHMPC*) baseado no uso de restrições de igualdade terminais, que só mantém a garantia de estabilidade com a inclusão da garantia de factibilidade, com uso de variáveis de folga no problema de otimização, capaz de flexibilizar as restrições terminais.

2.4.1 Descrição do modelo para sistemas estáveis

Considerando que o sistema possa conter apenas polos estáveis não repetidos, então suas funções de transferência tem a forma

$$G_{i,j}(s) = \frac{b_{i,j,0} + b_{i,j,1}s + \dots + b_{i,j,nb}s^{nb}}{(s - r_{i,j,1}^{st}) \dots (s - r_{i,j,na}^{st})}, \quad (2.20)$$

em que $\{na, nb \in \mathbb{N} \mid nb < na\}$ e $r_{i,j,l}^{st}$ são os polos estáveis. A resposta ao degrau desse sistema na forma discreta

$$S_{i,j}(k\Delta t) = d_{i,j}^0 + \sum_{l=1}^{na} d_{i,j,l}^{st} e^{r_{i,j,l}^{st}(k\Delta t)}, \quad (2.21)$$

em que o período de amostragem é Δt e os termos $d_{i,j}^0$ e $d_{i,j,l}^{st}$ são os coeficientes decorrentes da expansão em frações parciais.

Escreve-se esse sistema na forma incremental em espaço de estados das entradas

$$\begin{bmatrix} \mathbf{x}^s(k+1) \\ \mathbf{x}^{st}(k+1) \end{bmatrix} = \underbrace{\begin{bmatrix} \mathbf{I}_{ny} & \mathbf{0} \\ \mathbf{0} & \mathbf{F}^{st} \end{bmatrix}}_{\mathbf{A}} \begin{bmatrix} \mathbf{x}^s(k) \\ \mathbf{x}^{st}(k) \end{bmatrix} + \underbrace{\begin{bmatrix} \mathbf{B}_0^s \\ \mathbf{B}_0^{st} \end{bmatrix}}_{\mathbf{B}} \Delta \mathbf{u}(k), \quad (2.22)$$

$$\mathbf{y}(k) = \underbrace{\begin{bmatrix} \mathbf{I}_{ny} & \mathbf{\Psi}^{st} \end{bmatrix}}_{\mathbf{C}} \begin{bmatrix} \mathbf{x}^s(k) \\ \mathbf{x}^{st}(k) \end{bmatrix}, \quad (2.23)$$

para incluir ação integral ao modelo do controlador. Esse modelo é denominado como OPOM (*Output Prediction Oriented Model*) definido por Odloak (2004).

O vetor $\mathbf{x}^s(k)$ corresponde ao estados integradores artificiais, criados pela forma incremental das entradas que equivale às saídas previstas no estado estacionário. $\mathbf{x}^{st}(k)$ são os estados estáveis. $\mathbf{x} \in \mathbb{C}^{nx}$, $\mathbf{x}^s \in \mathbb{R}^{ny}$, $\mathbf{x}^{st} \in \mathbb{C}^{nst}$, $\Delta \mathbf{u}^s \in \mathbb{R}^{nu}$, $\mathbf{y} \in \mathbb{R}^{ny}$ em que $nst = ny \cdot nu \cdot \max(na)$ e $nx = ny + nst$.

As submatrizes que compõem as matrizes \mathbf{A} , \mathbf{B} e \mathbf{C} são definidas por:

$$\mathbf{B}_0^s = d_{i,j}^0, \quad \mathbf{B}_0^{st} = \mathbf{D}^{st} \mathbf{F}^{st} \mathbf{N}^{st},$$

$$\mathbf{F}^{st} = \text{diag} \left(e^{\Delta t \cdot r_{1,1,1}^{st}} \dots e^{\Delta t \cdot r_{1,1,na}^{st}} \dots e^{\Delta t \cdot r_{ny,nu,1}^{st}} \dots e^{\Delta t \cdot r_{ny,nu,na}^{st}} \right) \in \mathbb{C}^{nst \times nst},$$

$$\mathbf{D}^{st} = \text{diag} (d_{1,1,1}^{st} \cdots d_{1,1,na}^{st} \cdots d_{ny,nu,1}^{st} \cdots d_{ny,nu,na}^{st}) \in \mathbb{C}^{nst \times nst},$$

$$\mathbf{\Psi}^{st} = \begin{bmatrix} \overbrace{1 \ 1 \ \cdots \ 1}^{nu \cdot na} & \overbrace{0 \ 0 \ \cdots \ 0}^{nu \cdot na} \\ 0 \ 0 \ \cdots \ 0 & 0 \ 0 \ \cdots \ 0 \\ \vdots \ \vdots \ \ddots \ \vdots & \vdots \ \vdots \ \ddots \ \vdots \\ 0 \ 0 \ \cdots \ 0 & 1 \ 1 \ \cdots \ 1 \end{bmatrix} \in \mathbb{R}^{ny \times nst},$$

$$\mathbf{N}^{st} = \begin{bmatrix} \mathbf{J}^{st} \\ \mathbf{J}^{st} \\ \vdots \\ \mathbf{J}^{st} \end{bmatrix} ny \in \mathbb{R}^{nst \times nu},$$

$$\mathbf{J}^{st} = \begin{bmatrix} 1 \ 0 \ \cdots \ 0 \\ \vdots \ \vdots \ \ddots \ \vdots \\ 1 \ 0 \ \cdots \ 0 \\ 0 \ 1 \ \cdots \ 0 \\ \vdots \ \vdots \ \ddots \ \vdots \\ 0 \ 1 \ \cdots \ 0 \\ \vdots \\ 0 \ 0 \ \cdots \ 1 \\ \vdots \ \vdots \ \ddots \ \vdots \\ 0 \ 0 \ \cdots \ 1 \end{bmatrix} \in \mathbb{R}^{nu \cdot na \times nu},$$

2.4.2 IHMPC com garantia de estabilidade e factibilidade para sistemas estáveis

A técnica de IHMPC se baseia no modelo OPOM definido na Seção 2.4.1 e na seguinte função custo de horizonte infinito:

$$\begin{aligned} V_k = & \sum_{j=0}^{\infty} \|\mathbf{y}(k+j|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k}\|_{\mathbf{Q}_y}^2 \\ & + \sum_{j=0}^{h_c-1} \|\Delta \mathbf{u}(k+j|k)\|_{\mathbf{R}}^2 + \|\boldsymbol{\delta}_{y,k}\|_{\mathbf{S}_y}^2, \end{aligned} \quad (2.24)$$

em que $\mathbf{Q}_y \in \mathbb{R}^{ny \times ny}$ é a matriz positiva definida de ponderação das variáveis controladas; $\mathbf{R} \in \mathbb{R}^{nu \times nu}$ a matriz positiva semi definida que pondera as variações dos esforços de controle; $\mathbf{y}(k+j|k)$ é o vetor de predição da saída no instante $k+j$ calculado no instante k ; $\mathbf{y}_{sp,k}$ é o vetor de referência; $\Delta \mathbf{u}(k+j|k)$ é o vetor de variações de esforço de controle; $\boldsymbol{\delta}_{y,k} \in \mathbb{R}^{ny}$ é a variável de folga (*slack*) utilizadas para garantir a factibilidade do problema de otimização. $\mathbf{S}_y \in \mathbb{R}^{ny \times ny}$ é uma matriz positiva definida que pondera a atuação das variáveis de folga de forma que estas sejam levadas a zero ou minimizadas.

A (2.24) pode ser manipulada para a seguinte forma

$$\begin{aligned}
V_k &= \sum_{j=0}^{h_c} \|\mathbf{y}(k+j|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k}\|_{\mathbf{Q}_y}^2 \\
&\quad + \sum_{j=1}^{\infty} \|\mathbf{y}(k+h_c+j|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k}\|_{\mathbf{Q}_y}^2 \\
&\quad + \sum_{j=0}^{h_c-1} \|\Delta \mathbf{u}(k+j|k)\|_{\mathbf{R}}^2 + \|\boldsymbol{\delta}_{y,k}\|_{\mathbf{S}_y}^2.
\end{aligned} \tag{2.25}$$

Do sistema (2.22), escreve-se

$$\begin{aligned}
\mathbf{y}(k+h_c+j|k) &= \mathbf{C} \cdot \mathbf{x}(k+h_c+j|k) \\
&= \mathbf{x}^s(k+h_c|k) + \boldsymbol{\Psi}^{st} (\mathbf{F}^{st})^j \mathbf{x}^{st}(k+h_c|k),
\end{aligned} \tag{2.26}$$

e para garantir que o problema de otimização seja limitado, inclui-se a seguinte restrição terminal de igualdade

$$\underbrace{\mathbf{N}_s (\mathbf{A}^{h_c} \mathbf{x}(k) - \mathbf{A} \mathbf{W} \Delta \mathbf{u}_k)}_{\mathbf{x}^s(k+h_c|k)} - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k} = \mathbf{0}, \tag{2.27}$$

em que

$$\begin{aligned}
\mathbf{N}_s &= \begin{bmatrix} \mathbf{I}_{ny} & \mathbf{0}_{ny \times nst} & \mathbf{0}_{ny \times nun} \end{bmatrix}, \\
\mathbf{W} &= \begin{bmatrix} \mathbf{A}^{h_c-1} \mathbf{B} & \mathbf{A}^{h_c-2} \mathbf{B} & \dots & \mathbf{A} \mathbf{B} & \mathbf{B} \end{bmatrix}, \\
\Delta \mathbf{u}_k &= \begin{bmatrix} \Delta \mathbf{u}(k|k)^\top & \dots & \Delta \mathbf{u}(k+h_c-1|k)^\top \end{bmatrix}^\top.
\end{aligned}$$

A aplicação de (2.26) e da restrição (2.27) conforme adaptado de Odloak (2004), resulta

$$\begin{aligned}
V_k &= \sum_{j=0}^{h_c} \|\mathbf{y}(k+j|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k}\|_{\mathbf{Q}_y}^2 \\
&\quad + \sum_{j=0}^{h_c-1} \|\Delta \mathbf{u}(k+j|k)\|_{\mathbf{R}}^2 + \|\mathbf{x}^{st}(k+h_c|k)\|_{\overline{\mathbf{Q}}}^2 + \|\boldsymbol{\delta}_{y,k}\|_{\mathbf{S}_y}^2,
\end{aligned} \tag{2.28}$$

em que surge a termo de custo terminal ponderado pela matriz $\overline{\mathbf{Q}}$, o qual é obtida através da solução da seguinte equação de Lyapunov

$$\overline{\mathbf{Q}} = (\mathbf{F}^{st})^\top (\boldsymbol{\Psi}^{st})^\top \mathbf{Q}_y \mathbf{F}^{st} \boldsymbol{\Psi}^{st} + (\mathbf{F}^{st})^\top \overline{\mathbf{Q}} \mathbf{F}^{st}. \tag{2.29}$$

O problema de otimização do MPC proposto para sistemas com polos estáveis é na forma

$$\min_{\Delta \mathbf{u}_k, \boldsymbol{\delta}_{y,k}} V_k, \tag{2.30}$$

sujeito a (2.27) e

$$\Delta \mathbf{u}(k+j | k) \in \mathbb{U}, \quad j = 0, \dots, h_c - 1 \quad (2.31)$$

$$\mathbb{U} = \left\{ \begin{array}{l} -\Delta \mathbf{u}_{\max} \leq \Delta \mathbf{u}(k+j | k) \leq \Delta \mathbf{u}_{\max} \\ \Delta \mathbf{u}(k+j | k) = \mathbf{0}, j \geq h_c \\ \mathbf{u}_{\min} \leq \mathbf{u}(k-1) + \sum_{i=0}^j \Delta \mathbf{u}(k+i | k) \leq \mathbf{u}_{\max} \end{array} \right\} \quad (2.32)$$

Essa família de controladores IHMPC apresentam alguma características importantes que favorecem sua aplicação:

- Garantia de estabilização do sistema para cenários com modelo de predição exato, através do horizonte de predição infinito e as restrições de igualdade terminal impostas;
- Garantia de factibilidade com uso de variáveis de folga, resultando sempre na solução do problema de otimização;
- A capacidade de inclusão da abordagem de controle por faixa, que flexibiliza o problema de rastreamento em uma região aceitável através da inclusão de *set-points* artificiais.

2.5 IMPLEMENTAÇÃO DE CONTROLADORES EM SISTEMAS EMBARCADOS

A implementação de controle em sistemas embarcados envolve a integração de componentes de *software* e *hardware* dedicados para alcançar a funcionalidade de controle desejada. Nesta perspectiva, os sistemas embarcados são sistemas de computador especializados e projetados para executar tarefas ou funções específicas e constituem aplicações diversas, tais como sistemas de controle industrial, eletrônicos de consumo, dispositivos médicos e sistemas automotivos (LEE; SESHIA, 2017).

Em relação à implementação de controle, surge o conceito de malha de controle, que consiste em detectar entradas, processar os dados usando algoritmos de controle e emitir sinais de controle para atuadores ou outros dispositivos (EDWARDS et al., 1997).

Para desenvolver um sistema de controle embarcado, é essencial seguir uma série de etapas (LEDIN, 2003; FORRAI, 2012):

1. Definir requisitos do sistema: estudo sobre as variáveis de entradas e saídas e os critérios de desempenho a serem atendidos;
2. Modelar o sistema: um modelo matemático do sistema pode ser desenvolvido usando ferramentas de *software* dedicadas como MATLAB/Simulink. Este modelo pode ser usado para simular o comportamento do sistema e validar seu projeto.
3. Projetar o algoritmo de controle: Com base no modelo do sistema, um algoritmo de controle pode ser projetado para atingir os critérios de desempenho desejados. Este algoritmo pode ser desenvolvido usando linguagens de programação de alto nível e depois convertido na linguagem da plataforma de *hardware* escolhida, ou ser desenvolvido diretamente na linguagem final, especialmente a linguagem C/C++ ou *assembly*.

4. Escolher os componentes de hardware: Os componentes de hardware do sistema embarcado devem ser escolhidos com base nos requisitos do algoritmo de controle. Isso inclui a seleção de sensores e atuadores apropriados, bem como microcontroladores ou outras unidades de processamento, levando em consideração, especialmente a poder computacional e a capacidade de memória do dispositivo.
5. Desenvolver o *software*: Uma vez que o *hardware* foi selecionado, o *software* para o sistema embarcado pode ser desenvolvido. Isso inclui escrever o algoritmo de controle em código C/C++, bem como implementar quaisquer *drivers* ou interfaces necessários para os componentes de *hardware*.
6. Testar e depurar: Após o desenvolvimento do *software*, o sistema embarcado pode ser testado e depurado. Isso inclui verificar se o sistema atende aos critérios de desempenho, bem como identificar e corrigir quaisquer erros no projeto.
7. Implantar o sistema: Uma vez que o sistema embarcado foi testado e validado, ele pode ser implantado em seu aplicativo pretendido. Isso pode envolver a instalação do sistema em um ambiente físico e sua integração com outros sistemas ou componentes.

Ao incorporar um controlador em um microcontrolador, certos requisitos devem ser atendidos (FORRAI, 2012). Esses requisitos incluem poder de processamento e capacidade de memória suficientes para os algoritmos de controle necessários, recursos adequados de entrada/saída para interface com sensores e atuadores e suporte ao sistema operacional em tempo real para garantir respostas oportunas do sistema de controle. Além disso, interfaces de comunicação de baixa latência e alta largura de banda são necessárias para uma comunicação eficiente entre o controlador e outros dispositivos. O controlador também deve ter um projeto de *hardware* e *software* confiável para garantir a operação adequada em condições operacionais variadas e cumprir os padrões e regulamentos do setor, como requisitos de segurança e segurança cibernética. Por fim, a economia e a eficiência de energia são fatores cruciais a serem considerados para produção em massa e implantação em vários aplicativos.

Em se tratando do embarque de técnicas de controle ótimo, tais como o MPC, o tempo de execução da lei de controle do MPC é limitado pelo período de amostragem do sistema controlado, uma vez que esta precisa ser selecionada no intervalo de tempo de uma nova atualização do sistema. Nota-se o desenvolvimento de métodos de otimização eficientes e rápidos, a fim de viabilizar o uso do MPC em sistemas embarcados. Ferramentas de *software* para geração automática de código podem contribuir para viabilizar a aplicação, uma vez que a execução do sistema fica adaptada para condições específicas, o que pode reduzir significativamente o tempo de computação do problema (SANTANA, 2020).

Para cada uma das etapas de desenvolvimento citadas, existe um conjunto de técnicas de validação para garantir o funcionamento adequado do sistema de controle projetado. Uma metodologia de destaque é a chamada de Modelo V, indicada no diagrama da Figura 2.5, no qual o processo de desenvolvimento da aplicação é dividido em duas fases principais, que formam a estrutura em forma de V: a fase de planejamento, design e testes

de alto nível e a fase de implementação, integração e testes de baixo nível (FORRAI, 2012). Na primeira fase, os requisitos do sistema são definidos, o design do sistema é modelado e o algoritmo de controle é projetado e simulado para garantir os requisitos de desempenho. Na fase de implementação, integração e testes de baixo nível, o software é desenvolvido e integrado com o hardware e os testes são realizados para validar o desempenho do sistema.

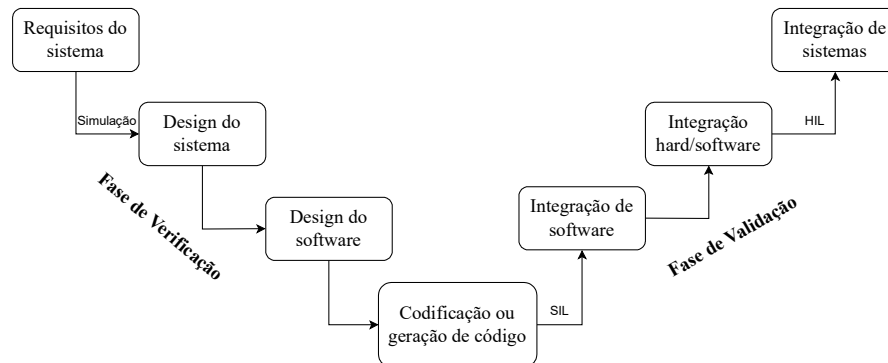


Figura 2.5: Diagrama da metodologia de projeto de *software* embarcado - modelo V.

Fonte: Autor

Na fase de validação, dois conceitos importantes surgem: *software-in-the-loop* e *hardware-in-the-loop*. Estes termos correspondem a etapas de simulação do *software* a ser embarcado, em que no primeiro conceito, os elementos planta e controlador são tratados de forma simulada, onde diversos testes podem ser feitos para verificar a funcionalidade e rendimento da proposta. Na etapa de *hardware-in-the-loop*, valida-se o controlador embarcado em *hardware* dedicado, mantendo-se a planta simulada, o que permite o teste de um sistema sob condições nominais simuladas, bem como além de seus limites operacionais pretendidos (LEDIN, 2003; FORRAI, 2012).

Neste capítulo é apresentada a contextualização das técnicas de fuzzy MPC e a versão proposta nesse trabalho.

FUZZY MPC FACTÍVEL POR FAIXA

O problema de otimização (2.30) apresentado na Seção 2.4 constitui um controlador na forma IHMPC para sistemas estáveis, com garantias de estabilidade nominal e factibilidade. Contudo, baseia-se em modelo de predição linear, inviabilizando sua aplicação em sistemas não lineares complexos. Santana et al. (2021) contornou essa realidade com a linearização contínua do modelo, mas somente a partir de modelo fenomenológico não linear do sistema. Uma vez que os controladores MPC, de modo geral, necessitam de um modelo bem representativo da dinâmica do sistema para funcionarem (CAMACHO; BORDONS, 2007), observa-se que na maioria das aplicações, a aquisição de um modelo fenomenológico pode ser custosa ou inviável, indicando que uma abordagem de modelo aproximada pode ser mais adequada, tais como as técnicas adaptativas. Além disso, uma abordagem baseada em dados pode aumentar ainda mais a aplicabilidade da técnica de controle IHMPC a sistemas com o nível de não linearidade e complexidade de uma BCS.

No que diz respeito às abordagens adaptativas de modelo de predição, pode-se considerar o uso de aproximadores universais, tais como redes neurais ou sistemas de inferência *fuzzy*. O último em questão foi apresentado na Seção 2.3, com a capacidade de manter o modelo na forma linear, mas aproximar a dinâmica não linear da planta.

Em Nakamori, Suzuki e Yamanaka (1993) foi proposto um dos primeiros algoritmos MPC baseado em modelo *fuzzy* e observaram-se algumas dificuldades de sintonia devido à atualização do modelo. Muitos dos trabalhos originados se basearam na forma Takagi-Sugeno (TSK), que descreve os consequentes do modelo na forma de autoregressores (NAKAMORI; SUZUKI; YAMANAKA, 1993; KANDIAH, 1996; ROUBOS et al., 1999; KILLIAN; MAYER; KOZEK, 2014). Algumas vertentes substituíram esses submodelos por modelos de convolução (HUANG et al., 2000; LIMA et al., 2009; DALHOUMI; DJEMEL; CHTOUROU, 2010). E outras, com base nas teorias de controle moderno, utilizaram submodelos na forma de espaço de estados (ZHANG; FENG; LU, 2007; XIA et al., 2010; KILLIAN et al., 2016; TENG et al., 2018; MENDES, 2008). Em específico, Mendes (2008) defende que a escrita em espaço de estados permite representar as dinâmicas de

forma mais completa, ao invés das versões simplificadas de autoregressores, que tendem a demandar mais regras *fuzzy*.

Segundo Babuška (1998), a topologia TSK permite aproximar um sistema não linear com duas perspectivas, a global, atuando como um sistema linear de parâmetros variáveis (Linear Parameter Varying - LPV); ou a local, atuando como um conjunto de modelos lineares locais. De forma que a aplicação de controle para cada uma das perspectivas dá-se, respectivamente, por um controlador com base no modelo LPV; ou por múltiplos controladores (conhecido como *parallel-distributed compensation*), referentes a cada modelo local, os quais tem sua contribuição ponderada pela estrutura TSK (MENDES, 2008; ABONYI et al., 2000a). Abonyi et al. (2000b) analisam a efetividade de ambas as abordagens, evidenciando que a abordagem local representa melhor os pontos de operação, enquanto a global, a dinâmica geral do sistema aproximado. Mendes (2008) comparou ambas as técnicas aplicadas ao controlador MPC e mostrou que a de modelo global é a que apresenta menor custo computacional se comparada à de múltiplos modelos locais, em função do uso de um único controlador associado. Roubos et al. (1999) também desenvolveu essa abordagem e ainda definiu as possibilidades de modelos LPV de um passo a frente (*single-step*) ou de múltiplos passos (*multi-step*), sendo a primeira com menor complexidade computacional. Xia et al. (2010) avalia ambas abordagens e observa que para modelo global o controlador converge mais rapidamente para a referência, se comparado a múltiplos modelos.

A origem do FMPC se baseia na utilização direta das técnicas consolidadas de MPC linear para o controle de sistemas altamente não lineares, o que se confirma com aplicações que abrangem sistema de soldagem a arco elétrico (ZHANG; KOVACEVIC, 1998), processos de polimerização (LIMA et al., 2009), reatores CSTR (do inglês *stirred-tank reactor*) (SARIMVEIS; BAFAS, 2003), em infraestrutura de prédios (KILLIAN; MAYER; KOZEK, 2014) e até em tratamento de esgoto (LI et al., 2020). O uso em sistemas tão distintos indica a ampla capacidade de controle dos algoritmos FMPC, permitindo associá-los aos sistemas de elevação artificial de petróleo, os quais têm características dinâmicas de alta complexidade, como não linearidades, dependência temporal, falhas, distúrbios, incertezas, baixas disponibilidades de instrumentação confiável e especialistas no setor (CAMPOS et al., 2013).

3.1 FUZZY MPC DE HORIZONTE INFINITO (FIHMPC)

Como principal contribuição deste trabalho, propõe-se a técnica de controle preditivo de horizonte infinito na forma adaptativa com base na estrutura de modelo *fuzzy* LPV para aproximar a dinâmica não linear da planta a ser controlada.

Observou-se a possibilidade de incorporar a estrutura TSK modificada na forma de espaço de estados (Seção 2.3.2) com o controlador IHMPC de duas formas, considerando o FIS como um conjunto de múltiplos modelos locais e aplicando para cada modelo um IHMPC, e, por fim, agregando as ações de controle de cada controlador pela estrutura *fuzzy*; ou a abordagem global que considera a “linearização instantânea”, em que o FIS combina os múltiplos submodelos e retorna com um modelo em espaço de estados atualizado a cada instante de amostragem, sendo, portanto, na forma LPV já mencionada

(BABUŠKA, 1998; MENDES, 2008). A segunda abordagem foi escolhida nesse trabalho, sendo nomeada por FIHMPC (do inglês *Fuzzy Infinite Horizon Model Predictive Control*), com o intuito de apresentar um custo computacional inferior se comparado ao necessário para a primeira abordagem, como também utilizar essa técnica de forma embarcada em etapas futuras.

Como definido na Seção 2.4, o IHMPC se baseia na resposta ao degrau do sistema decorrente do modelo escrito na forma de funções de transferência (FT), portanto, o modelo LPV será convertido em FT pela transformada de Laplace, e sua resposta ao degrau será extraída para obter o modelo OPOM. Esse processo de conversão dos modelos para OPOM pode ser feita *online*, processando a cada instante de amostragem (como foi apresentado pela primeira vez em Matos, Chagas e Martins (2021)); ou *offline*, já entregando o modelo TSK com submodelos OPOM para os algoritmos do controlador.

Para aumentar os graus de liberdade do controlador em questão, pode-se escrevê-lo na forma de controle por faixa, onde o valor de referência da variável a ser controlada deixa de ser um valor específico y_{sp} e passa a ser apresentado como um intervalo $[y_{\min}, y_{\max}]$ (GONZÁLEZ; ODLOAK, 2009). Essa abordagem já vem sendo incorporada pelo time de pesquisa em trabalhos como Fontes et al. (2020), Santana, Fontes e Martins (2021) e Santana et al. (2021), com o intuito de incorporar restrições de forma suave ao problema de otimização, àquelas que não necessitam ser absolutamente respeitadas a todo instante pelo controlador. É preciso salientar que a previsão é realizada com o modelo no instante k , não se atualizando, portanto, o modelo durante o horizonte de previsão. Essa abordagem reduz a precisão da previsão, contudo, evita o custo computacional de uma lei de controle com modelo de previsão não linear.

A Figura 3.1 resume o funcionamento do controlador e a integração com o modelo TSK. Destaca-se que o modelo OPOM origina variáveis de estado virtuais associadas aos estados integradores $\mathbf{x}^s(k)$, fazendo-se necessário utilizar um estimador de estados em conjunto com o controlador para estimar $\mathbf{x}(k)$ definido em (2.22), no qual seu modelo interno também é atualizado pelo TSK a cada instante de amostragem da planta.

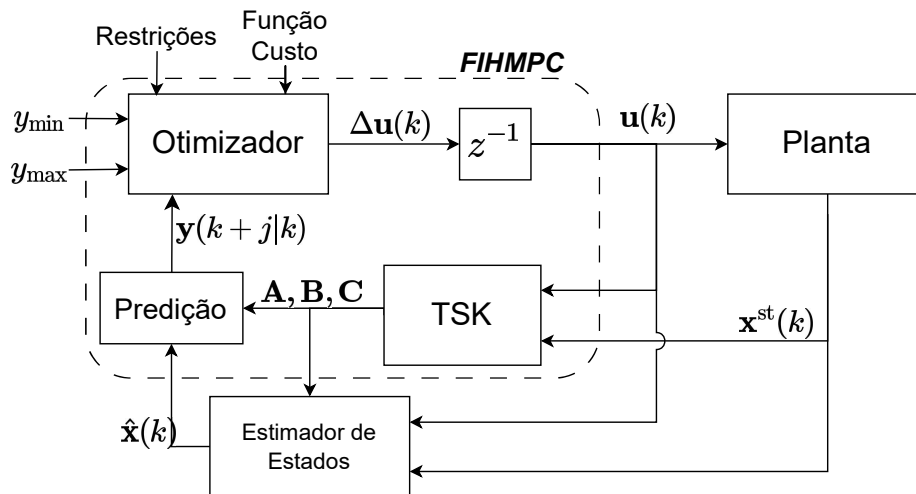


Figura 3.1: Diagrama da proposta de controle *fuzzy* MPC.

Fonte: Autor.

Dentre as características do IHMPC citadas na Seção 2.4, é preciso considerar que a atualização recorrente do modelo no controlador IHMPC, assim como o uso de estimadores de estados para os estados integradores, levam à perda da garantia de estabilidade nominal relacionada à técnica. Uma vez que esta garantia tem como condições a convergência assintótica e viabilidade recursiva (ODLOAK, 2004). A segunda não pode ser provada para o modelo adaptativo uma vez que a atualização a cada amostragem provoca conflito com a solução herdada do instante anterior que se baseou na condição de modelo anterior (SANTANA et al., 2021), além da abordagem *fuzzy* como LPV incluir um caráter aproximado ou de *mismatch* intrínseco entre planta e modelo. Contudo, vale ressaltar que a garantia de factibilidade tende a ser mantida com o uso das variáveis de folga no problema de otimização e a abordagem por faixa mantém a flexibilização do problema de controle.

O problema de controle (2.30) assume a seguinte forma

$$\begin{aligned} \min_{\Delta \mathbf{u}_k, \mathbf{y}_{sp,k}, \boldsymbol{\delta}_{y,k}, \boldsymbol{\delta}_{u,k}} V_k = & \sum_{j=1}^{h_c} \|\mathbf{y}(k+j|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k}\|_{\mathbf{Q}_y}^2 + \|\mathbf{x}^s(k+h_c|k)\|_{\tilde{\mathbf{Q}}}^2 \\ & + \sum_{j=0}^{h_c-1} \|\Delta \mathbf{u}(k+j|k)\|_{\mathbf{R}}^2 + \sum_{j=0}^{h_c-1} \|\mathbf{u}(k+j|k) - \mathbf{u}_{tg} - \boldsymbol{\delta}_{u,k}\|_{\mathbf{Q}_u}^2 \\ & + \|\boldsymbol{\delta}_{y,k}\|_{\mathbf{S}_y}^2 + \|\boldsymbol{\delta}_{u,k}\|_{\mathbf{S}_u}^2 \end{aligned} \quad (3.1)$$

sujeito a:

$$\Delta \mathbf{u}_k \in \mathbb{U}, \quad (3.2)$$

$$\mathbb{U} = \left\{ \begin{array}{l} \mathbf{u}_{\min} \leq \mathbf{u}(k-1) + \sum_{i=0}^j \Delta \mathbf{u}(k+i|k) \leq \mathbf{u}_{\max} \\ -\Delta \mathbf{u}_{\max} \leq \Delta \mathbf{u}(k+j|k) \leq \Delta \mathbf{u}_{\max} \\ \Delta \mathbf{u}(k+j|k) = 0, \forall j \geq h_c, \end{array} \right\} \quad (3.3)$$

$$\mathbf{x}(k+j|k) = \mathbf{A}(k) \cdot \mathbf{x}(k+j-1|k) + \mathbf{B}(k) \cdot \Delta \mathbf{u}(k+j-1|k) \quad (3.4)$$

$$\mathbf{y}(k+j|k) = \mathbf{C}(k) \cdot \mathbf{x}(k+j-1|k) \quad (3.5)$$

$$\mathbf{y}_{\min,k} \leq \mathbf{y}_{sp,k} \leq \mathbf{y}_{\max,k} \quad (3.6)$$

$$\mathbf{u}(k+h_c-1|k) - \mathbf{u}_{tg,k} - \boldsymbol{\delta}_{u,k} = \mathbf{0}, \quad (3.7)$$

$$\mathbf{x}^s(k+h_c|k) - \mathbf{y}_{sp,k} - \boldsymbol{\delta}_{y,k} = \mathbf{0}, \quad (3.8)$$

onde h_c é o horizonte de controle, $\Delta \mathbf{u}(k+j|k)$ são incrementos nas MVs e $\mathbf{y}(k+j|k)$ são as predições das CVs no instante $k+j$ dada a informação no instante k ; $\mathbf{y}_{sp,k}$ são os *set-points* artificiais das CVs relacionado ao esquema de controle por faixa definido na restrição (3.6); temos as restrições de MVs \mathbf{u}_{\min} , \mathbf{u}_{\max} , de incrementos das MVs $\Delta \mathbf{u}_{\max}$, e de CVs \mathbf{y}_{\min} , \mathbf{y}_{\max} ; $\mathbf{Q}_y \in \mathbb{R}^{ny \times ny}$ e $\mathbf{R} \in \mathbb{R}^{nu \times nu}$ são as matrizes de ponderação das (ny) CVs e (nu) MVs, respectivamente; $\Delta \mathbf{u}_k = [\Delta \mathbf{u}(k|k) \dots \Delta \mathbf{u}(k+h_c-1|k)]^T$ é o vetor de ações de controle; $\boldsymbol{\delta}_{y,k} \in \mathbb{R}^{ny}$ e $\boldsymbol{\delta}_{u,k} \in \mathbb{R}^{nu}$ são as variáveis de folga usadas para garantir a factibilidade do problema de otimização (3.1) em cenários de *mismatch* entre planta e modelo; $\mathbf{S}_y \in \mathbb{R}^{ny \times ny}$ e $\mathbf{S}_u \in \mathbb{R}^{nu \times nu}$ são as matrizes de ponderação das variáveis de folga;

\mathbf{u}_{tg} são os *targets* das MVs e \mathbf{Q}_u é sua matriz de ponderação. As restrições terminais (3.8) e (3.7) são usadas para prevenir custo ilimitado, embora tais restrições pudessem ser suprimidas dessa formulação adaptativa, uma vez que a garantia de estabilidade já é sabidamente perdida. Por outro lado, mesmo sem garantia de estabilidade, a formulação baseada em ingredientes terminais e horizonte de predição de infinito contribui para uma tarefa menos árdua no que se refere à sua sintonia (SILVA et al., 2020). A função custo tem a mesma parcela de custo terminal que em (2.30), ponderada pela matriz $\bar{\mathbf{Q}}$ (2.29). $\mathbf{A}(k)$, $\mathbf{B}(k)$ e $\mathbf{C}(k)$ são as matrizes

Salienta-se que o *Fuzzy IHMPC* (FIHMPC) proposto mantém a forma de resolução por programação quadrática uma vez que o modelo de predição para cada instante permanece linear, viabilizando a sua solução em sistemas embarcados, como verificado em Santana (2020), ao manter um custo computacional inferior a técnicas de MPC que resultam de problemas de otimização não lineares.

Com base nessas informações, o FIHMPC apresenta uma potencialidade de favorecer o funcionamento de sistemas não lineares, tais como o BCS, sendo capaz de incorporar suas particularidades e buscar operações mais seguras e eficientes, fatores avaliados na próxima seção.

Nesse capítulo são apresentados os detalhes da implementação da técnica de controle proposta no sistema BCS e o processo de avaliação do seu rendimento.

METODOLOGIA

Para testar e validar a técnica de controle proposta, o sistema BCS descrito na Seção 2.1 foi simulado no ambiente de programação do *software* MATLAB[®] através da integração numérica do modelo apresentado (2.1) e (2.4).

É observado que em instalações com BCS reais alguns parâmetros e variáveis raramente estão disponíveis, tais como o índice de produtividade, a viscosidade do poço e a vazão média de produção q_p (BINDER; PAVLOV; JOHANSEN, 2015). Para simular a perspectiva prática, faz-se necessário utilizar um estimador como proposto em Delou, Souza e Secchi (2020), ou uma abordagem numérica aproximada de entrada-saída, como foi conduzido aqui. A abordagem proposta considerou apenas o número mínimo de variáveis medidas, de acordo com Binder, Pavlov e Johansen (2015), usando os dados de f_{ref} , z_{ref} , p_{in} , p_{wh} e H - que pode ser obtido a partir da diferença de pressão gerada pela própria bomba. A vazão q_p (2.2) não será informada ao algoritmo de controle, servindo apenas como medida de avaliação do seu rendimento.

Os seguintes objetivos foram adotados para o controle do sistema BCS pela técnica FIHMPC:

- Inclusão explícita do envelope operacional: por meio do controle por faixa, calcularam-se os limites mínimo e máximo os quais o H deve permanecer para uma operação segura do sistema BCS;
- Rastreamento da pressão de entrada: para um valor de referência $p_{in(ref)}$, no qual a respectiva faixa é definida como $y_{min} = y_{max} = p_{in(ref)}$, ajustou-se a produção do sistema através da pressão de entrada, em função da correlação entre esta variável e a vazão de produção q_p (FONTES et al., 2020);
- Envelope operacional por frequência: para manter a proposta de usar apenas variáveis com medidas disponíveis, a atualização dos limites da zona de *head* será correlacionada com a frequência da bomba, ao invés da vazão, um envelope traduzido

como apresentado em Krishnamoorthy, Fjalestad e Skogestad (2019b). Com base nas curvas correspondentes a vazão, apresentadas em Binder, Pavlov e Johansen (2015), os polinômios de *upthrust* e *downthrust* como função da frequência são, respectivamente:

$$H_{ut} = 0.25837 \cdot f^2 + 0.30189 \cdot f - 6.92523 \quad (4.1)$$

$$H_{dt} = 0.18079 \cdot f^2 + 3.76875 \cdot f - 64.02227 \quad (4.2)$$

- Restrições de entrada: os limites mínimos e máximos de f e z_c e, seus respectivos limites de variação foram definidos como restrições rígidas do problema de otimização, para garantir a integridade dos elementos de controle.
- Uso das variáveis de folga: para garantir a factibilidade do problema, especialmente devido ao número de restrições do problema e à presença de distúrbios típicos.

Dessa forma, as MVs do sistema são $\mathbf{u}(k) = [f_{ref}(k), z_{cref}(k)]$, e as respectivas CVs $y = [p_{in}, H]$.

Para a implementação da técnica proposta foi preciso definir o modelo de predição do controlador, sendo na forma TSK, além de parametrizar o controlador para atingir o rendimento esperado, para, por fim, embarcá-lo no *hardware* de controle dedicado.

4.1 IDENTIFICAÇÃO DA PLANTA

O primeiro elemento necessário para aplicação do controlador FIHMPC proposto é a definição do modelo TSK que represente a planta a ser controlada.

Conforme apresentado na Seção 2.2, a identificação de sistemas não lineares pelos sistemas FIS TSK com base em dados apresenta quatro passos (NELLES, 2001):

1. *Excitação do sistema*: sinal de entrada com múltiplas variações de amplitude e rico espectro de frequência, a fim de estimular grande parte dos modos do sistema e extrair sua correlação através dos dados (AGUIRRE, 2004).
2. *Determinação dos parâmetros antecedentes*: através do particionamento por grade ou métodos de clusterização (BABUŠKA, 1998), definem-se as funções de pertinência correspondentes às regiões de operação que apresentam significância nos dados apresentados.
3. *Determinação dos parâmetros consequentes*: através do Problema 1, os submodelos lineares são definidos para cada região encontrada na etapa anterior.
4. *Análise estrutural*: através da repetição das etapas 2 e 3 e de métricas de qualidade, definir a melhor configuração do modelo *fuzzy*, ou seja, o número de regras adequado para aplicação.

Para identificar este modelo do sistema por meio de dados coletados da planta simulada (modelo não linear fenomenológico (2.1) e 2.4), foi preciso obter tais dados com a aplicação de entradas previamente escolhidas para excitar amplamente a dinâmica não linear da planta, de forma que esses sinais tenham como característica variação de amplitude e variação de frequência (NOWAK, 2002).

O sinal de excitação adotado foi o APRBS (do inglês *amplitude-modulated pseudo-random bit sequences*), um sinal com rica resposta em frequência e variação de amplitude para alcançar todo o intervalo operacional do sistema não linear, como usado em (JORDANOU et al., 2022), que propõe uma configuração de dois tempos de chaveamento distintos para enriquecer a excitação do sistema ainda mais. Salienta-se que esse tipo de sinal tem aplicabilidade delicada para aplicações reais, uma vez que por apresentar excitação prolongada e de alta frequência, pode comprometer a integridade dos elementos finais de controle e o desempenho global do sistema, considerando as regras de operação em vigor. Essa problemática pode ser contornada com uma configuração mais lenta para o sinal ou uso de outros sinais mais suaves em complemento a utilização do histórico de dados do sistema, para compor uma base de dados suficientemente representativa sobre a operação da BCS. O sinal foi então aplicado à BCS simulada e os dados de entrada e saída foram armazenados.

As funções de pertinência adotadas foram as gaussianas, originando-as por clusteração, através do algoritmo Gustafson-Kessel modificado por Babuška, Van Der Veen e Kaymak (2002). Este algoritmo tem como característica a formação de clusters elipsoides, adaptando-se melhor à distribuição dos dados (BABUŠKA, 1998).

De forma geral, a identificação do modelo, na forma de treinamento supervisionado, foi

realizado em batelada de dados, conforme as seguintes etapas, resumidas no Algoritmo 1.

Algoritmo 1: Pseudocódigo de identificação do modelo TSK com base em dados.	
Entrada: Dados em regime da Planta (X, U) Dados dinâmicos $\mathbf{x}(k), \mathbf{u}(k)$ para $k = 1, \dots, M$	
Saída: c_i, σ_i, A_i, B_i , para $i = 1, \dots, p$	
1	início
2	para $i = 1$ até p faça /* cada regra */
3	$c_i, \sigma_i \leftarrow$ Clusterização(X, U, p);
4	para $k = 1$ até M_t faça /* peso por regra por dado */
5	$\bar{w}_i(k) \leftarrow$ Fuzzifica($\mathbf{x}(k), \mathbf{u}(k), c_i, \sigma_i$)
6	fim
7	$A_i, B_i \leftarrow$ Mínimos_Quadrados($c_i, \sigma_i, X, U, \bar{w}_i(k)$)
8	fim
9	para $k = 2$ até M_v faça /* simula o modelo TSK */
10	$\bar{w}_i(k) \leftarrow$ Fuzzifica($x(k), u(k), c_i, \sigma_i$)
11	$\hat{x}(k+1) \leftarrow$ Defuzzifica($\bar{w}_i(k), x(k), u(k), p, A_i, B_i$)
12	fim
13	$erro_treino \leftarrow$ erro_RMSE(\hat{X}, X, U, p)
14	Salvar_Modelo($c_i^*, \sigma_i^*, erro, A_i, B_i$)
15	fim

Os parâmetros foram inicializados, como o número p de regras TSK (pontos de operação ou clusters) e as constantes do algoritmo de clusterização. As amostras de dados dinâmicos coletados da planta (divididos em treino e teste $M = M_t + M_v$) e o conjunto de dados em regime foram passados para o algoritmo. Sendo que os dados em regime foram usados na clusterização para mapear as p zonas de operação, retornando a definição destas na forma de funções gaussianas centradas em c_i e dispersas σ_i . O desvio-padrão σ_i é obtido com base nas matrizes de covariância resultantes do algoritmo GK, em que a diagonal principal corresponde à variância dos clusters e sua raiz quadrada resulta no desvio-padrão. Dessa forma os antecedentes das regras foram definidos.

Através da fuzzificação dos M_v dados dinâmicos, determinou-se o peso de cada regra para cada amostra e aplicou-se o algoritmo de Mínimos Quadrados ponderados por tais peso, determinando-se as matrizes \mathbf{A}_i e \mathbf{B}_i de cada submodelo. Resultando em um modelo TSK composto por p submodelos lineares. Por fim, o modelo é testado com a parcela de dados de teste M_v .

Para mensurar a qualidade do modelo será aplicado a todas as $i = 1, \dots, n$ saídas do modelo e aos M_v dados medidos o desvio médio quadrático (*root-mean-square error* - RMSE), o coeficiente de determinação (*R-squared* - R^2) e a variância explicada (*Variance Accounted For*-VAF).

$$RMSE_i = \frac{1}{M_v} \sqrt{\sum_{j=1}^M (\hat{x}_{i,j} - x_{i,j})^2}, \quad (4.3)$$

$$R_i^2 = \left(1 - \frac{\sum_j^{M_v} (\mathbf{x}_{i,j} - \hat{\mathbf{x}}_{i,j})}{\sum_j^{M_v} (\mathbf{x}_{i,j} - \bar{\mathbf{x}}_j)} \right), \quad (4.4)$$

$$\text{VAF}_i = \left(1 - \frac{\text{var}(\mathbf{x}_i - \hat{\mathbf{x}}_i)}{\text{var}(\mathbf{x}_i)} \right) \cdot 100\%. \quad (4.5)$$

Para definir a estrutura do modelo *fuzzy*, um estudo do número de regras foi realizado, através da repetição do Algoritmo 1 para parâmetro p no intervalo de 2 a 10 clusters, avaliando o desempenho de cada configuração com base nas métricas apresentadas e no aspecto dimensional do modelo. Por fim, definiu-se o modelo que apresentou melhor estimativa para um número de regras/submodelos baixo, em se tratando de consumo de memória, mantendo-se a dimensão do modelo reduzida para aplicação embarcada.

4.2 PROJETO E SINTONIA DO FIIHMPC

Para o projeto do FIIHMPC é necessário obter o modelo conforme seção anterior, e definir, por meio de testes, os parâmetros de sintonia do controlador para determinar a dinâmica desejada.

Os parâmetros do FIIHMPC a serem ajustados são:

- Horizonte de controle (h_c) – define quantos passos de variação de controle serão usado para calcular a solução ótima;
- Matrizes de ponderação:
 - Saídas controladas (\mathbf{Q}_y) – pondera o erro entre a saída real e a referência;
 - *Target* econômico (\mathbf{Q}_u) – pondera o a aproximação entre as MVs e o *target* desejado;
 - Variações nas entradas (\mathbf{R}) – pondera a variação do esforço de controle;
 - Variáveis de folga das saídas (\mathbf{S}_y) - pondera a ação das variáveis de folga da saída, garantindo a factibilidade do problema de otimização quanto a distúrbios nas CVs;
 - Variáveis de folga das entradas (\mathbf{S}_u) - pondera a ação das variáveis de folga da entrada, garantindo a factibilidade do problema de otimização quanto a distúrbios nas MVs.

Uma abordagem heurística para sintonia foi adotada. Com base em testes, buscou-se garantir rendimento aceitável e custo computacional reduzido em relação à alocação de memória para cálculo do controlador, uma vez que o aumento do horizonte de controle interfere diretamente na dimensão das matrizes e do número de esforços de controle a serem obtidos. Outros trabalhos similares como Santana et al. (2021) e Fontes et al. (2020) utilizaram a mesma abordagem e resultaram em uma sintonia mais conservadora e simplificada, e serviram como base para a sintonia deste controlador.

4.3 IMPLEMENTAÇÃO E VALIDAÇÃO

A aplicação do controlador FIHMPC proposto levou em conta o diagrama da Figura 3.1. A planta BCS foi simulada conforme modelo dinâmico apresentado na Seção 2.1 e escrita em ambiente de código *Matlab*. Enquanto isso, a implementação do controlador proposto no sistema embarcado foi realizada na forma de simulação *hardware-in-the-loop* (HIL), conforme diagrama da Figura 4.1.

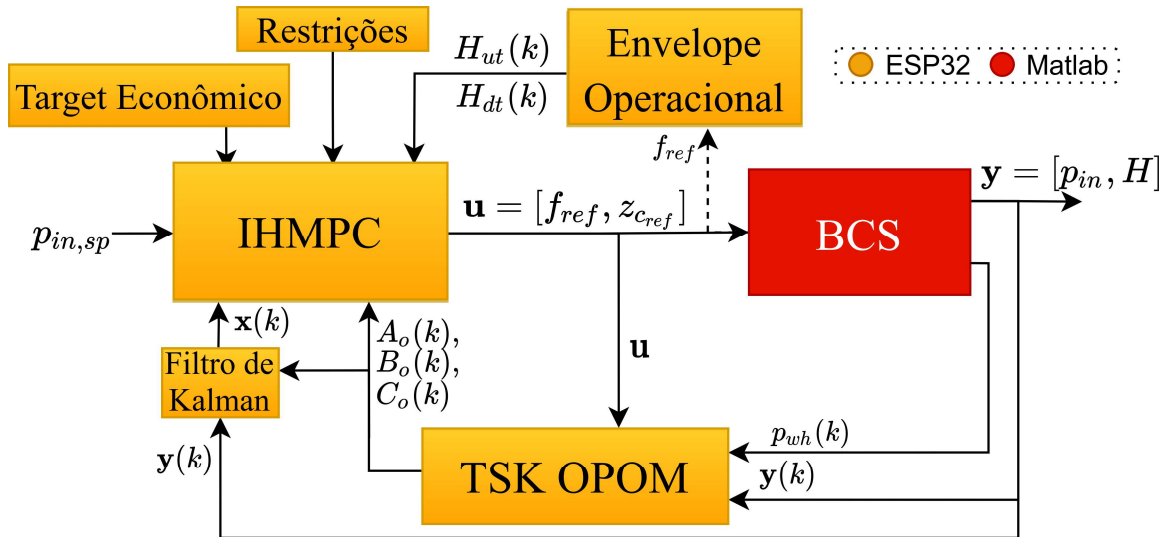


Figura 4.1: Diagrama da simulação HIL do FIHMPC por faixa proposto para o sistema BCS.

Fonte: Autor.

A plataforma de *hardware* adotada neste trabalho foi o microcontrolador ESP32, composto pelo processador Tensilica Xtensa LX6, com frequência de operação de 240 MHz, 52 kB de memória *RAM* e 4 MB de memória *flash*. Esta plataforma escolhida não se configura como um sistema de controle industrial dedicado, como um CLP ou SDCD (Sistema Digital de Controle Distribuído), e, portanto, não apresenta a robustez necessária para implementação em instalações de óleo e gás, contudo, pode ser usada como ferramenta de validação preliminar do objeto de pesquisa, reproduzindo o contexto embarcado e suas características, como os limites de memória e processamento. Como a sua linguagem de programação é C/C++, é possível reproduzir sistemas modelos de controle com um baixo custo de aquisição e um alto poder computacional, conforme verificado nos trabalhos de Santana (2020) e Santana, Fontes e Martins (2021).

A função que implementa o controlador, o respectivo solver, o cálculo do envelope e demais restrições, assim como o modelo TSK, foram implementados na linguagem *Matlab* e convertidos em linguagem C++ através da ferramenta de geração de código para sistemas embarcados - *Matlab Coder*¹. Configurou-se esta ferramenta conforme: conversão para precisão numérica simples (declaração de variáveis como *single*), em função da alta

¹<https://www.mathworks.com/products/matlab-coder.html>

dimensão das matrizes do modelo TSK e originadas da função custo do controlador; função convertida como uma biblioteca estática; linguagem C++; desabilitando dimensão dinâmica de variáveis e preservando as dimensões originais dos vetores e matrizes; definido o máximo de 2,5 kB de *stack*. O solver de otimização usado foi o *mpcActiveSetSolver*, do *Matlab MPC toolbox*², escolhido pela capacidade de processar o problema de otimização com precisão numérica simples. Os códigos foram compilados no *software* Arduino IDE 1.8.19³, juntamente com os parâmetros que configuram o problema de controle e o HIL.

Por meio de comunicação serial, o *Matlab* simula o sistema BCS com a integração do modelo apresentado na Seção 2.1 e envia os valores das variáveis de saída e a referência de p_{in} desejada para o ESP32. Ao receber, processa a atualização do envelope operacional, calculando a zona de H por (4.1) e (4.2). O modelo TSK atualiza o preditor do controlador. Para estimação dos estados artificiais do modelo OPOM, optou-se por utilizar o filtro de Kalman discreto, conforme realizado em Santana et al. (2021), com o modelo atualizado a cada instante de amostragem, como comentado na Seção 3. As matrizes de controle são computadas e o problema de otimização é resolvido de forma embarcada, resultando em: $\Delta \mathbf{u}_k$, $\mathbf{y}_{sp,k}$, $\delta_{\mathbf{y},k}$, $\delta_{\mathbf{u},k}$; o H_{min} e H_{max} ; o número de iterações do solver, índices de erro do solver e o tempo computacional do cálculo da solução do controlador FIHMPC.

Para validação da técnica de controle proposta, índices de rendimento foram utilizados, como a integral da função custo (*integral of cost function - ICF*), o tempo de permanência fora do envelope operacional T_{out} e o volume acumulado de produção de óleo V_T . Essas grandezas permitem caracterizar o custo total do problema de otimização, a capacidade de manter o sistema em segurança e a capacidade de produção do mesmo, respectivamente.

Os seguintes cenários de validação do controlador foram considerados:

- Rastreamento de trajetória sobre efeito de distúrbios não medidos: através de cenários realistas de implementação de um sistema BCS, são aplicados ruídos e distúrbios nas principais variáveis não medidas do sistema para analisar o efeito da abordagem *fuzzy* adaptativa sobre a linha de controle IHMPC;
- Otimização econômica: neste cenário, visou-se avaliar a possibilidade de inclusão de aspectos econômicos no controlador, a fim de otimizar aspectos como o uso racional dos recursos do sistema e o efeito energético dessa abordagem;
- Avaliação computacional: através das medidas de tempo de processamento e memória utilizada, avaliou-se a viabilidade e o rendimento da técnica de controle embarcada em simulação HIL em comparação aos trabalhos similares.

²<https://www.mathworks.com/products/model-predictive-control.html>

³<https://www.arduino.cc/en/software>

Análises e validações do processo de identificação do modelo TSK e das características da técnica de controle proposta em sistema BCS.

RESULTADOS

Nesta seção são apresentadas a identificação do modelo TSK, a aplicação do controlador FIHMPC embarcado em microcontrolador ESP32 e sua análise de rendimento numérico-computacional.

5.1 EXTRAÇÃO DE DADOS DA PLANTA

O modelo BCS (2.1) e (2.4) foi simulado com tempo de amostragem de 1 segundo usando o algoritmo de resolução de sistemas não lineares *Trust-Region-Dogleg*. Dois sinais de excitação do tipo APRBS não-correlacionados foram gerados para as entradas $f_{ref} \in [35; 65]$ Hz e $z_{c,ref} \in [0, 100]$ %, conforme utilizado em Jordanou et al. (2022) para identificação por treinamento supervisionado de um sistema BCS. Para exploração de mais condições de operação, os sinais foram compostos por duas seções com tempo mínimo de chaveamento (T_{min}) de 20 e 70 segundos para a primeira e segunda parte, respectivamente, conforme Figura 5.1. Esses tempos mínimos foram definidos com avaliação temporal da dinâmica mais lenta do sistema, associada aos atuadores (definidas em $\Delta f_{max} = 0,5$ Hz/s e $\Delta z_{c,max} = 1,0$ %/s).

A aplicação do sinal da Figura 5.1 no sistema BCS simulado resultou na reposta dinâmica da Figura 5.2, compondo os dados a serem utilizados no processo de identificação da planta pelo modelo TSK. Além dos dados em questão, foram obtidos pontos em regime para as combinações de entradas da Figura 5.3 com os respectivos valores de regime das variáveis p_{wh} , p_{in} e H , formando um conjunto de 100 amostras para as etapas de identificação *fuzzy* TSK a serem desenvolvidas na próxima seção.

5.2 IDENTIFICAÇÃO DA PLANTA POR MODELO TSK

Com os dados extraídos do sistema BCS, seguem-se as etapas descritas na Seção 4.1 para a identificação do modelo *fuzzy* TSK correspondente. O conjunto de dados dinâmicos foi separado em 80 % para treino e 20 % para teste aplicados à etapa de MQ.




Figura 5.1: Sinais APRBS para a identificação da BCS pelo modelo TSK.




Figura 5.2: Dados coletados da BCS de p_{wh} , p_{in} e H para o sinal de excitação aplicado.

Na etapa de treinamento, o método de validação cruzada k -fold foi aplicado para $k = 4$. O método de clusterização Gustafson-Kessel mapeou as regiões de operação utilizando o conjunto de dados de 100 amostras em estado estacionário. Este algoritmo foi configurado conforme indicado em Babuška, Van Der Veen e Kaymak (2002), resultando em expoente de imprecisão $m_c = 2$, a tolerância de terminação em 10^{-3} , o número de condição limiar $\beta = 10^{15}$ e ponderação para covariância $\gamma = 0,95$.

As regiões obtidas foram representadas pelas funções de pertinência gaussianas, com a obtenção dos seus respectivos centros c e os desvios-padrão σ . Os dados de treinamento




Figura 5.3: Combinação das entradas em regime para mapeamento do sistema nos diversos pontos de operação possíveis - dados para clusterização *fuzzy*.

correspondentes à dinâmica do sistema foram usados nos mínimos quadrados (Problema (2.18)) para definir os submodelos lineares relacionados a cada região ou regra *fuzzy*.

O número adequado de regras (p) para o modelo *fuzzy* foi avaliado através dos índices de qualidade $RMSE$, VAF e R^2 . Repetiu-se o processo de identificação considerando 2 a 10 regras e a etapa de teste foi realizada com predição infinitos passos a frente (simulação livre), resultando quantitativamente nos respectivos índices na Figura 5.4. Pode-se observar nestes números que $p = 3$ regras apresenta a melhor relação entre desempenho (menores valores para $RMSE$ e maiores para VAF e R^2) e dimensão do sistema para as três variáveis estimadas. Resultando em uma configuração de modelo de dimensão reduzida, mas capaz de representar bem a dinâmica do sistema BCS.

O modelo TSK obtido tem os termos antecedentes (funções de pertinência por regras) configurados segundo as Figuras 5.5 e 5.6, resumidamente apresentado na Tabela 5.1. As funções de pertinência obtidas apresentam uma relação lógica coerente com o sistema, de forma que se formou três combinações: frequência do motor baixa com abertura de *choke* alta; frequência do motor alta com *choke* baixa; e frequência alta com abertura de *choke* alta, resultando em três regiões de operação, em que a abertura de válvula apresenta maior relevância na não linearidade do sistema, conforme esperado. Além disso, para altas frequências e grandes aberturas da *choke* temos uma pressão de entrada baixa, resultando em uma região de alta vazão, conforme relacionado pelo controle via rastreamento da pressão de entrada.

As respostas em simulação livre do modelo TSK são apresentadas em Figura 5.7, Figura 5.8 e Figura 5.9. Tais comportamentos dinâmicos indicam uma aproximação suficiente do modelo *fuzzy* LPV proposto para um número reduzido de regras, validando-o como uma escolha prática.

O submodelo linear correspondente à segunda regra do modelo *fuzzy* em Tabela 5.1




Figura 5.4: Análise do índice $RMSE$ sob variação do número de regras do modelo *fuzzy* TSK.




Figura 5.5: Funções de pertinência das variáveis preditas p_{wh} , p_{in} e H .

foi escolhido como comparação (linhas tracejadas azuis das Figura 5.7, Figura 5.8 e Figura 5.9). Este modelo linear constitui um modelo de predição fixo e representa uma condição operacional próxima à pressão de entrada baixa e à vazão alta, situação desejada em um processo de produção de óleo com sistemas BCS. Entretanto, se o sistema BCS opera um pouco longe desta condição operacional, o desempenho de seu modelo linear resultante se deteriora, conforme quantificado pelos índices de desempenho apresentados em Tabela 5.2. Quando comparado ao desempenho obtido do modelo linear fixo, é possível




Figura 5.6: Funções de pertinência das variáveis manipuladas f_{ref} e $z_{c_{ref}}$.

Tabela 5.1: Regras *fuzzy* TSK identificadas para caracterizar os espaços de operação do sistema BCS.

Regra	$p_{wh}/(\text{bar})$		$p_{in}/(\text{bar})$		$H/(\text{m})$		$f_{ref}/(\text{Hz})$		$z_{c_{ref}}/(\%)$	
	c	σ	c	σ	c	σ	c	σ	c	σ
1	28,309	11,634	71,008	9,268	439,035	131,958	42,415	5,919	62,333	25,263
2	32,658	13,547	54,653	13,211	714,176	168,266	54,817	7,094	62,470	22,753
3	66,194	27,567	77,132	17,369	770,384	194,465	54,412	7,100	23,455	21,556

notar que o modelo *fuzzy* produz uma redução *RMSE* de $[47, 6618; 48, 8552; 9, 7568]$ %, e um aumento de *VAF* e R^2 em $[73, 9428; 44, 9488; 1, 3196]$ % e $[77, 8972; 45, 3081; 1, 6466]$ %, respectivamente. Estes resultados validam o uso da abordagem TSK como modelo de predição, ainda que para infinitos passos a frente - condição desejada para o problema de otimização de horizonte de predição infinito, ainda que não explorado no processo de predição.

Tabela 5.2: Comparação de predição em simulação livre entre modelo *fuzzy* TSK LPV e modelo linear para os dados de teste.

Índice	Modelo	$p_{wh}/(\text{bar})$	$p_{in}/(\text{bar})$	$H/(\text{m})$
<i>RMSE</i>	TSK	0.1076	0.1061	0.0992
	2	0.2057	0.2074	0.1099
R^2	TSK	0.8582	0.9005	0.9336
	2	0.4824	0.6197	0.9185
<i>VAF</i> / (%)	TSK	86.8750	90.5105	93.5374
	2	49.9447	62.4430	92.3193

As matrizes dos submodelos lineares que compõem o modelo *fuzzy* foram convertidas *offline* na forma OPOM equivalente, para incorporar ao controlador proposto. De forma que o custo computacional de conversões recorrentes (MATOS; CHAGAS; MARTINS, 2021) é evitado, uma vez que a lógica *fuzzy* agrega diretamente as matrizes do modelo OPOM.




Figura 5.7: Predição infinitos passos a frente da pressão de cabeça de poço para os dados de teste.




Figura 5.8: Predição infinitos passos a frente da pressão de entrada de poço para os dados de teste.

Na próxima seção, o modelo encontrado foi testado no controlador em ambiente embarcado e sobre efeito de distúrbios para observar a eficiência da técnica de controle proposta.




Figura 5.9: Predição infinitos passos a frente da altura manométrica para os dados de teste.

5.3 FIHMPC

Nesta seção são apresentados os resultados do controlador proposto para casos descritos na Seção 4.3.

A sintonia utilizada nos casos testados é apresentada na Tabela 5.3. A denominação IHMPC corresponde ao controlador com modelo de predição fixo (submodelo 2) apresentado na seção anterior, enquanto a denominação FIHMPC caracteriza o controlador com modelo de predição TSK, nas situações com e sem uso de *target* econômico (maximização da abertura da válvula *choke*). Os ajustes de sintonia foram realizados empiricamente, suficientemente para manter o controlador com rendimento aceitável, sem estender seu custo operacional, em caso de maior horizonte de controle.

Tabela 5.3: Controller parameters.

Parâmetros	IHMPC	FIHMPC	FIHMPC _{targetOFF}
m	2	2	2
\mathbf{Q}_y	[30, 20]	[30, 20]	[30, 20]
\mathbf{R}	[5, 5]	[5, 5]	[5, 5]
\mathbf{Q}_u	[0, 1]	[0, 1]	[0, 0]
$\mathbf{S}_y \times 10^5$	[5, 5]	[5, 5]	[5, 5]
\mathbf{S}_u	$[1 \times 10^{-6}, 100]$	$[1 \times 10^{-6}, 100]$	$[1, 1] \times 10^{-6}$
\mathbf{u}_{\min}		[35 Hz, 0 %]	
\mathbf{u}_{\max}		[65 Hz, 100 %]	
$\Delta \mathbf{u}_{\max}$		[0.5 Hz, 1 %]	
\mathbf{y}_{\min}		$[p_{in(ref)}(t), H_{ut}(t)]$	
\mathbf{y}_{\max}		$[p_{in(ref)}(t), H_{dt}(t)]$	

O primeiro cenário de comparação avalia o efeito do modelo de predição TSK sobre o controlador, em relação ao modelo fixo sobre a influência de distúrbios não medidos e com o objetivo de rastreamento de trajetória. A resposta dinâmica do sistema controlado para seguir a trajetória proposta, respeitar as restrições e rejeitar o efeito de distúrbios não medidos pode ser observada nas Figuras 5.10 a 5.16. A pressão de entrada da BCS foi direcionada a atingir quatro patamares que percorrem o intervalo de atuação do sistema BCS e, por consequência, suas diversas regiões de operação. Ruído gaussiano de $\mathcal{N}(0, d^2)$ com $d = \text{diag}([0.42 \text{ bar}; 0.3 \text{ bar}; 3 \text{ m}])$ e um conjunto de distúrbios do tipo degrau foram aplicados, sendo $\delta p_r(250 \text{ s}) = +4 \%$, $\delta p_r(700 \text{ s}) = -2 \%$, $\delta p_m(1100 \text{ s}) = +30 \%$ e $\delta p_{in}(1400 \text{ s}) = +2.1 \text{ bar}$.

Os controladores, no geral, convergiram o sistema para a referência, principalmente na compensação dos distúrbios não medidos gerados sobre o sistema, em função da ação integral, produzida pela forma incremental das entradas. No entanto, o controlador IHMPC apresentou rendimento inferior, especialmente para as mudanças de $p_{in(ref)} = 60$ para 90 bar, como também de $p_{in(ref)} = 75$ para 50 bar. Estes resultados indicam uma resposta mais lenta para o controlador de modelo fixo, se comparado ao FIHMPC. Em destaque, o controlador IHMPC apresentou melhor rendimento nas regiões de menor amplitude de p_{in} , como esperado, já que corresponde à região de operação do seu modelo fixo. O controlador FIHMPC gerou uma resposta balanceada sobre a faixa de não linearidades

do sistema decorrente da atualização contínua do modelo de predição, resultado similar ao obtido em Santana et al. (2021). Além disso, este alcançou uma redução de -21,85 % para o erro acumulado de trajetória da pressão de entrada em comparação ao IHMPC. De forma geral, as grandes variações de setpoint aumentam a discrepância do modelo linear em relação à planta, explicando o melhor rendimento da abordagem adaptativa.




Figura 5.10: Pressão de entrada da BCS para o FIHMPC e IHMPC.

Como definido, o objetivo da técnica era controlar também a dinâmica da planta em relação ao envelope operacional, definindo a faixa de operação da altura manométrica. A Figura 5.11 apresenta o comportamento de cada controlador, assim como a atualização da faixa de operação calculada como base na restrição de envelope operacional. Otimiza-se os *set-points* artificiais para manter o sistema na faixa aceitável de operação, flexibilizando esse tipo de restrição para o seu rastreamento e possibilitando estender a operação comum da BCS em regiões de operação econômica e tecnicamente mais viáveis. É notável que em alguns pontos ocorre o desrespeito momentâneo aos limites do envelope devido à ação das variáveis de folga utilizadas para factibilizar o problema de otimização do controlador, que atuam, principalmente, por efeito dos distúrbios interferindo no sistema.

Na Figura 5.12 confirma o efeito dos distúrbios interferindo no sistema, desviando as trajetórias e violando momentaneamente o envelope operacional. Nestas circunstâncias, o problema de otimização se mantém viável pelo efeito das variáveis de folga, apresentadas na Figura 5.13. Segundo as trajetórias sobre o envelope, o controlador IHMPC apresentou desempenho inferior em exceder a restrição do sistema, especialmente com a entrada dos distúrbios na pressão de reservatório. O controlador FIHMPC utilizou as variáveis de folga com menor intensidade e duração para absorver o efeito dos distúrbios em comparação do IHMPC. De forma geral, as variáveis de folga indicam o erro aproximado entre p_{in} e H em relação às suas referências e para z_c para a *target* econômico adotado.




Figura 5.11: Esquema de controle por faixa da altura manométrica da BCS para FIHMPC e IHMPC.




Figura 5.12: Trajetórias sobre o envelope operacional sobre a aplicação dos controladores FIHMPC e IHMPC.

As variáveis manipuladas de cada controlador são apresentadas na Figura 5.14 e indicam a similaridade de comportamento entre ambos, em especial para o respeito às restrições de f e z_c . As diferenças são notáveis nos instantes de transição entre regiões de operação, correlacionando com as respostas das variáveis controladas comentadas anteriormente.

O controlador FIHMPC, como explicado, é formado pelo modelo *fuzzy* e sua apro-

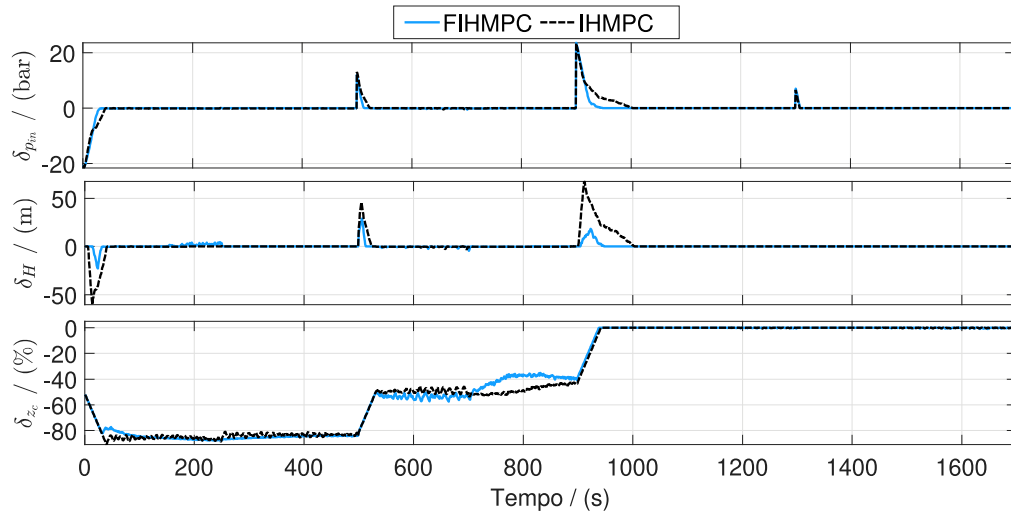


Figura 5.13: Variáveis de folga dos controladores FIHMPC e IHMPC.

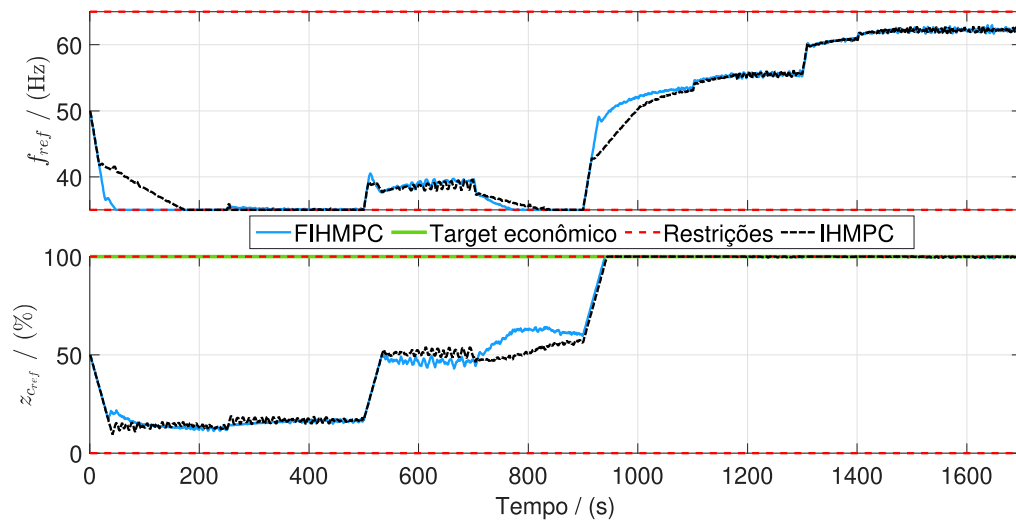


Figura 5.14: Variáveis manipuladas dos controladores FIHMPC e IHMPC.

ximação ao comportamento não linear do sistema. A Figura 5.15 mostra a atualização do modelo conforme o sistema alterou sua região de operação. Isto permite confirmar que o modelo do controlador IHMPC (região 2) é relacionado a uma maior vazão de produção de óleo (acima de 1000 s na figura), explicando o menor rendimento deste controlador em regiões de baixa vazão.

Sumariamente, o controlador FIHMPC apresenta resposta favorável em comparação à sua versão IHMPC. Conforme mostrado na Figura 5.16, o custo do controlador FIHMPC é inferior ao IHMPC, especialmente nas regiões de transições ou distúrbios, uma vez que

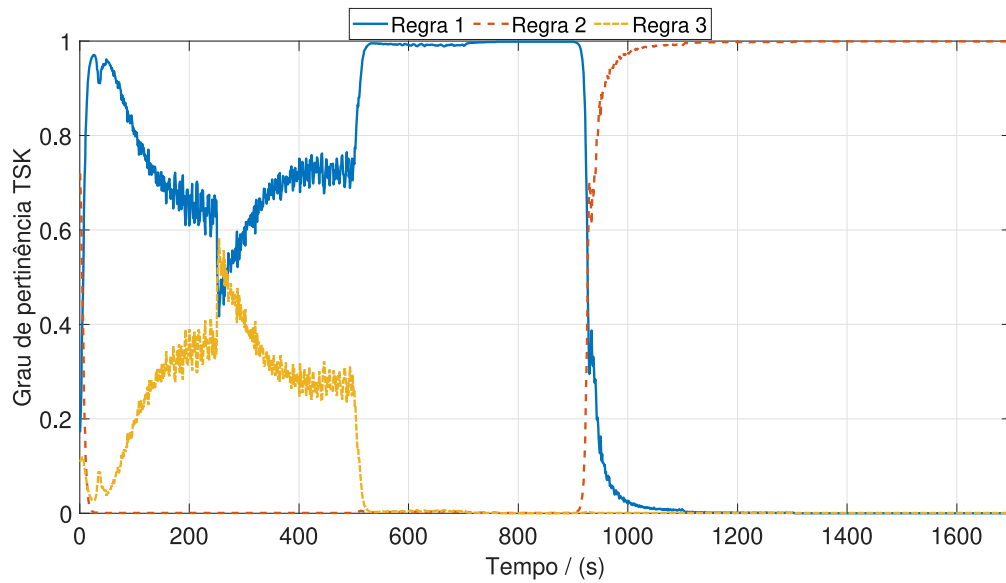


Figura 5.15: Atualização do modelo *fuzzy* usado no controlador FIHMPC.

uma menor amplitude e uma mais rápida convergência são alcançadas. Este resultado é confirmado pelo ICF apresentado na Tabela 5.4, já que o FIHMPC tem custo total 15,93 % menor que o IHMPC. O FIHMPC também apresenta uma trajetória mais rápida e curta fora do envelope, com T_{out} 13,27 % menor que seu concorrente, conforme Figura 5.12. O volume produzido V_t tem valor similar, com uma pequena diferença de 0,3 % maior para o FIHMPC, ou seja, este controlador mantém a produção do sistema com uma operação mais segura e com menor desgaste do sistema BCS frente ao controlador IHMPC.

Tabela 5.4: Comparação normalizada entre os controladores pela integral da função custo (ICF), tempo fora do envelope (T_{out}) e volume de óleo produzido (V_T).

Índice	IHMPC	FIHMPC
$ICF \times 10^6$	2,3515	1,9769
$T_{out}/(s)$	324	281
$V_T/(m^3)$	14,8140	14,8580




Figura 5.16: Função custo dos controladores FIHMPC e IHMPC.

5.3.1 Otimização econômica

Nesta seção, avalia-se o uso do *target* econômico de abertura da válvula *choke* e como o sistema BCS reage em cada cenário.

Na tabela 5.3, a coluna $\text{FIIH MPC}_{\text{targetOFF}}$ refere-se ao controlador FIIH MPC sem o uso do *target*, de forma que a maximização da abertura da válvula não faz parte do seu problema de otimização. Para isso, a \mathbf{Q}_u é zerada para desabilitar a parcela da função custo associada ao *target* e \mathbf{S}_u precisa ser aproximada a zero para não influenciar no custo total, porém não pode ser zerada para garantir que a matriz Hessiana permaneça positiva definida. O controlador utilizando o *target*, FIIH MPC é o mesmo utilizado na seção anterior.

Avaliando a pressão de entrada, Figura 5.17, não se nota diferença significativa entre as abordagens comparadas. Ambos controladores conduziram o sistema para a referência desejada e compensaram os distúrbios não medidos. Esperava-se que fosse esse o comportamento da pressão de entrada, uma vez que o baixo peso associado ao uso do *target* não torna sua otimização uma prioridade em relação às demais parcelas otimizadas.

Em relação às trajetórias sobre o envelope operacional, mostradas em Figura 5.18, mudanças significantes podem ser notadas. O controlador $\text{FIIH MPC}_{\text{targetOFF}}$ permitiu menos instantes de fuga do envelope por efeito dos distúrbios, o que pode ser escolhido como uma abordagem de operação mais segura a longo prazo para o funcionamento do sistema, mesmo que não seja alcançado o mesmo rendimento energético que com o uso de FIIH MPC.




Figura 5.17: Pressão de entrada do controlador FIIH MPC com e sem o uso do *target* econômico.

Na Figura 5.19 é possível verificar que o FIIH MPC leva a $z_c = 100\%$ o quanto antes, considerando os graus de liberdade disponíveis, o cenário e sintonia adotados. Além disso, ocorre também a redução da frequência de rotação da bomba em comparação ao




Figura 5.18: Trajetórias sobre o envelope operacional obtida da aplicação do controlador FIHMPC sobre análise econômica.

FIHMPC_{targetOFF}. Na prática, cumpre-se o objetivo de manter a válvula *choke* o mais aberta possível, por consequência reduzindo a perda de carga gerada pela válvula, e, consequentemente, reduzindo o consumo energético do motor elétrico da BCS em cerca de 2,93 %. Essa operação pode ser ainda mais benéfica para a vida útil do sistema se a frequência nominal deste for mantida por maiores intervalos de tempo, incluindo também esse *target* econômico.




Figura 5.19: Variáveis manipuladas na comparação econômica do FIHMPC.

5.3.2 Avaliação Computacional

Considerando a principal contribuição desse trabalho, o embarque de controladores FIHMPC para o sistema BCS, analisou-se o impacto computacional na aplicação embarcada, a fim de validar o comportamento em *hardware* dedicado. Com base no cenário de rastreamento de trajetória, inicialmente apresentado, foi realizado um conjunto de testes com 10 execuções do controlador FIHMPC no sistema ESP32, considerando a existência de ruídos externos ao sistema e diferentes momentos de uso do *hardware*.

Em se tratando do processo de compilação na plataforma, o programa Arduino IDE¹ indicou um uso de 21 % da memória *flash*, ou seja, o espaço de armazenamento de programas. A memória dinâmica utilizada se manteve em torno de 36 % e a memória de *heap* de 9,14 %. Estes valores apresentados indicam um uso relativamente baixo do *hardware*, sem ultrapassar as especificações do mesmo. Isto pode indicar que outras plataformas com especificações inferiores a do ESP32, como por exemplo, sistemas de controle industriais atuais, são capazes de suportar a solução de controle aqui proposta. Abre-se, portanto, a possibilidade de exploração das técnicas avançadas nas instalações *offshore* nos chamados “poços inteligentes” (TAHA; AMANI, 2019).

O problema de otimização do controlador executado no ESP32 apresentou um número máximo de 12 iterações no conjunto de testes feitos, segundo a Figura 5.20. Além disso, manteve-se majoritariamente abaixo do valor médio calculado. O tempo computacional para cada instante de tempo de execução, exibido na Figura 5.21, apresentou uma resposta similar às iterações, como esperado. Para a aplicação em tempo-real da proposta de controle, o tempo de cômputo da solução do problema de otimização não deve ultrapassar o período de amostragem do sistema e essa resposta foi observada, uma vez que o tempo máximo foi 20 vezes menor que o período de amostragem de 1 segundo, o equivalente a cerca de 5,32 % do ΔT .

A análise estatística para o tempo computacional mostrada na Figura 5.22, considerando os 10 testes de 1700 amostras, indica que a distribuição temporal se mantém na faixa de 48,70 s a 50,54 s, além de não exceder os 52,29 s. Estes resultados validam a abordagem de controle avançado proposta para poços de petróleo como computacionalmente viável para sistemas embarcados e para aplicação nas instalações isoladas dos sistemas BCS, especialmente *offshore*.

¹<https://www.arduino.cc/en/software>




Figura 5.20: O número médio, máximo e mínimo de iterações para cada passo de tempo do FIHMPC embarcado no ESP32.




Figura 5.21: O tempo computacional médio, mínimo e máximo para cada passo de tempo do FIHMPC embarcado no ESP32.

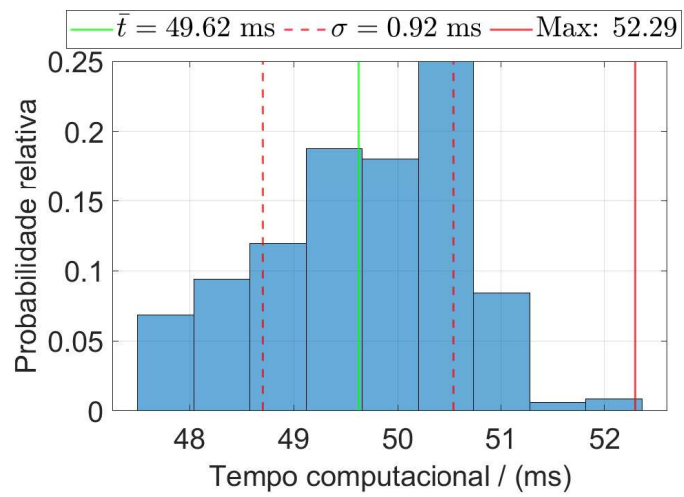


Figura 5.22: Análise estatística da distribuição do tempo computacional do controlador embarcado.

Neste capítulo são compilados as principais contribuições da técnica proposta e apresentadas as possibilidades futuras de continuação.

CONSIDERAÇÕES FINAIS

6.1 CONCLUSÃO

No decorrer deste trabalho foi apresentada a proposta do primeiro controlador preditivo com garantia de factibilidade com o modelo de predição na forma de um sistema de inferência *fuzzy* TSK, considerando uma abordagem por faixa e a aplicação embarcada em sistemas de elevação artificial do tipo BCS. O FIHMPC, aqui batizado, demonstrou rendimento e robustez consistentes com o esperado, além de não depender da existência ou aquisição de um modelo fenomenológico representativo, também não foi preciso que todas as variáveis do processo fossem mensuradas ou estimadas.

Em termos de identificação, o modelo *fuzzy* TSK obtido foi suficiente para representar a dinâmica do sistema BCS. Este modelo foi capaz de absorver a dinâmica não linear da planta e representá-la como um modelo LPV. A abordagem por clusterização para determinar os pontos de operação e encontrar os submodelos associados permitiu a obtenção de um modelo de baixa ordem e com sentido físico no que diz respeito à interpretabilidade. Isto favoreceu a implementação embarcada, especialmente com o aumento dimensional atrelado à forma OPOM.

A representatividade do modelo de predição para mais de um ponto de operação permitiu a atuação do controlador sobre toda a faixa do processo não linear. Confirmando o objetivo de sintetizar uma lei de controle preditivo que agregasse a capacidade de predição não linear, com as características da abordagem linear, em especial o peso computacional do problema de otimização. Além disso, evitaram-se linearizações sucessivas de um modelo fenomenológico não linear, reduzindo a computação em tempo real e o conhecimento especializado do sistema. Não sendo necessário também, estimar outras variáveis físicas ou parâmetros do sistema. Esta contribuição foi intensificada pela adoção da abordagem do envelope operacional como função da frequência em substituição à vazão — uma medida raramente disponível em instalações reais e que em outros trabalhos precisou ser estimada.

Os resultados da implementação embarcada no microcontrolador ESP32 mostraram que a abordagem FIHMPC estende a região operacional com melhor desempenho global, mantendo a viabilidade do problema de otimização, mesmo em um ambiente embarcado com recursos computacionais limitados. O desempenho do controlador em uma ampla faixa de operação, juntamente com sua baixa carga computacional, pode indicá-lo como uma opção mais viável em comparação com leis de controle não lineares, que seriam utilizadas para o mesmo propósito, mas com maior carga computacional.

O FIHMPC baseado em dados exibe a capacidade de manter o sistema na faixa de operação em uma situação de disponibilidade reduzida de grandezas medidas. Também foi demonstrado um desempenho aceitável para lidar com a perturbação mais comum do sistema de poços de petróleo por BCS, mantendo a estabilidade do sistema no cenário de distúrbios avaliado.

O baixo uso de memória e processamento do algoritmo valida a técnica de controle proposta em um ambiente embarcado e indica que as especificações do microcontrolador ESP32 superam os requisitos computacionais.

6.2 TRABALHOS FUTUROS

Como base nos resultados alcançado e na validação preliminar da técnica, sugere-se:

- avaliar o esquema proposto mediante um *hardware* comercial com especificações compatíveis com o ambiente de poço de petróleo e operação industrial segura, como os CLPs e SDCs;
- avaliar a aplicação da técnica considerando condições de operação multifásicas, especialmente para validar a abordagem de identificação *fuzzy* em condições de intensas variações de dinâmica;
- agregar a estabilidade robusta à técnica, uma vez que a estabilidade nominal é perdida, considerando que o modelo *fuzzy* estabelece um politopo para representar a dinâmica do sistema, em que os vértices são os submodelos lineares;
- expandir o trabalho para um campo de petróleo, considerando múltiplos poços, incluindo formulações cooperativas-distribuídas do MPC;
- avaliar técnica com a inclusão de objetivos econômicos - economic MPC (em única camada);
- abarcar sistemas de detecção, diagnóstico e isolamentos falhas típicas de poços com BCS em formulações MPC tolerantes a falhas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABONYI, J. *Fuzzy Model Identification for Control*. Boston, MA: Birkhäuser Boston, 2003. ISBN 978-1-4612-6579-5. Disponível em: <http://link.springer.com/10.1007/978-1-4612-0027-7>.
- ABONYI, J. et al. Local and Global Identification for Fuzzy Model Based Control. *Proc. of Intelligent Systems in Control and Measurement Symposium*, p. 111–116, 2000.
- ABONYI, J. et al. Local and Global Identification for Fuzzy Model Based Control. *Proc. of Intelligent Systems in Control and Measurement Symposium*, p. 111–116, 2000.
- AGUIRRE, L. A. *Introduction to Systems Identification – Linear Techniques and nonlinear applied to real systems*. [S.l.]: Editora UFMG, 2004. (in Portuguese).
- AGUIRRE, L. A. *Introdução à Identificação de Sistemas–Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. [S.l.]: Editora UFMG, 2015.
- ANP. *10 anos do Boletim da Produção de Petróleo e Gás Natural*. [S.l.], 2020. Disponível em: <https://www.gov.br/>.
- ANP. *Boletim da Produção de Petróleo e Gás Natural: Dezembro 2022*. [S.l.], 2023. Disponível em: <https://www.gov.br/anp/>.
- BABUŠKA, R. *Fuzzy Modeling for Control*. Dordrecht: Springer Netherlands, 1998. (International Series in Intelligent Technologies, v. 12). ISBN 978-94-010-6040-0. Disponível em: <http://link.springer.com/10.1007/978-94-011-4868-9>.
- BABUŠKA, R.; Van Der Veen, P. J.; KAYMAK, U. Improved covariance estimation for Gustafson-Kessel clustering. *IEEE International Conference on Fuzzy Systems*, v. 2, n. usually 1, p. 1081–1085, 2002. ISSN 10987584.
- BAHALOO, S.; MEHRIZADEH, M.; NAJAFI-MARGHMALEKI, A. Review of application of artificial intelligence techniques in petroleum operations. *Petroleum Research*, 2022. ISSN 2096-2495. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2096249522000485>.
- BEZDEK, J. C. *Pattern recognition with fuzzy objective function algorithms*. [S.l.]: Springer Science & Business Media, 2013.
- BILLINGS, S. A. *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. [S.l.]: John Wiley & Sons, 2013.

BINDER, B. J. et al. Embedded model predictive control for an electric submersible pump on a programmable logic controller. *2014 IEEE Conference on Control Applications, CCA 2014*, 2014.

BINDER, B. J.; PAVLOV, A.; JOHANSEN, T. A. Estimation of flow rate and viscosity in a well with an electric submersible pump using moving horizon estimation. *IFAC-PapersOnLine*, Elsevier Ltd., v. 28, n. 6, p. 140–146, 2015. ISSN 24058963.

CAMACHO, E. F.; BORDONS, C. *Model Predictive control*. 2. ed. London: [s.n.], 2007. (Advanced Textbooks in Control and Signal Processing). ISBN 978-1-85233-694-3. Disponível em: <http://link.springer.com/10.1007/978-0-85729-398-5>.

CAMPOS, M. et al. Controle avançado e otimização na indústria do petróleo. *Rio de Janeiro: Editora Interciência*, 2013.

CAMPOS, M. et al. *Challenges and problems with advanced control and optimization technologies*. IFAC, 2009. 1–8 p. ISSN 14746670. ISBN 9783902661548. Disponível em: <http://dx.doi.org/10.3182/20090712-4-TR-2008.00003>.

CAMPOS, M. C. et al. Advanced control systems for offshore production platforms. *Proceedings of the Annual Offshore Technology Conference*, v. 1, n. October, p. 141–153, 2013. ISSN 01603663.

CHOI, H.; PARK, H. “oil is the new data”: Energy technology innovation in digital oil fields. *Energies*, v. 13, n. 21, 2020. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/13/21/5547>.

DALHOUMI, L.; DJEMEL, M.; CHTOUROU, M. Fuzzy predictive control based on Takagi-Sugeno model for nonlinear systems. *2010 7th International Multi-Conference on Systems, Signals and Devices, SSD-10*, 2010.

DELOU, P. et al. Model predictive control with adaptive strategy applied to an electric submersible pump in a subsea environment. *IFAC-PapersOnLine*, Elsevier B.V., v. 52, n. 1, p. 784–789, 2019. ISSN 24058963. Disponível em: <https://doi.org/10.1016/j.ifacol.2019.06.157>.

DELOU, P.; SOUZA, M.; SECCHI, A. R. A Robust Adaptive MPC coupled with Kalman Filter for an Electric Submersible Pump System: A multi-model approach. *I Brazilian Congress on Process Systems Engineering (PSE-BR 2019)*, n. 2014, p. 435–438, 2019.

DELOU, P. A.; SOUZA, M. B. de; SECCHI, A. R. Addressing the lack of measurements in the subsea environment by using a model scheduling Kalman filter coupled with a robust adaptive MPC. *Brazilian Journal of Chemical Engineering*, Springer International Publishing, n. 0123456789, 2020. ISSN 01046632. Disponível em: <https://doi.org/10.1007/s43153-020-00079-x>.

DELOU, P. d. A. *ADAPTIVE MODEL PREDICTIVE CONTROL APPLIED TO SUBMERSIBLE PUMP LIFTED WELLS*. 55 p. Tese (Msc) — Universidade Federal do Rio de Janeiro, 2019.

EDWARDS, S. et al. Design of embedded systems: Formal models, validation, and synthesis. *Proceedings of the IEEE*, IEEE, v. 85, n. 3, p. 366–390, 1997.

FONTES, R. et al. On application of a zone IHMPC to an ESP-lifted oil well system. In: *Anais do Congresso Brasileiro de Automática 2020*. sbabra, 2020. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/sba/article/view/1700.

FONTES, R. M.; SANTANA, D. D.; MARTINS, M. A. An MPC auto-tuning framework for tracking economic goals of an ESP-lifted oil well. *Journal of Petroleum Science and Engineering*, Elsevier B.V., v. 217, n. July, p. 110867, oct 2022. ISSN 09204105. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0920410522007227>.

FORRAI, A. *Embedded control system design: A model based approach*. [S.l.]: Springer Science & Business Media, 2012.

GONZÁLEZ, A. H.; ODLOAK, D. A stable MPC with zone control. *Journal of Process Control*, v. 19, n. 1, p. 110–122, 2009. ISSN 09591524.

HUANG, Y. L. et al. Fuzzy model predictive control. *IEEE Transactions on Fuzzy Systems*, v. 8, n. 6, p. 665–678, 2000. ISSN 10636706.

JANG, J.; SUN, C.; MIZUTANI, E. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. [S.l.: s.n.], 1997. 614 p.

JORDANOU, J. P. et al. Nonlinear Model Predictive Control of Electrical Submersible Pumps based on Echo State Networks. *Advanced Engineering Informatics*, Elsevier Ltd, v. 52, n. June 2021, p. 101553, apr 2022. ISSN 14740346. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1474034622000283>.

KANDIAH, S. *Fuzzy Model Based Predictive Control of Chemical Processes*. 34–35 p. Tese (Doutorado) — University of Sheffield, 1996.

KARABOGA, D.; KAYA, E. Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. *Artificial Intelligence Review*, Springer Netherlands, v. 52, n. 4, p. 2263–2293, 2019. ISSN 15737462. Disponível em: <https://doi.org/10.1007/s10462-017-9610-2>.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*. IEEE, 2016. v. 4, n. 2, p. 1942–1948. ISBN 0-7803-2768-3. Disponível em: <http://ieeexplore.ieee.org/document/488968/>.

KILLIAN, M.; MAYER, B.; KOZEK, M. *Hierarchical fuzzy MPC concept for building heating control*. IFAC, 2014. 12048–12055 p. ISSN 14746670. ISBN 9783902823625. Disponível em: <http://dx.doi.org/10.3182/20140824-6-ZA-1003.00772>.

KILLIAN, M. et al. Cooperative Fuzzy Model-Predictive Control. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 24, n. 2, p. 471–482, 2016. ISSN 10636706.

KRISHNAMOORTHY, D. et al. Modelling and Robustness Analysis of Model Predictive Control for Electrical Submersible Pump Lifted Heavy Oil Wells. *IFAC-PapersOnLine*, Elsevier B.V., v. 49, n. 7, p. 544–549, 2016. ISSN 24058963. Disponível em: <http://dx.doi.org/10.1016/j.ifacol.2016.07.399>.

KRISHNAMOORTHY, D.; FJALESTAD, K.; SKOGESTAD, S. Optimal operation of oil and gas production using simple feedback control structures. *Control Engineering Practice*, v. 91, p. 104107, 2019. ISSN 0967-0661. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0967066119301261>.

KRISHNAMOORTHY, D.; FJALESTAD, K.; SKOGESTAD, S. Optimal operation of oil and gas production using simple feedback control structures. *Control Engineering Practice*, Elsevier Ltd, v. 91, n. August, p. 104107, 2019. ISSN 09670661. Disponível em: <https://doi.org/10.1016/j.conengprac.2019.104107>.

LEDIN, J. *Embedded control systems in C/C++: An Introduction for Software Developers Using MATLAB*. [S.l.]: CRC Press, 2003.

LEE, E. A.; SESHIA, S. A. *Introduction to embedded systems: A cyber-physical systems approach*. [S.l.]: Mit Press, 2017.

LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics*, v. 2, n. 2, p. 164–168, 1944.

LI, M. et al. Dissolved Oxygen Model Predictive Control for Activated Sludge Process Model Based on the Fuzzy C-means Cluster Algorithm. *International Journal of Control, Automation and Systems*, v. 18, n. 9, p. 2435–2444, 2020. ISSN 20054092.

LIMA, N. M. et al. Fuzzy model-based predictive hybrid control of polymerization processes. *Industrial and Engineering Chemistry Research*, v. 48, n. 18, p. 8542–8550, 2009. ISSN 08885885.

LJUNG, L. *System Identification: Theory for the User*. [S.l.]: Prentice Hall PTR, 1999. (Prentice Hall information and system sciences series). ISBN 9780136566953.

MATOS, V. S.; CHAGAS, T. P.; MARTINS, M. A. Integração de modelo fuzzy tsk em um controlador preditivo com região viável estendida. In: *15^o Simpósio Brasileiro de Automação Inteligente*. Rio Grande: [s.n.], 2021.

MATOS, V. S. et al. Embedded predictive controller based on fuzzy linear parameter-varying model: A hardware-in-the-loop application to an esp-lifted oil well system. *Digital Chemical Engineering*, v. 5, p. 100054, 2022. ISSN 2772-5081. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772508122000448>.

Matos, Victor S. and Chagas, Thiago P. and Martins, Márcio A.F. Integração de modelo fuzzy tsk em um controlador preditivo com região viável estendida. In: *15^o Simpósio Brasileiro de Automação Inteligente*. Rio Grande: [s.n.], 2021.

MENDES, T. P. G. *CONTROLE PREDITIVO NEURO-FUZZY: ANÁLISE COMPARATIVA EMPREGANDO DIFERENTES ESTRUTURAS DE MODELO*. Dissertação (Mestrado) — Instituto Tecnológico de Aeronáutica, 2008.

MENDES, T. P. G.; YONEYMA, T. Mpc neuro fuzzy: um estudo comparativo entre duas diferentes estratégias. In: *Simpósio Brasileiro de Automação Inteligente*. Florianópolis: [s.n.], 2007.

NAKAMORI, Y.; SUZUKI, K.; YAMANAKA, T. Model predictive control using fuzzy dynamic models. In: _____. *Fuzzy Logic: State of the Art*. Dordrecht: Springer Netherlands, 1993. p. 497–506. ISBN 978-94-011-2014-2. Disponível em: https://doi.org/10.1007/978-94-011-2014-2_46.

NELLES, O. *Nonlinear System Identification*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2001. ISBN 978-3-642-08674-8. Disponível em: <http://link.springer.com/10.1007/978-3-662-04323-3>.

NELLES, O. *Nonlinear system identification: from classical approaches to neural networks, fuzzy models, and gaussian processes*. [S.l.]: Springer Nature, 2020.

NOWAK, R. D. Nonlinear system identification. *Circuits, Systems, and Signal Processing*, v. 21, n. 1, p. 109–122, 2002. ISSN 0278081X.

ODLOAK, D. Extended robust model predictive control. *AIChE Journal*, v. 50, n. 8, p. 1824–1836, 2004. ISSN 00011541.

PATEL, K. et al. Use of advanced process control for automating conventional oilfield operations. *Society of Petroleum Engineers - SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition 2018, SATS 2018*, p. 2020, 2018.

PAVLOV, A. et al. Modelling and model predictive control of oil wells with electric submersible pumps. *2014 IEEE Conference on Control Applications, CCA 2014*, n. 3905, p. 586–592, 2014.

PINTELON, R.; SCHOUKENS, J. *System identification: a frequency domain approach*. [S.l.]: John Wiley & Sons, 2012.

ROUBOS, J. A. et al. Fuzzy model-based predictive control using Takagi-Sugeno models. *International Journal of Approximate Reasoning*, v. 22, n. 1, p. 3–30, 1999. ISSN 0888613X.

SANTANA, B. et al. Robust Model Predictive Control Applied to an ESP-lifted Oil Well System. In: *Anais do Congresso Brasileiro de Automática 2022*. sbabra, 2022. Disponível em: https://www.sba.org.br/cba2022/wp-content/uploads/artigos_cba2022/paper_4456.pdf.

SANTANA, B. A. *CONTROLE PREDITIVO COM GARANTIA DE ESTABILIDADE E FACTIBILIDADE EM SISTEMAS EMBARCADOS*. 1–13 p. Dissertação (Mestrado) — Universidade Federal da Bahia, 2020.

SANTANA, B. A.; FONTES, R. M.; MARTINS, M. A. Controlador preditivo de horizonte infinito embarcado: Aplicação hardware-in-the-loop a um sistema de bombeio centrífugo submerso. In: *15^o Simpósio Brasileiro de Automação Inteligente*. Rio Grande: [s.n.], 2021.

SANTANA, B. A.; FONTES, R. M.; MARTINS, M. A. An implementable zone NMPC applied to an ESP-lifted oil well system: Handling the lack of measurements with nonlinear state estimator coupling. *Journal of Petroleum Science and Engineering*, Elsevier B.V., v. 216, n. May, p. 110816, sep 2022. ISSN 09204105. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0920410522006751>.

SANTANA, B. A. et al. An adaptive infinite horizon model predictive control strategy applied to an esp-lifted oil well system. *IFAC-PapersOnLine*, v. 54, n. 3, p. 176–181, 2021. ISSN 2405-8963. 16th IFAC Symposium on Advanced Control of Chemical Processes ADCHEM 2021.

SARIMVEIS, H.; BAFAS, G. Fuzzy model predictive control of non-linear processes using genetic algorithms. *Fuzzy Sets and Systems*, v. 139, n. 1, p. 59–80, 2003. ISSN 01650114.

SCHNITMAN, L. *INTELLIGENT CONTROLLERS FOR DYNAMIC SYSTEMS WITH STATE AND INPUT CONSTRAINTS AND SUBJECTED TO MODEL UNCERTAINTIES*. Tese (Doutorado) — Instituto Tecnológico da Aeronáutica, 2001.

SILVA, B. P. et al. An implementable stabilizing model predictive controller applied to a rotary flexible link: An experimental case study. *Control Engineering Practice*, v. 99, p. 104396, 2020. ISSN 0967-0661. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0967066120300575>.

SUGENO, M.; KANG, G. T. Structure identification of fuzzy model. *Fuzzy Sets and Systems*, v. 28, n. 1, p. 15–33, 1988. ISSN 01650114.

TAHA, A.; AMANI, M. Introduction to smart oil and gas wells: Drilling, completion and monitoring solutions. *International Journal of Petrochemistry and Research*, v. 3, n. 1, p. 249–254, 2019.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, IEEE, n. 1, p. 116–132, 1985.

TENG, L. et al. Robust fuzzy model predictive control of discrete-time takagi-sugeno systems with nonlinear local models. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 26, n. 5, p. 2915–2925, 2018. ISSN 10636706.

WANG, L.-X. *A course in fuzzy systems and control*. [S.l.]: Prentice Hall PTR Upper Saddle River, NJ, 1997.

XIA et al. Constrained Infinite-Horizon Model Predictive Control for Fuzzy Discrete-Time Systems. *IEEE Transactions on Fuzzy Systems*, v. 18, n. 2, p. 429–436, 2010. ISSN 1063-6706. Disponível em: <http://ieeexplore.ieee.org/document/5415640/>.

ZHANG, T.; FENG, G.; LU, J. Fuzzy constrained min-max model predictive control based on piecewise Lyapunov functions. *IEEE Transactions on Fuzzy Systems*, v. 15, n. 4, p. 686–698, 2007. ISSN 10636706.

ZHANG, Y. M.; KOVACEVIC, R. Neurofuzzy model-based predictive control of weld fusion zone geometry. *IEEE Transactions on Fuzzy Systems*, v. 6, n. 3, p. 389–401, 1998. ISSN 10636706.

Salvador, 29/06/2023

DECLARAÇÃO

Declaro para os devidos fins que o texto final apresentado para a conclusão do meu curso de Mestrado em Mecatrônica da Universidade Federal da Bahia é de minha autoria. Declaro também que quaisquer informações utilizadas neste texto, mas que sejam provenientes de outros trabalhos, têm fonte claramente expressa e, quando for o caso, o seu uso foi devidamente autorizado pelo(s) respectivo(s) autor(es).



Nome: Victor Santos Matos

CPF: 048.132.955-25