



UNIVERSIDADE  
DE PERNAMBUCO

Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Programa de Pós-Graduação Acadêmica em Engenharia de Computação

Adelson Santos da Silva Júnior

# Gêmeos Digitais Interpretáveis e Adaptáveis Para Máquinas Industriais

Dissertação de Mestrado

Recife, Julho de 2023



Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Programa de Pós-Graduação Acadêmica em Engenharia de Computação

Adelson Santos da Silva Júnior

# Gêmeos Digitais Interpretáveis e Adaptáveis Para Máquinas Industriais

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-Graduação acadêmico em ENGENHARIA DE COMPUTAÇÃO da Universidade de Pernambuco como requisito parcial para obtenção do título de Mestre em Engenharia de Computação.

Prof. Dr. Fernando Buarque de Lima Neto  
Orientador

Recife, Julho de 2023

Dados Internacionais de Catalogação-na-Publicação (CIP)  
Universidade de Pernambuco – Recife

S586g Silva Júnior, Adelson Santos da  
Gêmeos digitais interpretáveis e adaptáveis para máquinas industriais. / Adelson Santos da Silva Júnior. – Recife: UPE, Escola Politécnica, 2023.

98 f.: il.

Orientador: Prof. Dr. Fernando Buarque de Lima Neto

Dissertação (Mestrado – Inteligência Computacional) Universidade de Pernambuco, Escola Politécnica, Programa de Pós-graduação em Engenharia de Computação, 2023.

1. Gêmeos Digitais. 2. Máquinas Autoconscientes. 3. Otimização por Enxames de Partículas. 4. Aplicações Industriais. 5. Modelagem Analítica. 6. Interpretabilidade. 7. Adaptabilidade. 8. Metodologia. 9. Sistemas Dinâmicos. I. Engenharia de Computação - Dissertação. II. Lima Neto, Fernando Buarque de (orient.). III. Universidade de Pernambuco, Escola Politécnica, Mestrado em Engenharia da Computação. IV. Título

CDD: 006.3



Dissertação de Mestrado apresentada por **Adelson Santos da Silva Júnior**, à Pós-Graduação em Engenharia de Computação da Escola Politécnica de Pernambuco da Universidade de Pernambuco, sob o título “**Gêmeos Digitais Interpretáveis e Adaptáveis Para Máquinas Industriais**”, orientado pelo Professor **Fernando Buarque de Lima Neto** - Doutor, onde foi aprovado pela Banca Examinadora formada pelos professores:

FERNANDO  
BUARQUE DE LIMA  
NETO:33949034404

Assinado de forma digital por  
FERNANDO BUARQUE DE LIMA  
NETO:33949034404  
Dados: 2023.08.02 11:15:49 -03'00'

---

Fernando Buarque de Lima Neto – Doutor  
(Orientador – Primeiro Examinador)

Assinado por: **Nuno Miguel Fonseca Ferreira**  
Num. de Identificação: 09807101  
Data: 2023.08.02 10:52:04+01'00'

---

Nuno Miguel Fonseca Ferreira – Doutor  
(Examinador Externo)

Documento assinado digitalmente  
 JOSE PAULO GONCALVES DE OLIVEIRA  
Data: 02/08/2023 09:31:15-0300  
Verifique em <https://validar.iti.gov.br>

---

José Paulo Gonçalves de Oliveira – Doutor  
(Examinador Interno)

Visto e permitida a impressão.  
Recife, 01 de Agosto de 2023.

Documento assinado digitalmente  
 CLEYTON MARIO DE OLIVEIRA RODRIGUES  
Data: 04/08/2023 12:01:42-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Dr. Cleyton Mário de Oliveira Rodrigues**  
Coordenador da Pós-Graduação em Engenharia de  
Computação da Escola Politécnica de Pernambuco da  
Universidade de Pernambuco



---

Universidade de Pernambuco - UPE  
Escola Politécnica de Pernambuco - POLI  
Rua Benfica, 455 • Madalena • Recife - Pernambuco • CEP  
50.720-001  
Fone: (081) 3184.7548 • CNPJ N.º 11.022.597/0005-15  
Site: [ppgec.upe](http://ppgec.upe)

*Dedico esta dissertação de mestrado à minha amada esposa, que esteve sempre presente ao meu lado, oferecendo suporte incondicional em cada passo dessa jornada. Agradeço a Deus por ter colocado você em minha vida, pois sua presença tem sido uma fonte constante de inspiração e força. Seu amor, encorajamento e compreensão foram fundamentais para que eu pudesse concluir este trabalho. Agradeço por ser meu porto seguro e por compartilhar comigo todas as alegrias e desafios. Esta conquista é nossa, e estou eternamente grato por ter você como minha parceira de vida. Te amo.*

O temor do Senhor é o princípio da sabedoria, e o conhecimento do Santo é entendimento. -  
Provérbios 9:10 (ARA)

# Resumo

Esta dissertação apresenta uma metodologia robusta para a criação e implementação de Gêmeos Digitais interpretáveis e adaptáveis, com possíveis aplicações industriais. Com o avanço tecnológico, o conceito de Gêmeos Digitais tem sido cada vez mais empregado como ferramenta para melhorar o desempenho e a eficiência de sistemas industriais. No entanto, o desenvolvimento de um Gêmeo Digital adaptativo e interpretável ainda é um desafio, especialmente quando se trata de sua aplicação em tempo real. A pesquisa começa com uma extensa fundamentação teórica, onde são abordados conceitos chave, como Gêmeos Digitais, Inteligência de Enxame, Automação Industrial e Máquinas Autoconscientes. A metodologia proposta é então introduzida, combinando a modelagem analítica com a Otimização por Enxame de Partículas, para gerar um Gêmeo Digital que pode aprender e adaptar-se às mudanças no sistema físico correspondente. A metodologia proposta é dividida em três etapas principais: modelagem do sistema físico, que envolve a formulação de equações matemáticas representando os componentes físicos do sistema; estimação de parâmetros, onde o modelo é ajustado para refletir precisamente o estado atual do sistema; e finalmente a descoberta de componentes desconhecidos, que busca identificar e integrar qualquer componente ou interação não capturada durante a modelagem inicial. Para comprovar a eficácia da metodologia, dois estudos de caso – um motor DC industrial e um atuador hidráulico – são minuciosamente apresentados e simulados. Nestas simulações, os Gêmeos Digitais exibiram notável aptidão para modelar com precisão os sistemas físicos, mesmo sob condições adversas como degradação da resistência da armadura do motor DC e alterações no fluido hidráulico. Também foi evidenciada a habilidade do Gêmeo Digital em identificar e integrar componentes anteriormente desconhecidos, como desbalanceamentos e vazamentos. Os resultados reiteram que a união dos Gêmeos Digitais com algoritmos PSO tem potencial para revolucionar o desempenho em aplicações industriais. Contudo, é indispensável considerar desafios como a demanda por dados de alta qualidade e a implementação de algoritmos de otimização em tempo real. Em conclusão, este trabalho destaca a relevância da pesquisa no progresso das máquinas autoconscientes, sublinhando a robustez, interpretabilidade e adaptabilidade dos Gêmeos Digitais propostos.

Palavras-chave: Gêmeos Digitais, Máquinas Autoconscientes, Otimização por Enxame de Partículas, Aplicações Industriais, Modelagem Analítica.

# Abstract

This dissertation presents a robust methodology for the creation and implementation of interpretable and adaptive Digital Twins, with possible industrial applications. With technological advancements, the concept of Digital Twins has been increasingly employed as a tool to enhance the performance and efficiency of industrial systems. However, the development of an adaptive and interpretable Digital Twin remains a challenge, especially when it comes to its real-time application. The research begins with an extensive theoretical foundation, where key concepts such as Digital Twins, Swarm Intelligence, Industrial Automation, and Self-Aware Machines are addressed. The proposed methodology is then introduced, combining analytical modeling with Particle Swarm Optimization to generate a Digital Twin that can learn and adapt to changes in the corresponding physical system. The proposed methodology is divided into three main stages: modeling of the physical system, which involves formulating mathematical equations representing the physical components of the system; parameter estimation, where the model is adjusted to accurately reflect the current state of the system; and finally, the discovery of unknown components, which seeks to identify and integrate any unaccounted component or interaction during the initial modeling. To verify the effectiveness of the methodology, two case studies - an industrial DC motor and a hydraulic actuator - are meticulously presented and simulated. In these simulations, the Digital Twins displayed a remarkable ability to accurately model the physical systems, even under adverse conditions such as degradation of the armature resistance of the DC motor and changes in the hydraulic fluid. The ability of the Digital Twin to identify and integrate previously unknown components, such as imbalances and leaks, was also highlighted. The results reaffirm that the combination of Digital Twins with PSO algorithms has the potential to revolutionize performance in industrial applications. However, it is essential to consider challenges such as the demand for high-quality data and the implementation of real-time optimization algorithms. In conclusion, this research emphasizes the significance in advancing self-aware machines, underscoring the robustness, interpretability, and adaptability of the proposed Digital Twins.

**Keywords:** Digital Twins, Self-Aware Machines, Particle Swarm Optimization, Industrial Applications, Analytical Modeling.

# Resumen

Esta investigación presenta una metodología robusta para la creación e implementación de Gemelos Digitales interpretables y adaptables, con posibles aplicaciones industriales. Con el avance tecnológico, el concepto de Gemelos Digitales se ha empleado cada vez más como una herramienta para mejorar el rendimiento y la eficiencia de los sistemas industriales, sin embargo, el desarrollo de un Gemelo Digital adaptativo e interpretable aún es un desafío, especialmente cuando se trata de su aplicación en tiempo real. Para lograr ello, la presente investigación parte de un amplio fundamento teórico, donde se abordan conceptos clave como Gemelos Digitales, Inteligencia de Enjambre, Automatización Industrial y Máquinas Autoconscientes la cual es base para la introducción de la metodología propuesta que combina la modelización analítica con la Optimización por Enjambre de Partículas para generar un Gemelo Digital que pueda aprender y adaptarse a los cambios en el sistema físico correspondiente. En ese sentido, la metodología propuesta se divide en tres etapas principales i) modelización del sistema físico, que implica la formulación de ecuaciones matemáticas que representen los componentes físicos del sistema; ii) estimación de parámetros, donde el modelo se ajusta para reflejar con precisión el estado actual del sistema y por ultimo; iii) la identificación de componentes desconocidos, que busca identificar e integrar cualquier componente o interacción no capturada durante la modelización inicial. Para comprobar la eficacia de la metodología, se presentan y simulan meticulosamente dos estudios de caso: un motor DC industrial y un actuador hidráulico. En estas simulaciones, los Gemelos Digitales mostraron una notable habilidad para modelar con precisión los sistemas físicos, incluso bajo condiciones adversas como la degradación de la resistencia del inducido del motor DC y cambios en el fluido hidráulico. También se evidenció la capacidad del Gemelo Digital para identificar e integrar componentes previamente desconocidos, como desequilibrios y fugas. Los resultados reafirman que la combinación de Gemelos Digitales con algoritmos PSO tiene el potencial de revolucionar el rendimiento en aplicaciones industriales. Sin embargo, es indispensable considerar desafíos como la demanda de datos de alta calidad y la implementación de algoritmos de optimización en tiempo real. En conclusión, esta investigación destaca la relevancia en el avance de las máquinas autoconscientes, subrayando la robustez, interpretabilidad y adaptabilidad de los Gemelos Digitales propuestos.

Palabras clave: Gemelos Digitales, Máquinas Autoconscientes, Optimización por Enjambre de Partículas, Aplicaciones Industriales, Modelización Analítica.

# Sumário

<b>Índice de Figuras</b> . . . . .	<b>x</b>
<b>Índice de Tabelas</b> . . . . .	<b>xii</b>
<b>Tabela de Símbolos e Siglas</b> . . . . .	<b>xiii</b>
<b>1 Introdução</b> . . . . .	<b>1</b>
1.1 Motivação, contexto e problema de pesquisa . . . . .	1
1.2 Objetivos . . . . .	3
1.3 Resultados Esperados e Impacto . . . . .	3
1.4 Estrutura do trabalho . . . . .	4
<b>2 Fundamentação teórica</b> . . . . .	<b>5</b>
2.1 Sistemas de Controle . . . . .	5
2.2 Gêmeos Digitais . . . . .	7
2.2.1 Conceitos . . . . .	8
2.2.1.1 Autoconsciência . . . . .	9
2.2.1.2 Adaptabilidade . . . . .	10
2.2.1.3 Interpretabilidade . . . . .	11
2.2.2 Estrutura do Gêmeo Digital . . . . .	11
2.2.3 Modelagem dos sistemas . . . . .	12
2.2.3.1 Modelos matemáticos . . . . .	15
2.2.3.2 Funções de Transferência e Representação no Espaço de Estados . . . . .	15
2.2.3.3 Modelos polinomiais . . . . .	17
2.2.3.3.1 Modelagem Baseada em Dados e Abordagens Adaptativas . . . . .	18
2.2.4 Identificação de Sistemas . . . . .	19
2.2.4.1 Identificação <i>Online</i> e <i>Offline</i> . . . . .	20
2.3 Otimização . . . . .	20
2.3.1 Conceitos Básicos de Otimização . . . . .	21
2.4 Inteligência de Enxames . . . . .	23
2.4.1 Conceitos . . . . .	24
2.4.2 Principais Famílias de Algoritmos . . . . .	24
2.4.3 Estimação de Parâmetros usando PSO . . . . .	25
2.4.4 Descoberta de Componentes Desconhecidos . . . . .	26
<b>3 Metodologia Proposta</b> . . . . .	<b>28</b>
3.1 Introdução . . . . .	29
3.2 Etapas da metodologia . . . . .	30
3.2.1 Modelagem do Gêmeo Digital (Etapa 1) . . . . .	31
3.2.2 Estimação de parâmetros conhecidos (Etapa 2) . . . . .	33

3.2.3	Descoberta de componentes e parâmetros desconhecidos (Etapa 3) . . .	37
3.3	Implementação do Gêmeo Digital . . . . .	40
<b>4</b>	<b>Experimentos . . . . .</b>	<b>45</b>
4.1	Configuração da Simulação . . . . .	48
4.1.1	Hardware do Computador . . . . .	48
4.1.2	Configuração do Software . . . . .	48
4.2	Estudo de Caso 1: Motor DC Industrial . . . . .	49
4.2.1	Modelo do motor DC . . . . .	50
4.2.2	Variação dos Parâmetros . . . . .	51
4.3	Estudo de Caso 2: Atuador Hidráulico . . . . .	54
4.3.1	Modelo do Atuador Hidráulico . . . . .	56
4.3.2	Variação dos Parâmetros . . . . .	57
<b>5</b>	<b>Resultados e discussão . . . . .</b>	<b>61</b>
5.1	Introdução . . . . .	61
5.2	Estudo de Caso 1: Motor DC . . . . .	62
5.2.1	Degradação da Resistência da Armadura . . . . .	62
5.2.2	Desgaste do Rolamento . . . . .	66
5.2.3	Desbalanceamento de Eixo . . . . .	70
5.3	Estudo de Caso 2: Atuador Hidráulico . . . . .	73
5.3.1	Degradação do fluido hidráulico . . . . .	73
5.3.2	Vazamento interno . . . . .	76
5.4	Análise do Tempo de Aquisição . . . . .	82
5.4.1	Degradação da Resistência da Armadura . . . . .	82
<b>6</b>	<b>Conclusão . . . . .</b>	<b>86</b>
6.1	Trabalhos Futuros . . . . .	88
	<b>Referências . . . . .</b>	<b>90</b>
	<b>ANEXO A Publicação produzida . . . . .</b>	<b>97</b>
A.1	Título . . . . .	97
A.2	Autores . . . . .	97
A.3	<i>Abstract</i> . . . . .	97
A.4	Evento . . . . .	98
A.5	Status . . . . .	98

# Índice de Figuras

Figura 1 – Evolução dos sistemas de controle automático de processos industriais. Evidenciando as principais técnicas e inovações associadas a cada estágio. . . . .	6
Figura 2 – Espectro de modelagem para Gêmeos Digitais, ilustrando a transição entre abordagens baseadas na física à esquerda e abordagens centradas em dados à direita, com exemplos destacados de modelos físicos, Filtro de Kalman e modelos de degradação. . . . .	13
Figura 3 – Representação esquemática de um circuito RC em série. Consistindo de um resistor R e um capacitor C. . . . .	16
Figura 4 – Estrutura base de modelo polinomial . . . . .	17
Figura 5 – Metodologia de criação do Gêmeo Digital interpretável . . . . .	30
Figura 6 – Representação esquemática de um pêndulo vertical, mostrando um peso suspenso de um ponto fixo e oscilando em torno de uma posição de equilíbrio vertical. . . . .	33
Figura 7 – Estimação de Parâmetros utilizando o Gêmeo Digital . . . . .	35
Figura 8 – Discrepância entre saídas do sistema real e do Gêmeo Digital . . . . .	37
Figura 9 – Fluxograma detalhado da metodologia proposta . . . . .	41
Figura 10 – Diagrama de blocos do Gêmeo Digital incorporado a um controlador . . . . .	43
Figura 11 – Diagrama de blocos do ambiente virtual de simulação. . . . .	46
Figura 12 – Esquema do sistema hidráulico abordado. . . . .	55
Figura 13 – Velocidade desejada (a) e degradação na resistência de armadura do motor DC (b) ao longo da simulação. . . . .	62
Figura 14 – Tensão de entrada do motor DC no cenário de degradação da resistência da armadura. . . . .	63
Figura 15 – Valores simulados e estimados da resistência da armadura no cenário de degradação da resistência da armadura. . . . .	64
Figura 16 – Erro de estimação relativo para a Resistência da armadura no cenário de degradação da resistência da armadura. . . . .	65
Figura 17 – Comparação entre saída de velocidade predita e aquirada do motor DC no cenário de degradação da resistência da armadura. . . . .	65
Figura 18 – Erro relativo entre saída de velocidade predita e aquirada do motor DC no cenário de degradação da resistência da armadura. . . . .	66

Figura 19 – Valores estimados e simulados do coeficiente de amortecimento no cenário de desgaste do rolamento. . . . .	67
Figura 20 – Erro percentual na estimação do coeficiente de amortecimento no cenário de desgaste do rolamento. . . . .	68
Figura 21 – Comparação entre a velocidade de saída predita e a adquirida no cenário de desgaste do rolamento. . . . .	68
Figura 22 – Erro relativo na predição da velocidade de saída no cenário de desgaste do rolamento. . . . .	69
Figura 23 – Comparação entre velocidade de saída predita e adquirida antes da descoberta de componentes desconhecidos. . . . .	71
Figura 24 – Comparação entre velocidade de saída predita e adquirida após a descoberta de componentes desconhecidos. . . . .	72
Figura 25 – Controle de posição do atuador hidráulico. . . . .	73
Figura 26 – Coeficiente de Amortecimento estimado e simulada. . . . .	74
Figura 27 – Erro relativo de estimação do Coeficiente de Amortecimento. . . . .	74
Figura 28 – Posição simulada e predita pelo Gêmeo Digital para o cenário de modificação do coeficiente de amortecimento. . . . .	75
Figura 29 – Pressão simulada do sistema para o cenário de modificação do coeficiente de amortecimento. . . . .	76
Figura 30 – Modificação na seção transversal da válvula devido ao vazamento. . . . .	77
Figura 31 – Pressão predita e simulada do sistema antes da Descoberta de Componentes Desconhecidos. . . . .	78
Figura 32 – Pressão predita e simulada do sistema após a Descoberta de Componentes Desconhecidos. . . . .	79
Figura 33 – Posição predita e simulada do pistão antes da Descoberta de Componentes Desconhecidos. . . . .	80
Figura 34 – Posição predita e simulada do pistão após a Descoberta de Componentes Desconhecidos. . . . .	80
Figura 35 – Antes: Detalhe para janela de otimização na previsão versus pressão simulada (a) e erro absoluto de previsão (b). . . . .	81
Figura 36 – Depois: Detalhe para janela de otimização na previsão versus pressão simulada do sistema (a) e erro absoluto de previsão (b). . . . .	81
Figura 37 – Erro absoluto da estimação de parâmetros para a degradação da resistência da armadura em diferentes tempos de aquisição. . . . .	83
Figura 38 – Erro relativo da estimação de parâmetros para a degradação da resistência da armadura em diferentes tempos de aquisição. . . . .	84
Figura 39 – Comparação entre a velocidade de saída predita pelo modelo e simulada. . . . .	85

# Índice de Tabelas

Tabela 1 – Comparação entre diferentes métodos de otimização. . . . .	23
Tabela 2 – Exemplos de Meta-Modelos e Condições de Operação Atribuídas . . . . .	38
Tabela 3 – Parâmetros iniciais do motor DC simulado. . . . .	51
Tabela 4 – Parâmetros da otimização por PSO . . . . .	52
Tabela 5 – Parâmetros iniciais do atuador hidráulico simulado usado no experimento. .	57
Tabela 6 – Parâmetros do Controlador PID para a controle da área da seção transversal da Válvula. . . . .	58

## Tabela de Símbolos e Siglas

DT	<i>Digital Twin</i>
DC	<i>Direct Current</i>
PSO	<i>Particle Swarm Optimization</i>
RMSE	<i>Root Mean Square Error</i>
$V_a$	Tensão de armadura do motor DC
$R_a$	Resistência de armadura do motor DC
$I_a$	Corrente de armadura do motor DC
$L_a$	Indutância de armadura do motor DC
$K_e$	Constante de tensão contrária do motor DC
$\omega_r$	Velocidade angular do motor DC
$J$	Momento de inércia do motor DC
$B$	Coefficiente de amortecimento do motor DC
$T_{load}$	Torque de carga do motor DC
$K_t$	Constante de torque do motor DC
$i_k$	Corrente no instante k
$i_{k-1}$	Corrente no instante k-1
$T_s$	Tempo de amostragem ( <i>Step Time</i> )
$\omega_k$	Velocidade angular no instante k
$\omega_{k-1}$	Velocidade angular no instante k-1
$\mathbf{V}i(k + 1)$	Velocidade da partícula i no instante k+1
$\mathbf{V}i(k)$	Velocidade da partícula i no instante k

$c_1$	Coefficiente cognitivo do PSO
$r_1$	Fator de escala aleatório 1
$P_i(k)$	Melhor posição da partícula $i$ no instante $k$
$X_i(k)$	Posição da partícula $i$ no instante $k$
$c_2$	Coefficiente social do PSO
$r_2$	Fator de escala aleatório 2
$G_i(k)$	Melhor posição global no instante $k$
$X_i(k)$	Posição da partícula $i$ no instante $k$
$v_{valvula}$	Velocidade do fluido na válvula
$p_{sistema}$	Pressão do sistema hidráulico
$q_{valvula}$	Vazão do fluido na válvula
$q_{bomba}$	Vazão da bomba
$A_{\{valvula\}}$	Área da seção transversal da válvula
$A_{\{pistao\}}$	Área da seção transversal do pistão
$F_{\{carga\}}$	Força de carga no sistema
$F_{\{mola\}}$	Força da mola no sistema
$F_{\{amort\}}$	Força de amortecimento no sistema
$F_{\{resist\}}$	Força resistiva no sistema
$k_{\{mola\}}$	Constante elástica do sistema em $N/m$
$D$	Coefficiente de amortecimento do sistema em $N/(m/s)$
$A_{max}$	Máxima seção transversal da válvula em $m^2$
$k_p$	Coefficiente proporcional do controlador PID
$k_i$	Coefficiente integral do controlador PID
$k_d$	Coefficiente derivativo do controlador PID
$p_k$	Pressão no instante $k$
$C$	Coefficiente de vazamento do fluido

# Agradecimentos

Em primeiro lugar, gostaria de expressar minha gratidão a Deus, meu Senhor, acima de tudo, por Seu amor e salvação. Agradeço por poder sentir a Sua presença e cuidado todos os dias. Suas promessas e desígnios nunca falham, Sua luz é um guia para todos aqueles que O buscam.

À minha companheira, Mythilene, pelo apoio incondicional e ajuda nos momentos mais difíceis e pelos sorrisos e abraços na alegria sempre presente, você é meu mundo, e nada seria possível sem você ao meu lado.

Aos meus pais, Adelson e Fátima, que nunca mediram esforços ao longo da minha vida, pelo amor, cuidado, educação e apoio, preparando, acompanhando e me auxiliando no caminho da vida, eu os amo, e vocês são a base de tudo que sou hoje.

Minha avó Amara (in memoriam), foi minha segunda mãe, e agradeço a Deus por tê-la tido por tanto tempo ao meu lado. Sinto sua falta.

Aos meus avós Sérgio e Jurandir, por sempre acreditarem e esperarem o meu melhor. Vocês são exemplos pra mim. Às minhas irmãs, pelo incentivo e torcida mesmo quando estive distante.

À toda a minha família, tios, tias, primos, primas, sogro, cunhada e cunhados pela importância significativa nesta jornada.

Agradeço de coração a João Luiz, meu amigo, um verdadeiro co-orientador, que nunca desistiu de mim e sempre me apoiou durante a jornada. Você é um companheiro para a vida.

Devo também uma imensa gratidão à equipe de pesquisa em Inteligência Artificial Explicável e Internet das Coisas. Cada membro desta equipe tem sido fundamental para a minha trajetória. Agradeço também ao PPGEC - UPE.

Por fim, gostaria de expressar minha profunda gratidão ao meu orientador, Fernando Buarque. Sei que dei um grande trabalho, mas sua compreensão e apoio foram essenciais.

Por último, mas não menos importante, a todos aqueles que contribuíram direta e indiretamente para a realização deste trabalho e, especialmente, àqueles que oraram e continuam orando pela minha vida e minha família.

# Capítulo 1

## Introdução

### 1.1 Motivação, contexto e problema de pesquisa

A evolução da tecnologia tem desempenhado um papel fundamental na transformação de setores industriais ao longo das últimas décadas. A automatização e a digitalização têm revolucionado a forma como as indústrias operam, desde a terceira revolução industrial até o advento da Indústria 4.0 [1]. A busca por melhorias no controle e eficiência dos processos industriais tem sido um esforço significativo da humanidade.

Os sistemas dinâmicos, inerentes ao funcionamento de muitas máquinas e processos industriais, são caracterizados por mudanças em seus estados ao longo do tempo [2]. O controle eficaz desses sistemas requer uma compreensão profunda de suas dinâmicas. No entanto, a complexidade desses sistemas, aliada a fatores imprevisíveis e, por vezes, desconhecidos, como condições climáticas adversas, variações nas condições operacionais, envelhecimento e deterioração dos componentes, representam desafios significativos para um controle eficaz [3]. Isso pode resultar em falhas no controle ou na operação, causando perdas de produtividade, financeiras ou até mesmo pessoais para todos os envolvidos.

Neste sentido, a busca por métodos avançados de controle e monitoramento se torna crucial. A teoria de controle moderna e clássica tem um foco importante no estudo desses sistemas e de seu comportamento, construindo modelos dos sistemas físicos e usando-os no desenvolvimento de controladores de sistemas [4].

Dentre as tecnologias emergentes, os Gêmeos Digitais (*Digital Twins*) representam um conceito revolucionário para aplicações industriais [5] [6], [7], [8]. Estes modelos virtuais, que replicam sistemas físicos, oferecem a possibilidade de simular e prever comportamentos, melhorar o controle e otimizar a manutenção [9]. A capacidade de atualizar continuamente os Gêmeos Digitais com dados em tempo real permite previsões mais precisas e melhores tomadas de decisão [8]. Consequentemente, permite, em instâncias posteriores, a autoconsciência e otimização do controle automático de processos em ambientes industriais.

Apesar dos avanços proporcionados pelos Gêmeos Digitais, existem barreiras que dificultam a sua implementação. Uma dessas barreiras é a complexidade e as incertezas inerentes a sistemas reais, que tornam desafiadora a criação de um Gêmeo Digital fiel e adaptativo. Além disso, à medida que os modelos se tornam mais complexos, entender ou interpretar o porquê de certas decisões ou previsões pode ser um desafio. A interpretabilidade, então, representa a medida na qual um sistema é compreendido. Em ambientes industriais, onde a compreensão clara das relações entre entradas e saídas é crucial, a falta de interpretabilidade nos modelos tradicionais pode limitar severamente a confiança dos operadores nas previsões do modelo e, conseqüentemente, em suas aplicações práticas, exigindo também expertise e instrumentação especializada para sua implementação e uso.

Assim, surge a necessidade de desenvolver uma metodologia que seja capaz de superar essas barreiras, proporcionando a criação de Gêmeos Digitais que sejam não apenas adaptativos, mas também interpretáveis, dando um passo para a autoconsciência e facilitando a sua aceitação, implementação e uso em cenários industriais.

A interpretabilidade desempenha um papel fundamental na aceitação e implementação prática dos Gêmeos Digitais na indústria. No contexto industrial, compreender o mecanismo de funcionamento dos modelos é crucial para uma tomada de decisões baseada nas previsões geradas. Portanto, o Gêmeo Digital deve fornecer uma representação do sistema que seja facilmente interpretável e compreensível pelos usuários.

Uma abordagem efetiva para promover a interpretabilidade do Gêmeo Digital é permitir que os usuários identifiquem como as diferentes condições físicas afetam as previsões geradas pelo modelo. Por exemplo, ao relacionar as variáveis do modelo com as características físicas do sistema, como temperatura, pressão e fluxo, é possível o entendimento sobre o comportamento do sistema e como as mudanças nessas variáveis influenciam as previsões.

De forma análoga, o conceito de autoconsciência se refere à capacidade de um ser entender as próprias condições e estados, adaptando-se e reagindo às mudanças em tempo real. Aplicado ao contexto de máquinas industriais, isso permitirá que um Gêmeo Digital reflita ou reproduza o estado atual do sistema físico e seja capaz de fazer previsões precisas sobre seu comportamento futuro. Argui-se que a autoconsciência pode aumentar a eficiência e a produtividade, ao mesmo tempo que reduz o tempo de inatividade, por meio da identificação e correção de anomalias de funcionamento [10].

Tendo em vista a motivação e os desafios apresentados, a pergunta central da pesquisa pode ser formulada da seguinte forma:

Como desenvolver um Gêmeo Digital que seja capaz de aprender e adaptar-se dinamicamente às mudanças nas condições operacionais, mantendo um alto grau de interpretabilidade para facilitar a aceitação e a implementação em cenários industriais?

## 1.2 Objetivos

O objetivo principal deste trabalho é desenvolver um Gêmeo Digital interpretável e adaptável para máquinas industriais. Para atingir esse objetivo, propõe-se uma metodologia híbrida que combina a modelagem analítica com heurísticas de otimização, como a Otimização por Enxame de Partículas (PSO). Os objetivos específicos da pesquisa incluem:

1. Propor uma metodologia híbrida para a criação de Gêmeos Digitais interpretáveis, que combine a modelagem analítica com a Otimização por Enxame de Partículas.
2. Desenvolver Gêmeos Digitais para um motor DC industrial e um atuador hidráulico, como estudos de casos, utilizando a metodologia proposta.
3. Avaliar a performance, interpretabilidade e a adaptabilidade dos Gêmeos Digitais desenvolvidos em diferentes cenários operacionais.
4. Discutir o nível de autoconsciência atingido pela metodologia proposta.

## 1.3 Resultados Esperados e Impacto

A principal contribuição esperada deste trabalho é o desenvolvimento de uma metodologia híbrida para a criação de Gêmeos Digitais interpretáveis e adaptáveis, que possa ser aplicada em diferentes cenários industriais. Através da combinação de técnicas analíticas e heurísticas, espera-se que a metodologia proposta seja capaz de lidar com a complexidade e incertezas de sistemas reais, proporcionando uma representação virtual mais fiel e adaptativa das máquinas industriais.

Além disso, espera-se que os Gêmeos Digitais desenvolvidos, sendo mais interpretáveis e adaptáveis, sejam capazes de fornecer ferramentas e dados robustos e confiáveis para os tomadores de decisão. Esta capacidade ampliada tem o potencial de otimizar a eficiência e a produtividade das máquinas industriais, auxiliando na formulação de decisões mais fundamentadas e informadas.

Finalmente, este trabalho representa um avanço em direção à autoconsciência em máquinas industriais. Ao adotar a metodologia híbrida proposta, o Gêmeo Digital tem a capacidade de se autoavaliar e se adaptar, possibilitando que a máquina reconheça e interprete seu próprio estado e condições de operação.

A metodologia proposta aborda os desafios de interpretabilidade e adaptabilidade dos Gêmeos Digitais e fornece uma estrutura prática para autoconsciência e tomada de decisão em máquinas industriais.

## 1.4 Estrutura do trabalho

O restante desta dissertação está organizado da seguinte forma:

O Capítulo 2 - "Fundamentação Teórica", oferece uma revisão da literatura sobre Gêmeos Digitais e os conceitos de autoconsciência, adaptabilidade e interpretabilidade. Ele também discute a aplicação de Gêmeos Digitais na indústria e o uso do algoritmo de Otimização por Enxame de Partículas (PSO do inglês *Particle Swarm Optimization*) para a estimação de parâmetros.

No Capítulo 3 - "Metodologia", a metodologia proposta para a criação de um Gêmeo Digital interpretável e adaptável é apresentada. A estratégia para a integração da modelagem analítica com a PSO é detalhada nesta seção.

No Capítulo 4 - "Experimentos", um motor de corrente direta (DC, do inglês *Direct Current*) industrial e um atuador hidráulico são selecionados como estudos de casos para aplicar e testar a metodologia proposta. O Ambiente de simulação é detalhado assim como a implementação da metodologia proposta.

No Capítulo 5 - "Resultados e Discussão", a performance e a adaptabilidade dos Gêmeos Digitais desenvolvidos são avaliadas em diferentes cenários operacionais. Os resultados das simulações são discutidos à luz da pesquisa existente e das implicações práticas.

No Capítulo 6 - "Conclusão", as conclusões do trabalho são apresentadas. As contribuições do estudo, as limitações e as possíveis direções para pesquisas futuras são discutidas neste capítulo.

# Capítulo 2

## Fundamentação teórica

Este Capítulo traz uma breve revisão no estado da arte em sistemas de controle, gêmeos digitais, modelagem e identificação de sistemas, otimização, inteligência de enxames e aplicações industriais.

### 2.1 Sistemas de Controle

O controle automático de processos industriais, abrangendo áreas como manufatura, sistemas energéticos, produção química e sistemas biológicos, tem desempenhado um papel vital no campo da pesquisa e desenvolvimento durante os últimos 80 anos, evoluindo através de quatro estágios significativos de desenvolvimento: controle convencional, e controles avançados I, II e III [11].

O estágio inicial, conhecido como controle convencional, compreende técnicas de controle amplamente utilizadas na indústria até hoje. A maioria das aplicações industriais ainda emprega técnicas de controle proporcional, integral e derivativo (PID) juntamente com métodos de controle manuais, de cascata, de retroalimentação, de realimentação e combinações desses [4]. Estas técnicas fundamentais formam a base do controle de processos moderno, proporcionando um ponto de partida crucial para desenvolvimentos mais avançados.

O controle avançado I, que representa o segundo estágio de desenvolvimento, introduz um elemento de adaptabilidade no cenário de controle de processos. Este estágio incorpora técnicas como controle autoajustável e ajuste de ganhos [12], expandindo significativamente a gama de sistemas que podem ser efetivamente controlados. Além disso, o controle avançado I introduz conceitos de controle multivariável, como o método do espaço de estados e funções de transferência, o método do lugar das raízes e métodos de controle não linear [4].

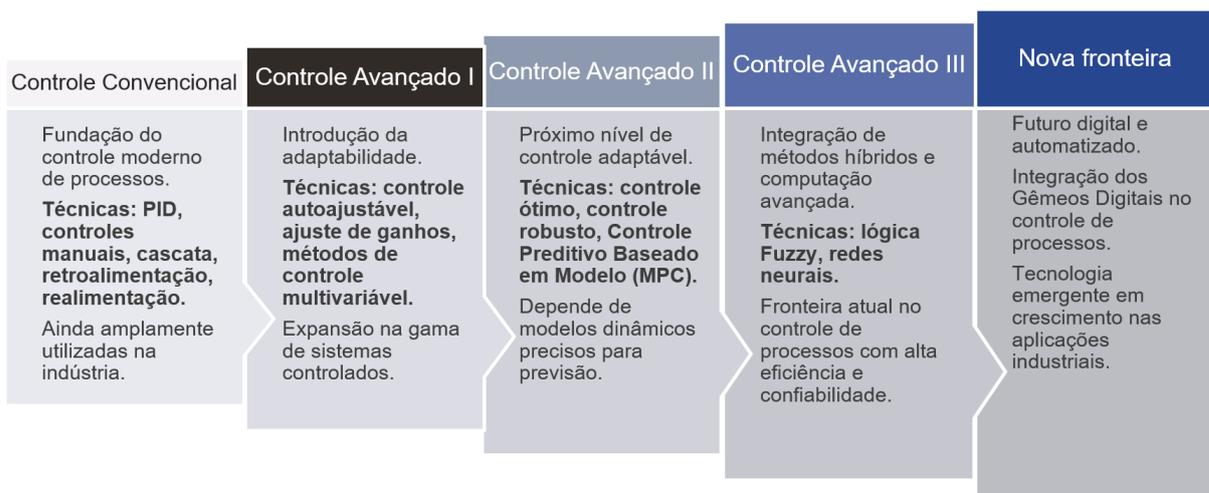
O terceiro estágio, conhecido como controle avançado II, leva o conceito de controle adaptável um passo adiante, incorporando técnicas como controle ótimo, controle robusto e controle preditivo baseado em modelo (MPC, do inglês *Model Predictive Control*) [13][9]. Estas técnicas utilizam modelos dinâmicos, ou seja, representações simplificadas para prever o

comportamento futuro do sistema, tornando a disponibilidade e a precisão desses modelos uma questão crítica. Essa necessidade de modelos precisos e adaptáveis de sistemas de controle nos leva à introdução e ao uso dos Gêmeos Digitais, uma tecnologia emergente que se tornou cada vez mais proeminente em várias aplicações industriais.

Por fim, o estágio mais recente, controle avançado III, envolve a integração de métodos híbridos e técnicas de computação avançada. Exemplos incluem o uso de lógica *Fuzzy* [14] e redes neurais [15] para fornecer controle mais preciso e adaptativo. Esses métodos avançados representam a fronteira atual do controle de processos, oferecendo potencial para melhorias significativas na eficiência e confiabilidade dos sistemas industriais.

A Figura 1 apresenta a evolução dos sistemas de controle desde o "Controle Convencional" até a "Nova Fronteira". Da esquerda para direita, podemos observar a progressão das técnicas utilizadas em cada fase, fornecendo uma visão panorâmica da trajetória do controle automático de processos industriais. No estágio inicial, destaca-se a predominância do controle PID, acompanhado de métodos como controle manual e de realimentação. Conforme avançamos, o "Controle Avançado I" introduz elementos de adaptabilidade, com técnicas como controle autoajustável e ajuste de ganhos. O "Controle Avançado II" enfatiza a integração de modelos dinâmicos, com destaque para técnicas como controle ótimo e MPC. O "Controle Avançado III" ilustra a vanguarda do controle de processos, integrando lógica Fuzzy e redes neurais. Finalmente, o último estágio elenca a integração dos Gêmeos Digitais como uma nova fronteira.

Figura 1 – Evolução dos sistemas de controle automático de processos industriais. Evidenciando as principais técnicas e inovações associadas a cada estágio.



Fonte: elaborado pelo autor (2023)

Por isso, na medida em que a indústria avança para um futuro cada vez mais digital e automatizado, torna-se imperativo estudar e entender as implicações desses avanços, e como

eles podem ser melhor integrados para melhorar a eficiência, a confiabilidade e a adaptabilidade dos processos de controle. Em particular, a integração e implementação de Gêmeos Digitais no controle de processos industriais representa uma nova fronteira para a indústria e é a área principal de investigação desta dissertação. A próxima seção detalha mais sobre Gêmeos Digitais, sua estrutura, a identificação de parâmetros e modelos parametrizáveis, e como eles se integram à prática do controle de processos.

## 2.2 Gêmeos Digitais

Um Gêmeo Digital (DT, do inglês *Digital Twin*) é uma representação digital fiel de um sistema ou objeto físico, possibilitando a simulação, análise e otimização de suas características e comportamentos em um ambiente virtual.

Considerando as técnicas modernas de controle de sistemas dinâmicos, o uso de Gêmeos Digitais tornou-se cada vez mais popular, pois eles podem ser utilizados para entender o comportamento e as características do sistema real sem interromper sua operação [8]. Podemos citar o crescente uso por diversas indústrias como engenharia aeroespacial, manufatura e robótica que são exemplos notáveis onde esta tecnologia tem causado um impacto significativo [16].

Li *et al.* [17] apresentam um levantamento abrangente sobre Gêmeos Digitais, seus impactos, implementações e os desafios associados em setores-chave, incluindo aeroespacial. Eles destacam particularmente a coleta de dados em tempo real, sincronização e problemas de processamento que podem dificultar a adoção suave dos Gêmeos Digitais na indústria aeroespacial. Os autores também identificam a necessidade de padronização, especialmente ao criar Gêmeos Digitais altamente interativos com capacidades cognitivas. Sua proposta enfatiza um caminho para tal padronização, que pode ser uma chave para expandir as aplicações aeroespaciais, tanto em termos tecnológicos quanto empresariais.

Além disso, um extenso e relevante trabalho foi realizado por Fei Tao *et al.* [18], que revisou o estado da arte da pesquisa em Gêmeos Digitais. Os autores discutiram os principais componentes, o desenvolvimento e as principais aplicações de Gêmeos Digitais na indústria. Esses tópicos são abordados com mais detalhes na próxima seção.

Dentro do contexto industrial, os Gêmeos Digitais representam uma ferramenta indispensável para a gestão eficiente de operações e para a tomada de decisões baseadas em dados. A capacidade de replicar virtualmente um sistema físico complexo oferece oportunidades únicas para a otimização e o aprimoramento de processos industriais.

Finalmente, a implementação efetiva de um Gêmeo Digital requer uma compreensão sólida de seus conceitos fundamentais, bem como de sua aplicação em cenários reais. Nesse sentido, as próximas seções detalham alguns dos conceitos-chave associados aos Gêmeos Digitais e sua aplicação na indústria.

### 2.2.1 Conceitos

A ideia de Gêmeos Digitais, uma revolução tecnológica que promete transformar a maneira como interagimos com o mundo físico, começou a tomar forma em 2003. Introduzido por Grieves em seu curso sobre "gerenciamento do ciclo de vida do produto", o conceito inicialmente proposto era de um modelo que englobasse três partes: o produto físico, o produto virtual e as conexões entre eles [19]. Esta definição preliminar, embora de certa forma muito abrangente, lançou as bases para a explosão exponencial das tecnologias habilitadoras dos Gêmeos Digitais.

Em 2012, o conceito de DTs foi revisitado pela *National Aeronautics and Space Administration* (NASA), que definiu o DT como uma simulação multi-física, multiescala, probabilística, e de ultra-fidelidade que reflete o estado de um gêmeo correspondente com base em dados históricos, dados de sensores em tempo real e modelo físico [20]. Embora 'ultra-fidelidade' indique uma representação extremamente precisa, é importante entender que ela pode não capturar todas as nuances minúsculas do sistema real. Ainda assim, essa definição refinada trouxe o conceito de DTs para a vanguarda da pesquisa atual, permitindo um estudo mais aprofundado e a aplicação prática em uma variedade de campos.

No entanto, ainda existem diferentes compreensões sobre o que constitui um Gêmeo Digital. Algumas pesquisas focam na importância da simulação para os DTs [21][22], enquanto outras argumentam que os DTs são construídos a partir de três dimensões: partes físicas, virtuais e de conexão [19]. Essa divergência de opiniões evidencia a complexidade e a flexibilidade dos Gêmeos Digitais, que podem ser adaptados para atender a uma gama diversificada de necessidades de pesquisa e de indústria.

Baseado no modelo de três dimensões para o DT, Tao et al. propuseram que um DT completo deveria incluir cinco dimensões: parte física, parte virtual, conexão, dados e serviço [18]. As cinco dimensões são igualmente importantes para os DTs. A parte física é a base para a construção da parte virtual. A parte virtual suporta a simulação, a tomada de decisões e o controle da parte física. Nesse sentido, Tao et al. argumentam que a dimensão dos dados está no centro dos DTs, pois é uma pré-condição para a criação de novo conhecimento. Eles também defendem a importância da dimensão de serviço. DTs conduzem a novos serviços que podem aprimorar a conveniência, a confiabilidade e a produtividade de um sistema de engenharia.

Um aspecto crucial dos DTs é sua capacidade de simular eventos com precisão em diferentes escalas de espaço e tempo. As simulações desempenham um papel significativo na engenharia moderna permitindo aos engenheiros testar *designs* e protótipos sem gastar recursos temporais e monetários excessivos na construção e manufatura [22]. Em vez disso, uma simulação por computador é relativamente rápida e barata de implantar. Os custos de falha são mínimos, incentivando a experimentação e o pensamento criativo.

Assim, os DTs se baseiam não apenas no conhecimento especializado, mas também, em

uma macro visão, coletam dados de todos os sistemas implantados de seu tipo e, então, agregam a experiência adquirida em campo. Desse modo, os DTs não só são usados durante o *design* do sistema, mas também durante o tempo de execução, para prever o comportamento do sistema *online* [22]. Isso pode ser útil para a previsão de falhas, mas também é algo importante a ser explorado pelos algoritmos de planejamento baseados em simulação.

Em relação a uma micro visão, o desenvolvimento das tecnologias habilitadoras dos DTs, como o aumento da capacidade de processamento de sistemas embarcados, ampliou seu uso além do planejamento, *design* e simulação de sistemas, permitindo sua incorporação diretamente nos controladores das máquinas. Isso faz com que um Gêmeo Digital esteja constantemente operante, coletando dados em tempo real e fornecendo *feedback* contínuo para o sistema de controle, possibilitando que o DT faça ajustes em tempo real, otimizando o desempenho e minimizando o tempo de inatividade.

Com uma compreensão clara do que constitui um Gêmeo Digital, é crucial examinar algumas características intrínsecas que potencializam sua utilidade e eficácia em diversos contextos. Nos próximos segmentos, discutimos aspectos como a ‘Autoconsciência’, ‘Adaptabilidade’ e ‘Interpretabilidade’ dos Gêmeos Digitais e sua importância no cenário atual.

### 2.2.1.1 Autoconsciência

A integração profunda entre o Gêmeo Digital e o controlador da máquina introduz a possibilidade de sistemas que manifestam um grau de autoconsciência. No contexto dos Gêmeos Digitais, "autoconsciência" refere-se especificamente à capacidade de um sistema reconhecer e monitorar seu próprio estado e comportamento, assim como avaliar seu desempenho em relação aos objetivos estabelecidos. Isso possibilita ao Gêmeo Digital uma compreensão mais profunda e precisa das condições operacionais e do desempenho do sistema físico que representa.

Dessa forma, o Gêmeo Digital vai além de ser apenas um modelo de simulação. Ele se transforma em um componente ativo e integrado do sistema de controle da máquina, capaz de mapear e monitorar constantemente seu próprio estado e desempenho em relação aos parâmetros definidos. Isso permite, em determinados contextos, a previsão de falhas e otimização de planejamento, enquanto também garante que a máquina possa perceber e responder a mudanças em tempo real [10].

A ideia de autoconsciência em Gêmeos Digitais, embora pareça um conceito abstrato, é uma característica integral em aplicações mais avançadas. Assim como os seres humanos têm a capacidade de entender seu próprio estado e comportamento, os Gêmeos Digitais mais avançados podem ser projetados para ter um entendimento semelhante de sua condição e operação. Esta autoconsciência é facilitada através da constante alimentação de dados do sistema físico para o digital, permitindo que o Gêmeo Digital acompanhe e compreenda seu próprio estado em tempo real [23].

### 2.2.1.2 Adaptabilidade

A adaptabilidade é um elemento fundamental na implementação de Gêmeos Digitais. Nesse contexto, pode ser definida como a capacidade do sistema de ajustar seu comportamento em resposta a mudanças no ambiente ou nas condições operacionais [20]. Isso inclui, de maneira particular, a habilidade de atualizar e ajustar o modelo digital do sistema representado com base em novos dados obtidos em tempo real, permitindo que o Gêmeo Digital reflita com precisão o estado atual do sistema físico [24].

Enquanto a autoconsciência envolve o reconhecimento e monitoramento do estado atual, a adaptabilidade foca na capacidade do Gêmeo Digital de responder e se ajustar a mudanças. Portanto, um Gêmeo Digital autoconsciente está ciente de seu estado, enquanto um Gêmeo adaptável pode alterar seu comportamento ou modelo com base nas informações que recebe.

A instrumentação de um sistema com sensores é uma técnica que pode ser utilizada para adaptação. A medição de parâmetros específicos durante a operação de uma máquina permite a atualização do modelo digital com os valores atuais do sistema, tornando o Gêmeo Digital mais preciso em suas previsões. No entanto, a instrumentação especializada necessária para a medição desses parâmetros aumenta significativamente os custos de operação e manutenção, sendo em muitos casos inviável.

Por outro lado, uma das maneiras de tornar o Gêmeo Digital mais adaptável é a estimação contínua (ou *online*) de parâmetros. Utilizando dados em tempo real, valores referentes a parâmetros não instrumentados do sistema são estimados de forma a adaptar os modelos durante a sua operação [25]. Em diversos casos, essa estimação matemática pode ser resolvida como um problema de otimização, onde a função de custo é minimizada para garantir a adaptação do modelo. [26]. O modelo então é atualizado de maneira a representar o sistema mais precisamente em tempo real.

Esta abordagem não deve ser confundida com o conceito de ‘sensor virtual’. Embora ambos busquem estimar valores não diretamente medidos, um ‘sensor virtual’ tenta replicar a leitura de um sensor real, usando combinações de outras leituras e modelos matemáticos. Por outro lado, a estimação de parâmetros aqui abordada foca em ajustar e otimizar os parâmetros do modelo do Gêmeo Digital com base nos dados reais coletados, visando uma representação mais precisa do sistema.

No entanto, até o momento tem sido considerado um Gêmeo Digital com uma estrutura fixa onde os parâmetros, sejam instrumentados ou não, são conhecidos ou considerados quando da criação do modelo. Todavia, essa abordagem pode enfrentar limitações na captação de todas as variáveis e parâmetros que influenciam as saídas do sistema. Essas variáveis podem não ter estado presentes no momento da criação do modelo ou podem não ter sido suficientemente capturadas seja numa modelagem analítica do sistema ou ainda nos dados usados para a geração do modelo. Além disso, falhas ou mudanças inesperadas no sistema podem levar a uma divergência entre as

previsões do Gêmeo Digital e os resultados reais do sistema.

Portanto, outras abordagens de adaptação precisam ser exploradas quanto ao desenvolvimento modelo de Gêmeo Digital. Para uma representação ainda mais precisa do comportamento do sistema, é essencial considerar também certos componentes e parâmetros que podem ser desconhecidos inicialmente. A incorporação desses elementos desconhecidos ao modelo pode potencializar sua capacidade de retratar o sistema durante um determinado período operacional [27].

### **2.2.1.3 Interpretabilidade**

Um outro conceito crucial em aplicações industriais é o de interpretabilidade [5]. As partes responsáveis pelas decisões sobre a operação de um determinado sistema tendem a confiar mais em algo que possam entender em certo nível, do que em um modelo de "caixa preta" que lhes diz o que precisam fazer para aumentar a eficiência, produtividade, etc. Portanto, é importante que o Gêmeo Digital possa fornecer uma representação do sistema que seja interpretável.

Interpretabilidade, como um conceito chave, representa a medida na qual um sistema é compreendido, seja por operadores humanos ou outros sistemas. Esta compreensão pode ser considerada em termos de previsibilidade, transparência, correlação causal entre entradas e saídas e, em relação a um Gêmeo Digital, correlação entre os componentes do sistema real e sua representação [28]. Em sistemas complexos, como Gêmeos Digitais, a interpretabilidade tem um papel crucial na garantia de que o sistema possa ser confiável e, assim, possa efetivamente desempenhar seu papel.

Por outro lado, a interpretabilidade também pode ser um desafio significativo em gêmeos digitais. Por causa da sua natureza complexa e multidimensional, pode ser difícil discernir como as entradas do sistema afetam suas saídas. Este problema é ainda mais acentuado quando o modelo do Gêmeo Digital inclui componentes não-lineares ou adaptativos, o que pode tornar as relações de entrada-saída mais difíceis de entender [29].

Assim, a interpretabilidade é um aspecto fundamental da implementação de gêmeos digitais na indústria. Um Gêmeo Digital interpretável é mais fácil de gerenciar, mais confiável na tomada de decisões e que pode ser integrado com outros sistemas e processos industriais.

## **2.2.2 Estrutura do Gêmeo Digital**

Uma das características fundamentais dos Gêmeos Digitais é a estrutura interna do que chamamos de parte virtual, que dá forma à representação digital do sistema físico em interesse. A seleção da estrutura é crítica para a eficácia do Gêmeo Digital, uma vez que determina o grau de semelhança com o sistema físico assim como o quanto os métodos de análise utilizados são relevantes. No geral, essa estrutura pode se referir a diferentes aspectos do Gêmeo Digital, como

o tipo de modelo utilizado para representar o sistema e sua atualização e os métodos de coleta e processamento de dados.

Os modelos utilizados nos Gêmeos Digitais são representações virtuais das relações entre as variáveis de um sistema. Estes variam em grau de formalismo, desde representações gráficas até modelos analíticos. No que se refere à construção desses modelos, os principais tipos residem entre dois opostos: os modelos de caixa-branca, baseados em leis naturais, descrições matemáticas dos fenômenos e equações diferenciais; e os modelos de caixa-preta, baseados diretamente em experimentação, aquisição e análise de dados para inferência do modelo, também conhecida como identificação do sistema [25].

### 2.2.3 Modelagem dos sistemas

A modelagem é, sem dúvidas, o núcleo de um Gêmeo Digital, sendo amplamente reconhecida na literatura como crucial para a sua implementação eficaz [30] [31] [32]. No entanto, como destacado por Fei et al. [18], não há um consenso sobre como construir de maneira genérica um modelo de Gêmeo Digital.

Nesse âmbito, a escolha da estrutura de modelo é um passo crítico que vai além de simplesmente replicar o comportamento do sistema físico. A estrutura do modelo determina, então, a qualidade das previsões e simulações que o Gêmeo Digital pode realizar assim como a interpretabilidade e a adaptabilidade do Gêmeo Digital ao ambiente operacional e às mudanças no sistema físico.

Portanto é necessário considerar um equilíbrio delicado entre a precisão desejada, a capacidade de interpretar e adaptar o modelo, a disponibilidade de dados e os recursos computacionais disponíveis. Consequentemente, a estrutura do modelo atua como o esqueleto sobre o qual o Gêmeo Digital é construído e se desenvolve, fornecendo a base necessária para que esse possa efetivamente simular, prever, controlar e otimizar o sistema físico.

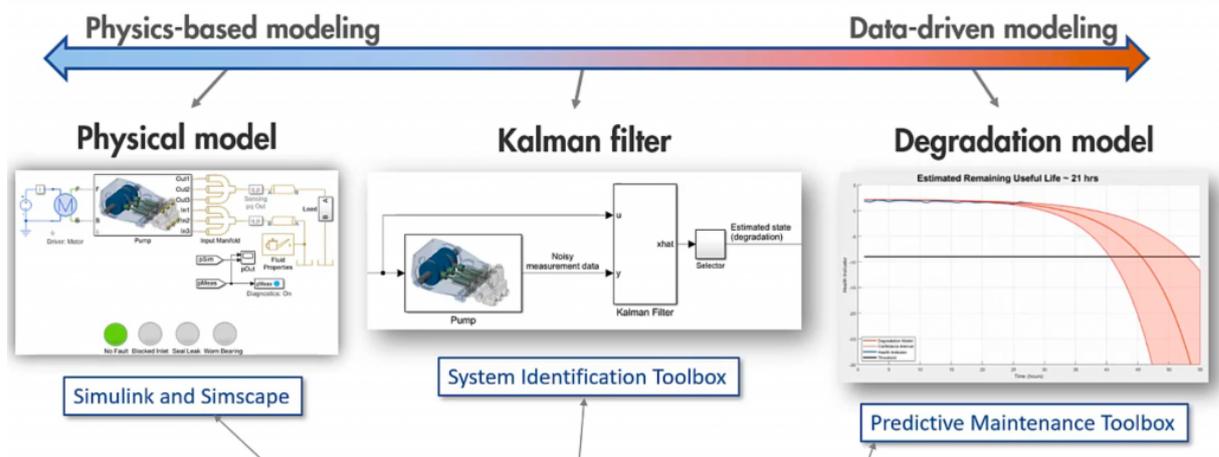
Dentre as diferentes estruturas de modelos que podem ser usadas para representação de um sistema podemos citar os modelos analíticos, funções transferência, representação no espaço de estados, modelos polinomiais, etc. Cada uma adequada para diferentes aplicações, sendo a disponibilidade dos recursos, sejam eles de conhecimento, capacidade de processamento ou dados do sistema, um fator crucial para sua escolha [33]. Tais estruturas podem ser vistas como um *continuum*, variando de modelos altamente interpretáveis e teóricos, como os modelos baseados em equações físicas e matemáticas, a modelos empíricos mais flexíveis, mas menos interpretáveis, como os modelos de caixa-preta baseados em aprendizado de máquina.

Independentemente da estrutura escolhida, é necessário que o modelo seja capaz de capturar de forma adequada o comportamento do sistema de interesse. Ainda mais, é igualmente importante lembrar que cada estrutura de modelo possui suas próprias limitações e requisitos, e a escolha mais adequada dependerá tanto das necessidades quanto das limitações específicas da

tarefa em questão.

A Figura 2 apresenta um espectro da modelagem de Gêmeos Digitais, destacando a diferença entre abordagens baseadas estritamente na física e aquelas centradas em dados. No extremo esquerdo, vemos um modelo totalmente baseado na física, construído a partir de princípios mecânicos e hidráulicos, que representa o comportamento real do sistema de forma detalhada. No centro do espectro, temos o Filtro de Kalman, uma abordagem híbrida que combina informações do mundo real com dados para atualizar e prever o estado de um sistema. Por fim, à direita, encontramos o modelo de degradação, que se baseia principalmente em dados históricos e sensores para prever o tempo de vida útil restante de um equipamento. Esta representação visual reforça a ideia de que a criação de um Gêmeo Digital pode variar em sua abordagem, dependendo das necessidades específicas da aplicação e da disponibilidade de dados e conhecimento físico.

Figura 2 – Espectro de modelagem para Gêmeos Digitais, ilustrando a transição entre abordagens baseadas na física à esquerda e abordagens centradas em dados à direita, com exemplos destacados de modelos físicos, Filtro de Kalman e modelos de degradação.



Fonte: extraído de MATLAB (2019) [34]

Num extremo do espectro, os modelos do tipo caixa-branca, também conhecidos como modelos físicos ou mecanicistas, são abordagens de modelagem baseadas em leis físicas conhecidas e equações matemáticas que representam o sistema de interesse [35]. Esses modelos são projetados com uma compreensão completa dos processos internos do sistema, geralmente expressos por meio de equações diferenciais. Assim, cada parâmetro nesses modelos tem um significado físico explícito. Eles são altamente interpretáveis e se comportam bem fora dos domínios de dados de treinamento.

Modelos de caixa-branca oferecem uma interpretabilidade intrínseca ao revelar a estrutura interna e o funcionamento do sistema. Estes são baseados em conhecimentos prévios, como princípios físicos ou regras definidas por especialistas, o que ajuda a estabelecer relações de causa

e efeito entre as entradas e saídas do sistema [33]. Sendo possível relacionar partes específicas da estrutura do modelo e seus parâmetros aos diferentes componentes do sistema real, cujas características conhecidas e parâmetros podem ser monitorados por sensores ou ainda estimados pelos sistemas de controle.

Quanto aos modelos do tipo caixa-preta, no outro extremo do espectro, são baseados em uma coleção de dados do sistema. Técnicas de aprendizado de máquina e identificação de sistemas são utilizadas para representar o sistema físico, sem a necessidade de um conhecimento aprofundado das leis físicas que regem o sistema. Diferentes técnicas de aprendizado, tais como redes neurais artificiais [36], máquinas de vetor de suporte [37], florestas aleatórias [38], entre outras, são aplicadas para treinar esses modelos com base nos dados históricos do sistema [39].

Modelos caixa-preta possuem várias vantagens intrínsecas. Eles são capazes de capturar complexidades não-lineares e interações entre variáveis que podem ser difíceis de modelar explicitamente com modelos caixa-branca. No que diz respeito à sua construção, eles geralmente são considerados menos complexos, pois não exigem um conhecimento profundo das leis físicas que governam o sistema - apenas dados suficientes para o treinamento. Contudo, a simplicidade ou complexidade do treinamento pode variar dependendo do algoritmo de aprendizado de máquina específico, da qualidade e quantidade de dados disponíveis, dos recursos computacionais disponíveis e do problema específico em mãos [40].

Entretanto, ao contrário dos modelos de caixa-branca, esses sofrem de falta de interpretabilidade. Em outras palavras, geralmente existe uma maior dificuldade de compreensão quanto as relações que esses modelos aprendem entre as entradas e saídas [41]. Além disso, sua precisão é altamente dependente da qualidade e quantidade de dados disponíveis para treinamento. Portanto, os modelos de caixa-preta podem falhar em fazer previsões precisas caso os dados de treinamento sejam limitados ou o sistema esteja sujeito a mudanças significativas ao longo do tempo [42].

Modelos caixa-cinza, entre os dois extremos, combinam os princípios dos modelos caixa-branca e caixa-preta. Eles são desenvolvidos utilizando tanto o conhecimento teórico do sistema como os dados históricos coletados do mesmo [43]. Por integrar conhecimentos a priori e técnicas de aprendizado de máquina, os modelos caixa-cinza conseguem proporcionar um melhor balanço entre interpretabilidade e precisão [33].

Uma importante característica desses modelos é sua capacidade de lidar com a complexidade e incerteza do sistema, sem abrir mão totalmente do entendimento físico. São portanto, adequados para uso em sistemas dinâmicos complexos, onde as leis físicas, ou ainda o conhecimento a priori, apesar de existente, por si só podem não ser suficientes para representar completamente o comportamento do sistema e onde os dados disponíveis podem ser escassos ou ruidosos para uma abordagem caixa-preta [44]. No entanto, a construção de modelos caixa-cinza pode ser mais desafiadora e requerer mais esforço, pois exige tanto o conhecimento profundo do sistema quanto a capacidade de desenvolver e ajustar algoritmos de aprendizado de máquina.

Finalmente, é igualmente fundamental explorar as diferentes representações e estruturas matemáticas que esses modelos podem adotar. Em detalhe, se apresenta as representações matemáticas específicas, funções de transferência, modelos no espaço de estados e modelos polinomiais. Além disso, é discutida a crescente importância da modelagem baseada em dados e abordagens adaptativas na era digital atual.

### **2.2.3.1 Modelos matemáticos**

Os modelos matemáticos, com suas estruturas analíticas, representam a essência de numerosas técnicas de modelagem de sistemas. Estes modelos são formulados considerando as leis físicas e teorias matemáticas que orientam o comportamento do sistema em estudo. Exemplos notáveis incluem a lei de Newton para sistemas mecânicos, as leis de Kirchhoff para circuitos elétricos e as equações de Navier-Stokes para fluidos [4][45]. Esses modelos oferecem uma representação detalhada dos componentes principais do sistema e de suas interações, que são expressas por meio de funções matemáticas ou equações diferenciais.

Apesar da sua importância, a modelagem matemática também apresenta certas limitações. Em primeiro lugar, a elaboração desses modelos demanda um entendimento aprofundado do sistema e das leis físicas que o regulam, o que pode ser um desafio considerável, principalmente quando se trata de sistemas de grande escala e complexos. Ademais, a resolução e a análise de modelos matemáticos, particularmente aqueles baseados em equações diferenciais, podem se mostrar difíceis, especialmente no caso de equações não lineares ou de alta ordem. Por último, apesar de sua precisão, os modelos matemáticos podem não conseguir capturar com exatidão todas as nuances do sistema, sobretudo quando este é impactado por incertezas, ruídos e perturbações [46].

### **2.2.3.2 Funções de Transferência e Representação no Espaço de Estados**

Funções de Transferência e Representações no Espaço de Estados são métodos que apresentam significativa adesão na modelagem de sistemas lineares e, frequentemente, utilizados na análise e controle de sistemas dinâmicos [47][48]. Ambas as representações simplificam a análise de sistemas complexos, tornando-os mais acessíveis e compreensíveis. Estas são relativamente fáceis de se construir uma vez que se conheça as características básicas do sistema como a resposta a um degrau ou a resposta em frequência.

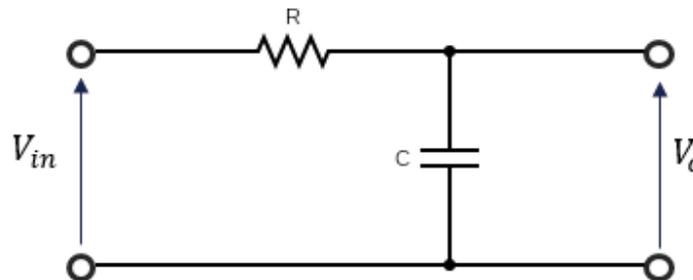
Funções de transferência, comumente usadas em engenharia de controle, descrevem a relação dinâmica entre a entrada e a saída de um sistema. Essas funções são expressas no domínio da frequência, e podem ser obtidas pela transformada de Laplace das equações diferenciais que regem o sistema. Um aspecto notável dos modelos de função de transferência é que eles representam o comportamento do sistema sem descrever explicitamente os seus estados internos [47]. Na prática, a função de transferência de um sistema também pode ser determinada a partir de dados experimentais ou através da dedução direta das leis físicas do sistema. Por exemplo,

em um circuito elétrico de resistor (R), indutor (L) e capacitor (C), a função de transferência pode ser deduzida diretamente da lei de Ohm e das leis de Kirchhoff [49].

Por outro lado, a representação no espaço de estados é um modelo que descreve um sistema utilizando um conjunto de equações diferenciais de primeira ordem. Esta representação é bastante útil para sistemas com múltiplas variáveis, onde várias entradas e saídas estão presentes, permitindo uma análise mais rica do sistema [48]. A representação no espaço de estados utiliza matrizes para descrever a relação entre as entradas e saídas do sistema e as variáveis de estado, que representam os estados e condições internas. Além disso, é possível uma descrição mais completa do sistema, incluindo aspectos como estabilidade, controlabilidade e observabilidade, que são cruciais para a análise e *design* de controladores [48].

Na Figura 3, ilustramos um circuito RC (Resistivo e Capacitivo) em série, um exemplo clássico em estudos de sistemas dinâmicos. Este sistema exemplifica distintas maneiras de modelar sistemas dinâmicos.  $V_{in}$  representa a tensão de entrada do sistema e  $V_c$  a tensão de saída do capacitor.

Figura 3 – Representação esquemática de um circuito RC em série. Consistindo de um resistor R e um capacitor C.



Fonte: elaborado pelo autor (2023)

A equação 2.1:

$$FT(s) = \frac{V_c(s)}{V_{in}(s)} = \frac{1}{RCs + 1} \quad (2.1)$$

apresenta a Função de Transferência do sistema, que fornece uma descrição direta da relação dinâmica entre a entrada e a saída no domínio da frequência. Esta representação é eficaz ao se analisar a resposta do sistema a diferentes frequências de entrada e é comumente utilizada em design de controladores.

Em contraste, o conjunto de equações a seguir:

$$\begin{aligned} \dot{x}(t) &= -\frac{1}{RC}x(t) + \frac{1}{RC}u(t) \\ y(t) &= x(t) \end{aligned} \quad (2.2)$$

mostra a Representação no Espaço de Estados, que descreve o sistema em termos de suas variáveis internas ou estados. Esta forma é particularmente útil para sistemas com múltiplas

entradas e saídas e oferece insights sobre o comportamento interno do sistema, onde  $x$  representa as variáveis de estado que descrevem as condições internas do sistema a qualquer momento.

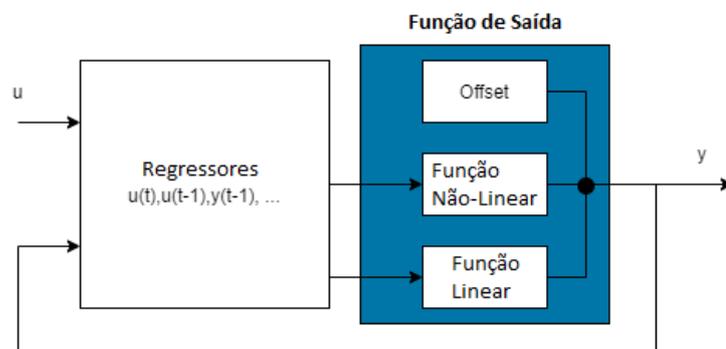
Enquanto a Função de Transferência enfatiza a relação entre a entrada e a saída, a Representação no Espaço de Estados concentra-se nas dinâmicas internas do sistema e sua evolução ao longo do tempo. Apesar de suas vantagens, tanto as funções de transferência quanto a representação no espaço de estados têm suas limitações. Eles são tipicamente aplicados a sistemas lineares e invariantes no tempo, e podem se tornar complexos para sistemas não lineares ou variantes no tempo. Além disso, a obtenção desses modelos geralmente requer conhecimento profundo do sistema ou extensos dados experimentais.

### 2.2.3.3 Modelos polinomiais

Outra estrutura comum para representação dos sistemas são os modelos polinomiais, que são muitas vezes enquadrados em uma perspectiva de caixa-cinza. Eles são especialmente úteis para lidar com sistemas não lineares e podem ser ajustados para incluir uma variedade de entradas e saídas do sistema.

Modelos polinomiais incorporam em sua estrutura componentes não lineares e são largamente utilizados para modelagem de sistemas com componentes não lineares. Entre as estruturas comuns estão os modelos autorregressivos lineares e não lineares com entradas exógenas (ARX, NARX), autorregressivos de média móvel com entradas exógenas (ARMAX, ARIMAX) e outros [50]. Estes baseiam-se em entidades chamadas regressores, variáveis do processo, além dos operadores de tempo. A forma básica de um modelo polinomial é representada na Figura 4, podendo os seus diferentes componentes estarem ou não ativos ao mesmo tempo. Os regressores representados são funções das entradas e saídas e de seus valores passados (e.g.  $u(t)$ ,  $y(t-1)$ ) como também componentes não lineares (e.g.  $u(t)^2$ ,  $y(t-2)^3$ ).

Figura 4 – Estrutura base de modelo polinomial



Fonte: Adaptada de Mathworks (2023) [51]

### 2.2.3.3.1 Modelagem Baseada em Dados e Abordagens Adaptativas

Do outro lado do espectro, temos as estruturas de modelos de caixa-preta. Elas são baseadas em dados do sistema e em técnicas de aprendizado de máquina, com pouca ou nenhuma suposição feita sobre a natureza física ou matemática do sistema subjacente. Embora menos interpretáveis do que os modelos de caixa-branca ou cinza, esses modelos são extremamente flexíveis e podem se ajustar a uma ampla variedade de comportamentos de sistema.

A aprendizagem de máquina, especialmente o uso de redes neurais, árvores de regressão e outros métodos, tem se mostrado cada vez mais promissora na modelagem de sistemas [52][36]. Esses métodos são capazes de representar sistemas complexos e não lineares, capturando interações não lineares entre variáveis que podem ser desafiadoras para abordagens de modelagem tradicionais. No entanto, suas limitações não podem ser ignoradas.

Notavelmente, uma das principais restrições é a falta de transparência interpretativa [41]. Apesar desses métodos poderem aprender a partir de dados complexos e não-lineares, os modelos resultantes, por vezes, podem se assemelhar a ‘caixas-pretas’. As relações específicas aprendidas entre as entradas e saídas do sistema podem se tornar opacas, dificultando a compreensão direta do funcionamento do modelo. Esta falta de clareza pode se mostrar problemática, particularmente em sistemas de alto risco, onde erros podem trazer consequências graves [53].

Outro aspecto a considerar é que a modelagem baseada em dados não possui adaptabilidade intrínseca, ou seja, seus parâmetros não se ajustam automaticamente às mudanças no sistema [36]. Se o sistema real em questão alterar significativamente, seja por falhas, desgaste ou mudança nas condições operacionais, o modelo pode não ser capaz de capturar tais mudanças, diminuindo a precisão de suas previsões.

Técnicas mais avançadas, como a identificação esparsa de sistemas dinâmicos não lineares, conhecida também como *Sparse Identification of Nonlinear Dynamics* (SINDy) [54], tem ganhado notoriedade pela utilização de aprendizado de máquina e extensas bibliotecas de regressores na construção de seus modelos. Avanços significativos foram feitos na área como a aplicação de tais modelos em *Model Predictive Control* (MPC) [55] e a descoberta de equações governantes de sistemas não triviais [54]. Apesar de seus avanços, esta técnica ainda requer um uso considerável de recursos computacionais.

Os modelos de discrepância, também conhecidos como Modelos de Erros, são uma estratégia emergente na modelagem. Essa abordagem busca representar as diferenças entre o comportamento do sistema real e o comportamento previsto por um modelo matemático simplificado. Os modelos de discrepância permitem capturar e quantificar incertezas, erros de modelagem e outros efeitos que podem ser desafiadores de serem explicitamente representados nos modelos matemáticos convencionais [56]. Essa abordagem é especialmente útil para lidar com a complexidade e as limitações dos modelos matemáticos tradicionais, proporcionando uma compreensão mais completa e realista do sistema estudado.

Apesar da notoriedade recente desses últimos, a interpretação de seus elementos constitutivos - regressores, operadores de tempo e parâmetros do modelo - pode ser exclusivamente matemática [54]. Ou seja, mesmo que esses elementos possam ter uma interpretação matemática clara, muitas vezes eles não possuem um significado físico direto. Isto implica que não existe uma correspondência direta ou intuitiva com características observáveis ou mensuráveis do sistema físico que está sendo modelado, deixando mais uma vez a interpretabilidade de lado.

Essas restrições ressaltam a necessidade contínua de pesquisa e desenvolvimento no campo da modelagem de sistemas. O desafio reside em encontrar abordagens que harmonizem a flexibilidade e poder de generalização dos métodos de aprendizado de máquina com a interpretabilidade e adaptabilidade dos modelos tradicionais.

## 2.2.4 Identificação de Sistemas

A identificação do sistema é um processo fundamental no desenvolvimento de modelos que descrevem sistemas dinâmicos. Ljung descreve esse processo como "a arte e a ciência de construir modelos matemáticos de sistemas dinâmicos a partir de observações"[25]. A identificação do sistema envolve duas partes principais: primeiro, a escolha de uma estrutura de modelo adequada, segundo, a estimação de parâmetros dentro dessa estrutura. A estrutura do modelo, discutida previamente, se refere ao tipo de equações, funções e representações que descrevem o sistema, enquanto os parâmetros são os coeficientes ou constantes nas equações ou funções que determinam o comportamento específico do sistema. Segundo Ljung, o processo de identificação do sistema é orientado pelos dados e envolve uma combinação de conhecimento do domínio (por exemplo, leis físicas ou propriedades de engenharia do sistema), e a análise dos dados coletados do sistema [25]. A qualidade e a quantidade dos dados são cruciais para a identificação do sistema. Medidas inadequadas ou a falta de dados podem levar a modelos imprecisos ou inúteis.

A identificação do sistema é considerada um problema de otimização. Os parâmetros do modelo são ajustados de modo a minimizar a diferença entre as saídas do modelo e os dados observados. Esse problema se torna cada vez mais complexo dependendo do detalhamento do modelo e da disposição dos dados.

Além disso, a identificação do sistema deve levar em conta a questão do *overfitting* (sobreajuste) e do *underfitting* (subajuste). *Overfitting* ocorre quando o modelo é excessivamente complexo e "memoriza" os dados, em vez de aprender as verdadeiras relações subjacentes. *Underfitting* ocorre quando o modelo é muito simples e não consegue capturar a dinâmica complexa do sistema. Ljung discute várias técnicas para evitar esses problemas, como a validação cruzada e o uso de critérios de informação para selecionar a complexidade do modelo [25]

### 2.2.4.1 Identificação *Online* e *Offline*

Duas categorias gerais de classificação para a identificação de sistemas são estabelecidas: identificação *offline* e identificação *online*.

Na identificação *offline* (ou em lote), todas as medições necessárias são coletadas antecipadamente e o modelo é construído posteriormente com base nos dados disponíveis. Esta abordagem permite que os desenvolvedores e pesquisadores dediquem tempo para múltiplas análises profundas e iterativas dos dados e do modelo, mas tem a desvantagem de que o modelo não pode ser atualizado durante a operação do sistema [25]. Os parâmetros determinados por essas análises permanecem constantes durante o uso do modelo. Eles são tipicamente baseados em uma grande quantidade de dados e assumem que o sistema não mudará significativamente no futuro.

Contrastando com isso, a identificação *online* (ou adaptativa) busca atualizar continuamente o modelo à medida que novas medições são realizadas. Isso é especialmente útil em situações em que as características do sistema podem mudar com o tempo, seja devido ao desgaste, flutuações ambientais, ou outros fatores como nos ambientes industriais. Ao incorporar novas informações conforme se tornam disponíveis, permitem que o modelo se atualize para refletir as novas condições do sistema. Isso pode ser especialmente valioso em sistemas onde a mudança é esperada ou inevitável. Neste caso, um modelo que permanece fixo poderia tornar-se rapidamente desatualizado, enquanto um modelo adaptativo pode continuar a fornecer estimativas precisas [25].

Ambas as técnicas de identificação possuem vantagens e desvantagens, e a escolha entre elas depende das características específicas do sistema e das restrições operacionais da máquina. A identificação *offline* permite a utilização de algoritmos de otimização mais complexos, uma vez que não há restrições de tempo real. No entanto, ela não é adequada para modelar sistemas com dinâmicas que mudam muito rapidamente. Por outro lado, a identificação *online* pode se adaptar às mudanças do sistema, mas os algoritmos usados devem ser computacionalmente eficientes para operar em tempo real.

## 2.3 Otimização

A identificação de sistemas, tal como discutida na seção anterior, é essencialmente um problema de otimização. Dada uma estrutura de modelo que represente o comportamento observado, precisamos encontrar os parâmetros que minimizam a diferença entre as previsões do modelo e os dados observados.

Esta seção explora mais profundamente os conceitos e técnicas de otimização, com um foco particular no seu papel na identificação de sistemas. Primeiro, são apresentados alguns conceitos básicos de otimização e como se aplicam à identificação de sistemas. Em seguida,

uma comparação é feita entre diferentes métodos de otimização, destacando suas vantagens, desvantagens e cenários de aplicação ideais.

### 2.3.1 Conceitos Básicos de Otimização

A otimização é o processo sistemático de selecionar a melhor solução em um conjunto de alternativas possíveis. Este conceito é fundamentado na formulação de um modelo matemático que descreve o problema, definindo uma função objetivo que quantifica a medida de otimalidade. O objetivo é determinar os valores das variáveis de decisão que otimizam a função objetivo, ao mesmo tempo que satisfazem um conjunto de restrições [57].

Técnicas de programação matemática, como programação linear, programação inteira e programação não linear, são utilizadas para resolver problemas de otimização, explorando sistematicamente o espaço de solução e melhorando iterativamente o valor da função objetivo [58]. Nos mais diversos domínios, incluindo pesquisa operacional, engenharia, economia e logística, a otimização desempenha um papel vital, permitindo a alocação eficiente de recursos, minimização de custos e maximização de desempenho [59].

É possível classificar a otimização entre otimização contínua e discreta, em relação aos valores que as variáveis de decisão podem assumir, se qualquer valor dentro de um intervalo contínuo ou se são restritas a um conjunto finito ou infinito contável de possíveis valores [57]. A otimização também pode ser classificada como determinística ou estocástica, dependendo de se a função objetivo e as restrições são conhecidas com certeza ou se estão sujeitas a incertezas [58].

No contexto da identificação de sistemas, a otimização é utilizada para ajustar os parâmetros dos modelos a fim de minimizar a discrepância entre as saídas do sistema real e as previsões do modelo. Este processo é geralmente proposto como um problema de minimização, em que a função objetivo é a soma dos quadrados dos resíduos, diferença entre real e previsto pelo modelo, embora outras métricas também possam ser usadas dependendo da natureza do problema e dos objetivos específicos da modelagem [25].

Diferentes técnicas podem ser usadas para resolver os problemas de otimização, que variam amplamente em termos de complexidade, eficiência e aplicabilidade a diferentes tipos de problemas. Alguns dos métodos de otimização mais comuns usados na identificação de sistemas são:

- **Método dos Mínimos Quadrados:** O Método dos Mínimos Quadrados, demanda baixo esforço computacional e é de baixa complexidade. Isso significa que ele pode ser aplicado de maneira rápida e simples, tornando-se particularmente útil para problemas lineares. Este método, amplamente explorado em trabalhos como [60], busca minimizar a soma dos quadrados dos resíduos, ou seja, a diferença entre os valores reais e previstos por um modelo.

- **Otimização por Gradiente:** É um método de médio esforço computacional e de média complexidade. Trata-se de um método iterativo que utiliza a derivada da função objetivo para encontrar o mínimo local ou global [61]. Este método é especialmente útil quando se é possível diferenciar a função objetivo e quando o número de variáveis do problema é grande. No contexto de Gêmeos Digitais, este método pode ser usado para ajustar os parâmetros do modelo de forma eficiente, desde que a função objetivo seja devidamente diferenciável.
- **Métodos de Newton e Quasi-Newton:** Apresentam um alto esforço computacional e alta complexidade. Estes métodos iterativos usam a derivada de segunda ordem (ou uma aproximação) para encontrar o mínimo de uma função [62]. Tais métodos são mais eficientes que os métodos de gradiente, mas também são mais complexos e requerem que a função objetivo seja duas vezes diferenciável. No entanto, quando essas condições são atendidas, estes métodos podem oferecer uma convergência mais rápida e precisa, o que pode ser particularmente útil em problemas de identificação de sistemas onde a precisão do modelo é de extrema importância.
- **Meta-heurísticas:** Estas técnicas demandam um moderado esforço computacional, mas possuem baixa complexidade e podem ser aplicadas a uma ampla gama de problemas de otimização complexos. As Meta-heurísticas são estratégias de alto nível que guiam o processo de busca para encontrar soluções ótimas ou quase ótimas [63]. Estes métodos são especialmente úteis quando se lida com problemas de otimização não-lineares ou de grande escala, os quais são comuns ao desenvolver Gêmeos Digitais para sistemas industriais complexos.

Ao se escolher o método de otimização mais adequado para a identificação de sistemas e para a criação de Gêmeos Digitais, deve-se levar em conta as características específicas do problema em questão, bem como as capacidades computacionais disponíveis. A escolha do método de otimização adequado pode significar a diferença entre um modelo altamente preciso e eficiente e um que não atenda às necessidades do problema.

A Tabela 1 traz, como uma visão geral, uma breve comparação entre diferentes métodos de otimização citados acima. As categorias são relativas, e o desempenho real pode depender de vários fatores, como características do problema e especificidades da implementação. Também é importante notar que esta é uma comparação simplificada e pode não capturar todas as nuances de cada método.

As meta-heurísticas apresentam algumas vantagens relevantes para a identificação de sistemas e a criação de Gêmeos Digitais. Em primeiro lugar, elas não exigem o conhecimento exato do gradiente da função objetivo, o que as torna adequadas para lidar com problemas complexos, não-lineares e até mesmo com funções objetivo que são apenas parcialmente conhecidas ou ruidosas. Além disso, as meta-heurísticas são projetadas com mecanismos que equilibram

Tabela 1 – Comparação entre diferentes métodos de otimização.

<b>Método</b>	<b>Esforço Computacional</b>	<b>Complexidade</b>	<b>Aplicabilidade</b>
Mínimos Quadrados	Baixo	Baixa	Ampla para problemas lineares
Otimização por Gradiente	Médio	Média	Ampla para funções contínuas diferenciáveis
Métodos de Newton	Alto	Alta	Ampla para funções duas vezes diferenciáveis
Quasi-Newton	Médio	Média	Ampla para funções contínuas diferenciáveis
Meta-heurísticas (ex. PSO, GA)	Médio	Baixa	Ampla para problemas de otimização complexos

Fonte: elaborado pelo autor (2023)

entre a exploração de novas áreas no espaço de busca e a exploração de soluções conhecidas, permitindo-lhes realizar uma busca global robusta e evitar ficar presas em ótimos locais. Em segundo lugar, devido à sua natureza de busca global, estas técnicas têm uma capacidade robusta para evitar mínimos locais e encontrar soluções próximas ao ótimo global [63]. Por fim, estas técnicas são facilmente paralelizáveis, o que pode permitir um aproveitamento eficiente dos recursos computacionais disponíveis, especialmente em problemas de grande escala.

## 2.4 Inteligência de Enxames

Esta seção introduz a Inteligência de Enxames, uma subcategoria de meta-heurísticas inspirada na inteligência coletiva de grupos de animais. Esta seção é dividida em quatro subseções principais para explorar em profundidade os conceitos, algoritmos, aplicações e descobertas relacionadas com a inteligência de enxames.

Na primeira subseção, está discutida a origem e a inspiração por trás da inteligência de enxames. A compreensão de como os animais, como pássaros e insetos, trabalham coletivamente para alcançar um objetivo comum está explorada. A análise desses comportamentos na natureza inspirou o desenvolvimento de técnicas de otimização baseadas na inteligência de enxames, proporcionando um novo olhar sobre a resolução de problemas complexos.

Em seguida, são apresentados os principais algoritmos de inteligência de enxames, incluindo a Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO). É feita uma exploração de suas características distintas, assim como uma discussão sobre seus respectivos méritos e limitações.

Então, é demonstrada a aplicação do PSO para a estimação de parâmetros na identificação de sistemas. E é dada atenção especial à maneira como a PSO lida com o problema da otimização

e como esta técnica pode ser adaptada para satisfazer as necessidades específicas da modelagem de sistemas.

Finalmente, é discutida a capacidade da inteligência de enxames de descobrir novos componentes ou parâmetros em um sistema, mesmo quando estes não foram explicitamente definidos. Isto demonstra a versatilidade destas técnicas, não apenas para otimização, mas também para o descobrimento e a identificação de sistemas.

Com esta seção, espera-se proporcionar uma melhor compreensão das técnicas de inteligência de enxames e sua aplicação para a identificação de sistemas e a criação de Gêmeos Digitais.

### **2.4.1 Conceitos**

A inteligência de enxames é um paradigma emergente na esfera da inteligência artificial, enquadrado na abrangente disciplina da computação natural. Esta abordagem é inspirada pela coletividade e pela capacidade de autogestão exibidas por vários sistemas sociais presentes na natureza, como colônias de insetos, bandos de pássaros e cardumes de peixes [64]. Em cada um desses sistemas, os indivíduos aderem a regras básicas e, por meio de interações locais e/ou globais, a sociedade como um todo executa tarefas complexas com eficiência, sem necessitar de uma estrutura hierárquica de controle ou de um líder centralizado [65].

A aplicação da inteligência de enxames na resolução de problemas de otimização possui características interessantes. Sua natureza descentralizada e distribuída confere robustez ao sistema, que mantém sua eficácia mesmo diante de falhas individuais [66]. A inteligência de enxames executa a busca de soluções de maneira paralela, e com ampla exploração do espaço de soluções, seja em largura ou profundidade, o que favorece o escape de ótimos locais e a obtenção de soluções de qualidade elevada.

Para a identificação de sistemas, onde soluções robustas e diversificadas são procuradas, a inteligência de enxames satisfaz esse critério e se mostra adequada em diversos casos. Esta propriedade amplifica o potencial de descoberta de modelos que capturam com eficiência a dinâmica do sistema [67].

Além disso, a inteligência de enxames possui adaptabilidade inerente, permitindo que os modelos ajustem suas respostas em tempo real conforme as mudanças no ambiente ou nas condições do problema [67]. Tal flexibilidade destaca o valor da inteligência de enxames para aplicações de gêmeos digitais, onde é particularmente necessária, e sistemas de decisão em tempo real [66].

### **2.4.2 Principais Famílias de Algoritmos**

Diversas famílias de algoritmos de inteligência de enxames foram desenvolvidas, cada uma com suas características e aplicações distintas. Alguns dos mais proeminentes incluem:

**Otimização por Colônia de Formigas (ACO):** Algoritmos ACO são inspirados no comportamento de busca por comida das formigas. As formigas depositam feromônios no caminho de volta ao ninho, deixando um rastro que outras formigas podem seguir para encontrar comida. Este mecanismo foi aplicado com sucesso na resolução de problemas de otimização, particularmente em problemas de roteamento e programação [68]. O conhecimento, nesse caso, é armazenado não nos indivíduos e sim no ambiente.

**Otimização por Enxame de Partículas (PSO):** O PSO é uma técnica inspirada no comportamento de enxames de pássaros ou cardumes de peixes. Cada partícula (indivíduo) na população representa uma solução candidata e tem associada a si uma posição e uma velocidade no espaço de busca. A posição da partícula indica uma solução específica para o problema, enquanto a velocidade determina a direção e a magnitude da mudança da posição da partícula na próxima iteração. As partículas se movem pelo espaço de busca com base em sua experiência pessoal (melhor posição já encontrada) e na experiência dos vizinhos (melhor posição encontrada pelo enxame). A combinação dessas informações determina a nova posição da partícula, tentando encontrar soluções mais otimizadas. O PSO tem sido aplicado com sucesso em uma ampla gama de problemas contínuos e discretos [69].

**Colônia de Abelhas Artificiais (ABC):** O ABC é um algoritmo que simula o comportamento de uma colônia de abelhas inspirado na busca de néctar das abelhas e sua forma de transmissão de conhecimento para outras abelhas dentro da colmeia. Utilizando os princípios de abelhas empregadas, observadoras e exploradoras, o ABC tem sido efetivo em resolver problemas de otimização numérica e problemas de otimização complexos, especialmente os que envolvem busca global [70].

**Pesquisa de Cardume de Peixes (FSS):** O FSS é um algoritmo inspirado no comportamento social de cardumes de peixes. Esta abordagem foi desenvolvida por Bastos e Lima-Neto e baseia-se em comportamentos de peixes como o agrupamento e a busca por comida. Cada peixe no cardume representa uma solução potencial para o problema e, através de movimentos individuais e coletivos, o cardume de peixes converge para a solução ótima. O FSS tem sido aplicado com sucesso a uma variedade de problemas de otimização, oferecendo um equilíbrio eficaz entre a exploração global e a exploração local do espaço de busca [71].

Cada família de algoritmos tem suas próprias forças e aplicações, o que torna a inteligência de enxames uma área versátil e poderosa para a resolução de problemas de otimização complexos. No entanto, cabe salientar que a escolha do algoritmo adequado deve ser baseada na natureza do problema, a fim de maximizar a eficácia da solução proposta.

### 2.4.3 Estimação de Parâmetros usando PSO

A Estimação de Parâmetros é uma etapa fundamental em muitos problemas de modelagem e controle de sistemas. Uma abordagem eficaz para esse processo é a Otimização por

Enxame de Partículas (*Particle Swarm Optimization* - PSO). Nessa técnica, cada partícula (ou agente) explora o espaço de busca, ajustando sua posição com base no conhecimento pessoal e no melhor desempenho do enxame. O PSO equilibra a exploração do espaço de busca (diversidade) e a exploração em torno das melhores soluções encontradas (intensidade), o que contribui para o sucesso dessa abordagem [69].

O PSO tornou-se um método popular para a estimação de parâmetros devido à sua simplicidade e eficiência. Ele tem sido aplicado com sucesso em diversos domínios, como energia renovável, robótica e engenharia química. Estudos anteriores demonstraram os benefícios da PSO na estimação de parâmetros de sistemas dinâmicos lineares e não lineares [72]. Por exemplo, Schwaab et al. (2008) utilizaram o PSO para estimar os parâmetros de modelos dinâmicos e mostraram que essa abordagem pode fornecer regiões de confiança de probabilidade para os parâmetros do modelo [72].

Na área da robótica, o PSO tem sido empregado com sucesso para estimar os parâmetros de modelos de exoesqueletos robóticos [73]. Em um estudo realizado por Zha et al. (2019), a PSO foi utilizada para essa finalidade e os resultados mostraram que abordagens híbridas de PSO podem melhorar significativamente a precisão das previsões do modelo em comparação com outros métodos de estimação [73].

Além disso, o PSO tem sido aplicado em domínios como sistemas de energia, controle de processos e robótica, com resultados promissores. Por exemplo, Polsena et al. (2021) propuseram uma abordagem baseada em PSO para estimar os parâmetros de um modelo de motor de corrente contínua (Motor DC) em tempo real, alcançando estimativas precisas dos parâmetros [74].

Portanto, considerando a eficiência, simplicidade e os resultados positivos em diversos domínios de aplicação, a PSO se mostra uma escolha viável e promissora para a estimação de parâmetros em sistemas dinâmicos, incluindo aqueles abordados nesta dissertação.

#### **2.4.4 Descoberta de Componentes Desconhecidos**

Em certas aplicações industriais, a descoberta e identificação de componentes e interações de sistemas desconhecidos são de extrema importância. Embora esse seja um desafio complexo, várias técnicas têm sido utilizadas com sucesso para abordar essa questão no contexto de sistemas dinâmicos.

Uma das abordagens relevantes é a metodologia proposta por Brunton et al. (2016), conhecida como SINDy (*Sparse Identification of Nonlinear Dynamical Systems*). Essa metodologia permite descobrir e caracterizar a dinâmica de sistemas não lineares a partir de dados disponíveis. No entanto, é importante observar que a SINDy requer uma quantidade significativa de dados de alta qualidade para identificar com precisão a dinâmica do sistema [54]. Essa abordagem tem se mostrado poderosa para identificar as relações não lineares subjacentes em sistemas complexos.

A metodologia SINDy baseia-se no princípio de que a dinâmica de um sistema não linear

pode ser representada por um conjunto esparsos de funções não lineares. A abordagem utiliza uma combinação de técnicas de aprendizado de máquina e otimização para descobrir as relações não lineares entre as variáveis do sistema. A partir dos dados disponíveis, SINDy constrói uma matriz de características que contém polinômios das variáveis de entrada, bem como suas interações não lineares. Em seguida, utiliza técnicas de regressão esparsa para identificar as combinações de características que melhor explicam a dinâmica do sistema. Através do processo de seleção de recursos, a metodologia SINDy é capaz de identificar automaticamente as equações que descrevem a evolução temporal das variáveis do sistema. Essa abordagem tem se mostrado eficaz para a descoberta de relações não lineares e simplificação de modelos em sistemas complexos, proporcionando uma maior compreensão da dinâmica subjacente.

Dessa forma, a metodologia SINDy oferece uma abordagem poderosa para a descoberta de componentes e caracterização de sistemas não lineares, permitindo extrair informações valiosas a partir de conjuntos de dados disponíveis. No entanto, é importante ressaltar que a precisão da identificação da dinâmica do sistema depende da disponibilidade de dados de alta qualidade e de uma boa escolha das características relevantes.

Outra abordagem interessante é o uso do algoritmo PSO para identificar componentes desconhecidos em sistemas dinâmicos. Deng (2009) explorou o potencial do PSO para identificar componentes desconhecidos em uma rede de reações químicas [27]. O autor demonstrou que essa abordagem poderia identificar adequadamente os componentes matemáticos do sistema com base em uma série de meta-modelos simples.

Uma das principais vantagens do PSO é a sua capacidade de explorar o espaço de busca de forma mais abrangente e eficiente. O algoritmo do PSO permite que as partículas do enxame se movam em direção às melhores soluções identificadas, o que facilita a descoberta de componentes desconhecidos em um espaço dimensional mais amplo. Além disso, o PSO é menos dependente da quantidade e qualidade dos dados de entrada em comparação ao SINDy. Enquanto o SINDy requer uma quantidade significativa de dados de alta qualidade para identificar com precisão a dinâmica do sistema, o PSO pode lidar melhor com conjuntos de dados escassos ou ruidosos, tornando-o mais flexível e robusto na descoberta de componentes desconhecidos.

Essas abordagens representam um avanço significativo na descoberta de componentes desconhecidos em sistemas dinâmicos. Além disso, pesquisas recentes, como o trabalho de Kaiser et al. (2018) [55], têm explorado ainda mais a aplicação da SINDy e técnicas similares em cenários de dados limitados. Essas técnicas promissoras abrem caminho para a descoberta de componentes e interações em sistemas dinâmicos complexos, mesmo quando os dados são limitados ou ruidosos.

Portanto, a descoberta de componentes desconhecidos em sistemas dinâmicos é uma área de pesquisa em constante evolução, e abordagens como a SINDy e o PSO mostram um grande potencial para identificar e caracterizar a dinâmica desses sistemas, mesmo quando os componentes e interações não são previamente conhecidos.

## Capítulo 3

# Metodologia Proposta

Este Capítulo apresenta a metodologia proposta para a criação de um Gêmeo Digital, levando em consideração três pontos principais. Primeiro, a capacidade de representação do sistema físico, que é essencial para uma simulação de alta fidelidade. É importante ressaltar que esta "alta fidelidade" busca aproximar-se ao máximo da realidade, não implicando necessariamente em uma precisão de 100%, mas sim em uma representação que seja suficiente para fornecer previsões acuradas e análises consistentes sobre o comportamento do sistema. Segundo, a adaptação, que permite ao Gêmeo Digital refletir as mudanças dinâmicas e condições imprevistas no sistema físico. Terceiro, a interpretação, que possibilita aos usuários entenderem o modelo, suas previsões e possíveis falhas, facilitando a tomada de decisões informadas.

A solução apresentada é um modelo híbrido que faz uso de princípios físicos, dados adquiridos em tempo real, Otimização por Enxame de Partículas (PSO) e por fim, conceitos da engenharia e operação de máquinas industriais.

Na introdução, a metodologia é abordada num contexto geral, explicando como ela é composta e os principais fluxos de interações. O produto final é então discutido neste contexto. Enquanto as demais seções explicam as etapas da metodologia detalhadamente. Desde a modelagem utilizada, as questões de adaptabilidade e de interpretabilidade.

Os principais pontos que são abordados incluem a modelagem do sistema físico e a criação de um Gêmeo Digital, a realização de uma estimativa de parâmetros online usando PSO, e a identificação de componentes desconhecidos do sistema também usando PSO.

O objetivo deste Capítulo é fornecer uma compreensão clara de como a metodologia proposta pode ser usada para criar um Gêmeo Digital interpretável, que pode ser compreendido e analisado por operadores, e que seja capaz de se adaptar dinamicamente a mudanças e condições desconhecidas no sistema que está sendo modelado.

Esta abordagem permite o desenvolvimento de uma máquina consciente de seus estados e condições de operação além de prover essas informações externamente para operadores e tomadores de decisões.

## 3.1 Introdução

A metodologia proposta tem como objetivo construir um Gêmeo Digital interpretável, capaz de incorporar um mecanismo de estimação de parâmetros conhecidos e a descoberta de componentes desconhecidos do sistema em tempo real. Isso é possível utilizando os benefícios dos gêmeos digitais em conjunto com uma abordagem de Otimização por Enxame de Partículas (PSO).

A metodologia envolve três etapas principais:

1. Modelagem do sistema físico e criação de um gêmeo digital básico (DT, do inglês *Digital Twin*): nesta fase, um modelo básico do sistema é construído com base na física e nos dados conhecidos do sistema. A construção deste modelo inicial proporciona uma base sólida para a interpretação, pois reflete a compreensão atual do sistema.
2. Execução da estimação de parâmetros online usando PSO: esta etapa envolve a otimização dos parâmetros do modelo usando dados em tempo real e o algoritmo PSO. Tais parâmetros têm significados concretos e podem ser diretamente associados a comportamentos ou características específicas do sistema físico.
3. Identificação de componentes desconhecidos do sistema também usando PSO: aqui, o algoritmo PSO é usado para identificar e incorporar ao modelo componentes não contemplados inicialmente. Ao identificar esses componentes, o modelo se torna mais completo e, conseqüentemente, mais fácil de ser interpretado em relação ao sistema real.

Os ‘componentes desconhecidos’, como discutido anteriormente, seriam as partes ou características do sistema que não foram previamente consideradas ou que não estão explicitamente modeladas. Estes podem incluir falhas, desgaste ou mudanças nas condições operacionais que não foram previstas inicialmente, ou quando da modelagem inicial do sistema. A identificação desses componentes pode melhorar a precisão das previsões do Gêmeo Digital e a sua capacidade de se adaptar a novas condições.

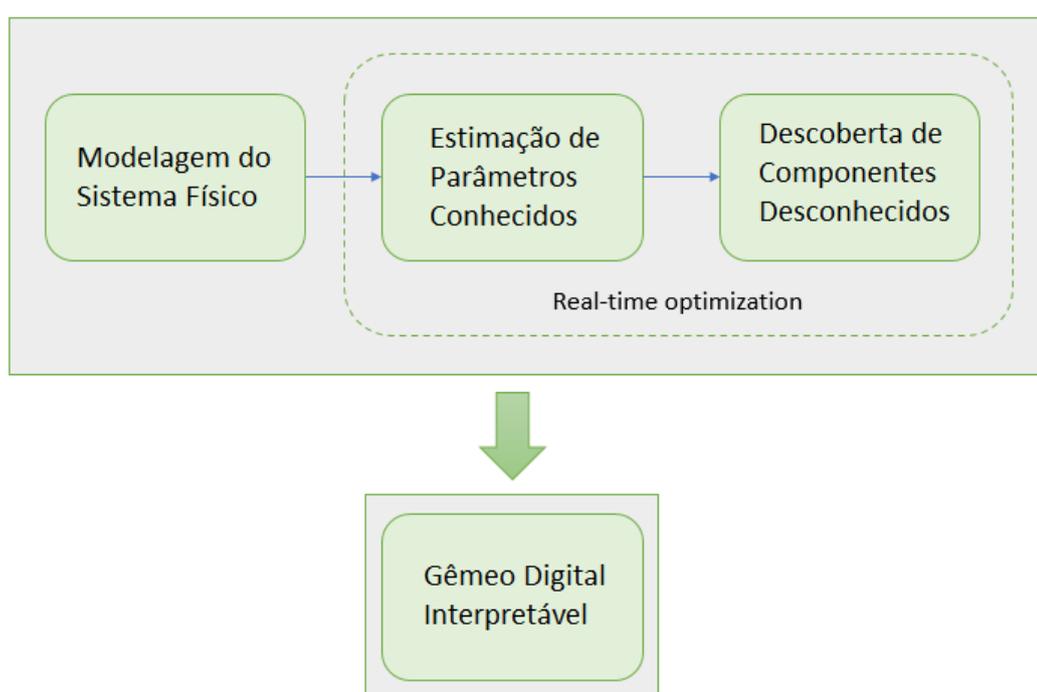
É importante notar que, a partir do desenvolvimento de um primeiro DT (Etapa 1), suas variações e adaptações tem um certo valor em relação a implementação em máquinas reais. Cada etapa da metodologia traz uma melhoria significativa no DT. Quando avançamos para a Etapa 2 e desenvolvemos o DT’ (Gêmeo Digital Adaptável), o operador e a máquina se beneficiam de um modelo otimizado, que ajusta seus parâmetros em tempo real através do algoritmo PSO. Essa adaptabilidade permite um entendimento mais preciso do estado do sistema, resultando em decisões mais informadas e eficazes.

Com a implementação da Etapa 3, onde o DT evolui para o DT’’ (Gêmeo Digital Aprimorado), a compreensão do sistema se torna ainda mais profunda. O DT’’ é capaz de identificar e integrar componentes desconhecidos, adaptando-se de forma dinâmica às mudanças do sistema.

Esta característica revela aspectos antes ocultos do sistema e permite uma visão mais completa e realista da situação. Assim, a máquina e o operador ganham uma perspectiva aprimorada, sendo capazes de responder com mais eficiência às mudanças e aos desafios emergentes.

O resultado é um operador e uma máquina que não apenas entendem melhor sua condição atual, mas também são capazes de prever e se adaptar a situações futuras de maneira eficaz. A Figura 5 ilustra as três etapas da metodologia. Os blocos envolvidos pela linha pontilhada representam as etapas de otimização em tempo real, que são o cerne deste trabalho.

Figura 5 – Metodologia de criação do Gêmeo Digital interpretável



Fonte: elaborado pelo autor (2023)

## 3.2 Etapas da metodologia

Cada etapa, desde a modelagem inicial até a identificação de componentes desconhecidos, desempenha um papel crucial para garantir que o Gêmeo Digital seja um reflexo preciso e atualizado do sistema físico. Nesta seção, são exploradas em detalhes cada uma destas etapas, elucidando os processos, técnicas e considerações envolvidos para assegurar a eficácia e interpretabilidade do modelo.

### 3.2.1 Modelagem do Gêmeo Digital (Etapa 1)

Métodos alternativos, como os baseados em aprendizado de máquina, podem não ser capazes de capturar todas as nuances dos princípios físicos subjacentes e serem mais difíceis de interpretar, devido ao fato de que o comportamento do sistema é aprendido a partir dos dados, em vez de ser diretamente descrito através de equações. Assim, a metodologia proposta recomenda a criação desse primeiro Gêmeo Digital (DT) com base em equações matemáticas que representam os componentes físicos do sistema real. Esta abordagem garante que o modelo do Gêmeo Digital represente com precisão o comportamento conhecido do sistema físico e seja facilmente interpretável.

Ao utilizar equações matemáticas, é possível capturar os princípios físicos intrínsecos e conhecidos que regem o comportamento do sistema e simular sua resposta a diferentes condições de operação. Esta abordagem tem sido amplamente utilizada no desenvolvimento de Gêmeos Digitais para diversas aplicações, incluindo manufatura, robótica e aeroespacial, entre outras [75] [76].

A modelagem do sistema físico é um passo fundamental para a criação de um Gêmeo Digital. Esta fase envolve a formulação de equações matemáticas que descrevem os componentes físicos do sistema e suas interações. Tais equações podem ser derivadas a partir de princípios físicos, tais como leis de conservação de massa e energia, equações de movimento, leis de termodinâmica, entre outros. Também é importante considerar as condições operacionais do sistema e quaisquer restrições associadas [75].

Três pontos importantes devem ser considerados no projeto ou escolha do Gêmeo Digital. Primeiro, o modelo deve ser projetado para ser interpretável, permitindo ao usuário entender como o Gêmeo Digital opera e como se relaciona com o sistema real. Para isso, extensivo conhecimento sobre o sistema é necessário e o entendimento das diferentes partes e suas interações é um aspecto fundamental. A documentação apropriada pode incluir descrições detalhadas dos componentes do sistema, das equações utilizadas e dos parâmetros do modelo. Por outro lado, inclusão de diagramas esquemáticos ou representações gráficas do sistema e suas partes componentes pode ajudar a transmitir uma compreensão mais clara e intuitiva do sistema [20].

Em segundo lugar, o modelo deve ser parametrizável, permitindo a configuração do sistema conforme necessário. Isso é crucial para garantir que o Gêmeo Digital possa se adaptar às mudanças nas condições operacionais e refletir o estado atual do sistema físico. Alguns exemplos de parâmetros podem ser coeficientes de resistência, ganhos de controle, parâmetros termodinâmicos, constantes eletromagnéticas, entre outros. Eles devem ser selecionados de tal forma que possam ser facilmente medidos ou estimados a partir dos dados do sistema e que tenham significância no contexto geral do sistema, relacionando os valores dos parâmetros, ou ainda a variância destes, com estados e variáveis do sistema físico [20].

Finalmente, mas ainda de extrema importância, o modelo deve ser modular, permitindo

a adição de novos componentes e subsistemas conforme necessário. A modularidade é uma característica crítica na modelagem do Gêmeo Digital. Um modelo modular significa que o sistema é dividido em vários componentes ou módulos menores, cada um com seu próprio conjunto de equações e parâmetros. Isso permite que o modelo seja flexível e adaptável às mudanças, pois cada componente pode ser alterado ou substituído sem afetar o resto do sistema. No contexto deste trabalho, por exemplo, estados do sistema como corrente e velocidade são calculados separadamente.

Isso é particularmente útil ao lidar com sistemas complexos e em evolução, onde novos componentes podem ser adicionados ou os existentes podem ser modificados ao longo do tempo. A modularidade também facilita a manutenção e atualização do modelo, pois permite que cada componente ou subsistema seja tratado de forma independente [77]. Essa modularidade é explorada extensivamente na etapa 3 desta metodologia.

O modelo do Gêmeo Digital necessário nessa primeira etapa da metodologia pode ser definido matematicamente na forma:

$$(y_1, y_2, \dots, y_l) = DT(p_1, p_2, \dots, p_n, x_1, x_2, \dots, x_m). \quad (3.1)$$

Aqui,  $DT$  representa o modelo matemático que encapsula o sistema físico. As  $l$  saídas possíveis  $y$  do sistema são computadas por meio de  $DT$ , que é informado por  $n$  parâmetros  $p$  e  $m$  entradas  $x$ . As entradas  $x$  representam os estímulos ou controles aplicados ao sistema, os parâmetros  $p$  são características intrínsecas do sistema, e as saídas  $y$  são as respostas do sistema a esses estímulos.

A modelagem de  $DT$  deve ser tal que os parâmetros  $p$  possam ter seus valores identificados. Neste primeiro momento, esses parâmetros são tratados como invariantes. A identificação dos parâmetros iniciais do modelo pode ser realizada usando métodos de identificação de sistemas, conforme discutido no Capítulo 2 deste trabalho. Ou ainda instrumentação adequada pode ser utilizada para medição daqueles, categorizando esses parâmetros conhecidos como instrumentados ou não-instrumentados. Assim, temos  $DT$  atuando como réplica do sistema real, considerando os parâmetros conhecidos não-instrumentados como constantes fixas não variáveis, e os instrumentados adquirindo seus valores a partir do sistema.

Para ilustrar o processo de modelagem, vamos considerar um simples exemplo de um sistema mecânico, como um pêndulo vertical esquematizado na Figura 6.

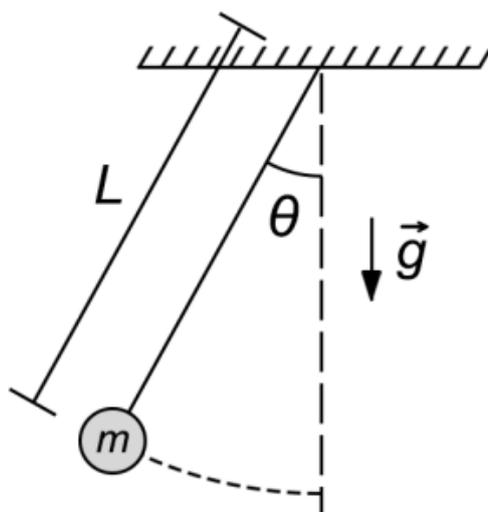
As equações de movimento para um pêndulo podem ser derivadas a partir da segunda lei de Newton, resultando na equação diferencial 3.2.

$$\theta''(t) + \frac{g}{L} \sin(\theta(t)) = 0, \quad (3.2)$$

onde  $\theta(t)$  é o ângulo do pêndulo em relação à vertical,  $g$  é a aceleração da gravidade e  $L$  é o comprimento do pêndulo. Esta equação é um exemplo simples de como os princípios físicos

podem ser traduzidos em equações matemáticas para a modelagem do Gêmeo Digital. No mundo real, exemplos mais complexos podem incluir a modelagem de um motor de avião ou um robô industrial, cada um com seu próprio conjunto de equações derivadas dos princípios físicos relevantes.

Figura 6 – Representação esquemática de um pêndulo vertical, mostrando um peso suspenso de um ponto fixo e oscilando em torno de uma posição de equilíbrio vertical.



Fonte: elaborado pelo autor (2023)

Ao utilizar essa abordagem, o Gêmeo Digital pode capturar com precisão os princípios físicos subjacentes e simular a resposta do sistema a várias condições operacionais. Além disso, oferece flexibilidade e adaptabilidade, já que permite a atualização do modelo com novos dados e a modificação para inclusão de subsistemas adicionais, conforme necessário.

Ao longo do tempo, à medida que o sistema físico passa por alterações, essas mudanças devem ser refletidas no Gêmeo Digital atualizando os parâmetros relevantes. Isso pode exigir a re-identificação dos parâmetros com base nos dados mais recentes do sistema. O modelo do Gêmeo Digital pode exigir manutenção e atualizações regulares para garantir sua precisão e relevância, sendo necessário um aprimoramento de  $DT$ .

### 3.2.2 Estimação de parâmetros conhecidos (Etapa 2)

A segunda etapa da metodologia consiste na estimação online dos parâmetros conhecidos não-instrumentados. Essa tarefa é realizada com dados de entrada e saída adquiridos da operação do sistema. Esses dados são utilizados como referência em um algoritmo de otimização para uma determinada função objetivo, baseada no próprio Gêmeo Digital  $DT$ .

O uso de algoritmos de otimização baseados em enxames, como o PSO, oferece várias vantagens para a estimativa de parâmetros. Em particular, eles são capazes de explorar eficientemente o espaço de pesquisa, evitando os mínimos locais que podem atrapalhar outros métodos de otimização. Além disso, o PSO é um método de otimização robusto e flexível, que pode ser facilmente adaptado para lidar com diferentes tipos de problemas de otimização, o que o torna bastante interessante para aplicações em tempo real.

O algoritmo PSO, um método inspirado pela movimentação de enxames na natureza, busca valores para os parâmetros conhecidos e não-instrumentados que minimizem o erro entre o sistema real e as saídas do modelo. O PSO inicia com um conjunto de soluções aleatórias, chamado de partículas, e iterativamente ajusta estas partículas com base na posição da melhor solução (partícula) até agora encontrada, e na melhor solução do enxame como um todo. Esse processo resulta numa busca global pelo espaço de soluções.

Devemos considerar que as saídas de processos de sistemas dinâmicos como máquinas industriais são influenciadas não só por suas entradas e parâmetros internos, mas também pelos estados e variáveis do processo ao longo do tempo. Portanto, o problema de otimização precisa considerar um intervalo de tempo necessário para calcular o valor da função objetivo baseado no comportamento do modelo e do sistema real.

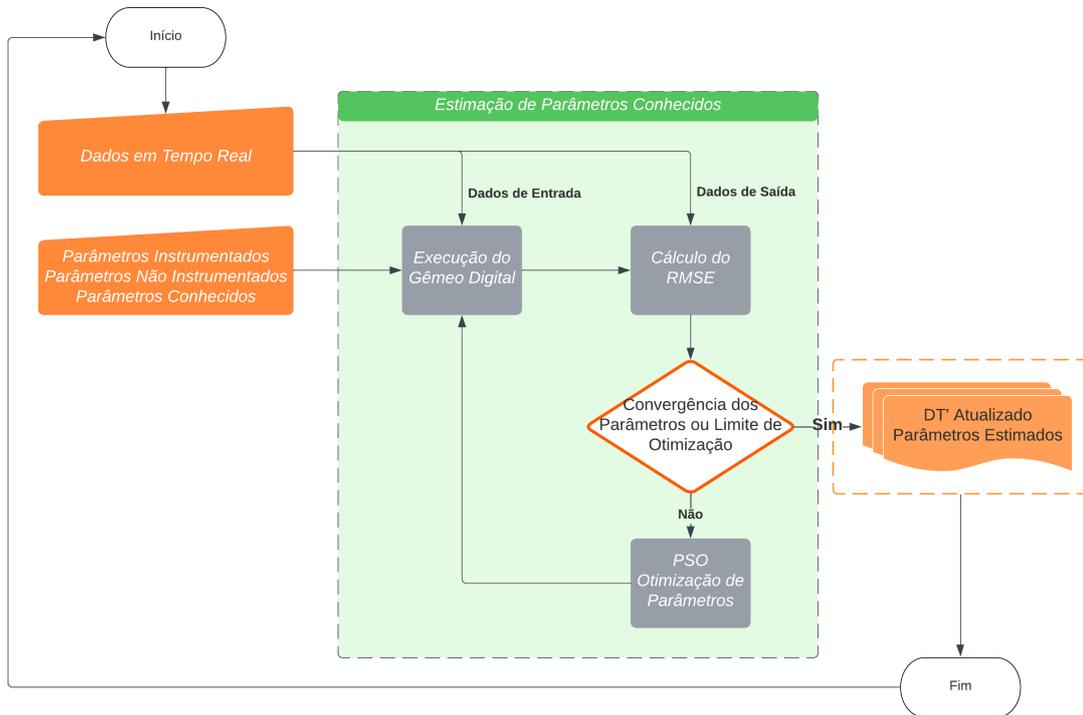
A função objetivo utilizada neste trabalho é baseada no erro quadrático médio (RMSE, do inglês *Root Mean Square Error*) entre os dados de referência adquiridos e as saídas do modelo. O RMSE é uma métrica comumente usada para avaliar a precisão das previsões de um modelo. É definido como a raiz quadrada da média das diferenças quadradas entre os valores previstos e reais.

Para avaliar um conjunto de parâmetros, o modelo é executado para simular durante o mesmo tempo de aquisição dos dados. Ele utiliza os parâmetros gerados pelo PSO, os valores de referência de entrada e o tempo de amostragem para as iterações necessárias. Finalmente, o RMSE é calculado entre os dados de referência adquiridos da execução do sistema real e as saídas do modelo. Assim, o algoritmo PSO tenta minimizar o RMSE ajustando os parâmetros do modelo para a próxima iteração até que uma convergência seja alcançada.

Durante a otimização, a função objetivo é avaliada repetidamente para diferentes conjuntos de parâmetros. O algoritmo PSO move os "enxames" (conjuntos de possíveis soluções) em direção à região do espaço de parâmetros que minimiza a função objetivo. Ao fim da otimização, obtemos os valores de parâmetros que oferecem a melhor representação dos dados do sistema. O uso dos parâmetros convergidos pela otimização levará a previsões melhores e melhor desempenho do sistema. A Figura 7 ilustra como o processo de estimação de parâmetros é realizado na etapa 2 desta metodologia.

Então, uma vez estimados os parâmetros, o modelo do Gêmeo Digital é atualizado com os novos valores ótimos e o sistema está agora apto a prever melhor o comportamento

Figura 7 – Estimação de Parâmetros utilizando o Gêmeo Digital



Fonte: elaborado pelo autor (2023)

da máquina, estando pronto para um novo tempo de aquisição. Ainda mais, a variação dos parâmetros estimados ao longo do tempo, se forem tratados adequadamente podem fornecer *insights* sobre o estado de saúde da máquina e as condições operacionais, e pode ser usado para fins de diagnóstico, entre outros.

O modelo do Gêmeo Digital para esta etapa da metodologia difere do anterior principalmente na adaptação dos valores dos parâmetros  $p$  que agora são estimados a partir dos dados adquiridos em tempo real. Cada parâmetro conhecido no modelo do Gêmeo Digital representa algum aspecto do sistema físico. Mudanças nesses parâmetros refletem variações correspondentes no sistema. Por exemplo, um parâmetro pode representar a eficiência de um componente, e uma mudança nesse parâmetro pode indicar um desgaste ou falha nesse componente. Portanto, ao monitorar os parâmetros, podemos avaliar não apenas o desempenho global do sistema, mas também a condição de seus componentes individuais.

Este segundo Gêmeo digital é mostrado na equação 3.3, onde  $p'_i$  é um parâmetro do modelo, com  $i$  sendo o índice do parâmetro e o símbolo "'" denotando que é um parâmetro estimado. Além disso,  $p_i$  denota parâmetros que não são estimados.

$$DT' = DT(p'_1, p'_2, p_3, p_4, \dots, p_n, x_1, x_2, \dots, x_m). \quad (3.3)$$

A estimação de parâmetros é uma atividade crítica no desenvolvimento e uso de modelos de sistemas, e deve ser realizada periodicamente. Em sistemas dinâmicos, especialmente aqueles sujeitos a desgaste ou degradação, as condições operacionais do sistema e os estados dos componentes podem mudar com o tempo. Assim, para manter a precisão do Gêmeo Digital, é necessário realizar a re-estimação de parâmetros periodicamente ou quando há sinais de que o comportamento do sistema físico mudou significativamente. Isso garante que o Gêmeo Digital mantenha uma representação precisa do sistema físico ao longo do tempo, adaptando-se às suas mudanças e evolução. Assim, continuará refletindo a condição atual do sistema físico, mesmo que esteja sujeito a desgaste, degradação ou outras mudanças.

Isso é particularmente verdadeiro para sistemas complexos, onde a relação entre as entradas, saídas e estados do sistema pode ser altamente não-linear e dependente do tempo. Um bom ajuste de parâmetros pode melhorar significativamente a precisão das previsões do modelo, levando a melhores decisões de controle e operação.

Além disso, a capacidade de atualizar os parâmetros do modelo com base em dados novos permite que o Gêmeo Digital seja adaptativo, refletindo as mudanças nas condições operacionais e no estado do sistema físico ao longo do tempo. Isso permite que o Gêmeo Digital seja usado para monitoramento em tempo real do sistema.

Por exemplo, na indústria aeroespacial, considerando que o monitoramento da saúde do motor de um avião é crucial para garantir a segurança das operações aéreas e minimizar o tempo de inatividade do serviço, informações em tempo real coletadas dos sensores do motor podem ser usadas como entradas para o Gêmeo Digital. Estimando-se os parâmetros do motor, como a eficiência do combustível e a condição dos componentes individuais, entre outros, é possível acompanhar as tendências desses parâmetros, identificando anomalias e prevenindo possíveis falhas. Por exemplo, se o parâmetro representando a eficiência de combustão de um motor começa a diminuir consistentemente, isso pode indicar um desgaste em um componente crítico ou uma falha iminente. Assim, o Gêmeo Digital serve como um sistema de alerta precoce, permitindo ações preventivas para evitar falhas e interrupções.

Um outro aspecto importante na estimação de parâmetros é o uso deste para o planejamento de manutenções preventivas e a otimização de algum aspecto do controle do sistema. Ao incorporar os parâmetros estimados no Gêmeo Digital, é possível antecipar o desgaste ou falhas nos componentes do sistema antes que eles se tornem críticos, facilitando o planejamento de intervenções preventivas para minimizar o tempo de inatividade e maximizar a eficiência operacional.

Além disso, os parâmetros estimados podem fornecer informações valiosas para algoritmos de controle avançado, como os de controle preditivo. Estes utilizam um modelo do sistema para prever o comportamento futuro e tomar decisões de controle com base nessa previsão. Se o modelo for capaz de adaptar-se às mudanças do sistema através da re-estimação de parâmetros, o algoritmo de controle preditivo será capaz de fazer decisões mais precisas e eficazes.

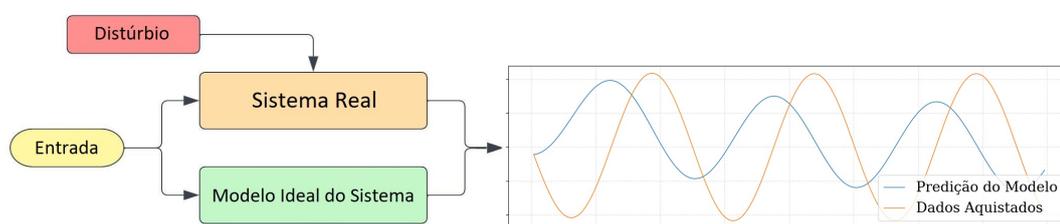
Assim, a segunda etapa da metodologia proposta visa aprimorar a precisão e a adaptabilidade do Gêmeo Digital através da estimação e atualização contínua dos parâmetros do modelo. Ao fazer isso, ela não só melhora a precisão do modelo, mas também facilita a manutenção preventiva e otimiza o controle do sistema. Finalmente, ela cumpre com os requisitos básicos de adaptação do Gêmeo Digital e fornece uma base sólida para as etapas subsequentes da metodologia, que se concentrarão na identificação e integração de componentes desconhecidos do sistema no Gêmeo Digital.

### 3.2.3 Descoberta de componentes e parâmetros desconhecidos (Etapa 3)

Até o momento, consideramos a estrutura do modelo do Gêmeo Digital como fixa, isto é, o seu comportamento estaria vinculado às equações pré-estabelecidas no momento de concepção do modelo, em sua maioria, condições ideais de funcionamento. No entanto, condições operacionais específicas não contempladas na estrutura inicial selecionada podem influenciar a saída do sistema, causando uma discrepância entre o sistema real e as saídas do modelo ainda que com os parâmetros atualizados. A Figura 8 ilustra a diferença entre as saídas do modelo e sistema real para um mesmo *input*, devido a uma perturbação externa no sistema. O diagrama compara um sistema real e um modelo ideal do sistema. Ambos são submetidos à mesma entrada, porém o sistema real está sujeito a um distúrbio, fazendo com que suas saídas diverjam em resposta.

Tal discrepância pode ser interpretada como um comportamento não normal da máquina, ou seja, condições defeituosas devido, por exemplo, a um eixo desbalanceado, atrito introduzido, fuga de corrente, entre outros. A identificação desses fatores é crucial não apenas para o controle, mas também para o diagnóstico do sistema, manutenção da máquina e otimização do processo em aplicações industriais.

Figura 8 – Discrepância entre saídas do sistema real e do Gêmeo Digital



Fonte: elaborado pelo autor (2023)

Para aprimorar as capacidades do Gêmeo Digital, a discrepância na saída pode ser tratada complementando a estrutura conhecida do modelo e os parâmetros estimados com a descoberta de componentes e parâmetros desconhecidos.

No entanto, a interpretabilidade do modelo ainda desempenha um papel significativo, vinculando a estrutura do modelo a partes do sistema real, assim como suas condições de falha e comportamento. Portanto, os componentes desconhecidos do modelo são introduzidos como uma combinação de meta-modelos matemáticos conhecidos e interpretáveis.

Os meta-modelos, como discutido por Deng (2009) [27], são modelos matemáticos típicos, como funções lineares, exponenciais, periódicas, entre outras. Estes são cruciais na determinação das características e das respostas do sistema. O conjunto de modelos matemáticos aqui selecionado visa uma representação apropriada do sistema dinâmico, fundamentando-se na sua relevância e interpretação física no contexto da engenharia.

Cada modelo matemático pode ser associado a condições específicas de operação que são comumente observadas em sistemas mecânicos e elétricos na indústria. Estas associações podem ser feitas considerando a forma da função matemática e a natureza da condição de operação. Por exemplo, uma função exponencial, que mostra um crescimento ou decaimento rápido, pode representar situações como fuga de corrente, deterioração, desgaste, ou corrosão. Da mesma forma, uma função periódica, que representa comportamentos oscilatórios, pode ser usada para simular condições como eixo desbalanceado ou desalinhado, ou instabilidade da máquina.

É importante observar que, embora essas associações forneçam um bom ponto de partida para a modelagem de condições operacionais específicas, a adequação de um determinado modelo matemático para uma condição de operação específica pode variar dependendo das características exatas do sistema e das condições em estudo. A Tabela 2, elaborada pelo autor e fundamentada em princípios consolidados de engenharia, apresenta uma série de meta-modelos com suas respectivas equações matemáticas e condições de operação atribuídas dos sistemas.

Tabela 2 – Exemplos de Meta-Modelos e Condições de Operação Atribuídas

<b>Função do Modelo</b>	<b>Equação Matemática</b>	<b>Condição de operação atribuída</b>
Linear	$mx + b$	Fricção, desalinhamento, folga
Exponencial	$ab^x$	Fuga de Corrente, deterioração, desgaste, corrosão
Exponencial Negativa	$ae^{-bx}$	Envelhecimento, degradação, fadiga, crescimento de rachadura
Potência	$ax^b$	Paradas bruscas, sobrecarga, choque mecânico
Logarítmica	$a \ln(x) + b$	Saturação, efeitos de memória, histereses
Periódica	$a \sin(bx + c) + d$	Eixo desbalanceado, Eixo desalinhado, instabilidade da máquina

Fonte: elaborado pelo autor (2023)

Realiza-se então uma segunda otimização para selecionar a combinação adequada de meta-modelos que complemente o modelo adaptativo, diminuindo as discrepâncias entre a

previsão do modelo do Gêmeo Digital e os dados do processo. O ajuste, ou otimização, é realizado em três fases simplificadas. Cada etapa é explicada em detalhes a seguir:

1. **Seleção dos Meta-Modelos:** Na primeira fase, selecionamos os meta-modelos que serão usados para complementar o modelo de Gêmeo Digital. Essa seleção é feita com base nas características operacionais do sistema real, como a presença de atrito, desalinhamento, desgaste, entre outros. Cada um desses comportamentos pode ser representado por uma função matemática específica, como mostrado na Tabela 2.
2. **Definição das entradas para os meta-modelos:** As entradas para os meta-modelos são definidas. Estas podem incluir o tempo de aquisição de dados, assim como as próprias entradas, saídas e estados do sistema. Essa versatilidade permite levar em consideração várias possibilidades diferentes.
3. **Otimização dos Parâmetros dos Meta-Modelos:** Na terceira fase, otimiza-se os parâmetros dos meta-modelos selecionados para que eles representem da melhor maneira possível os dados do processo. Isso é feito através do ajuste dos parâmetros dos meta-modelos para minimizar a diferença entre as previsões do modelo do Gêmeo Digital e os dados do processo.

Para tal otimização, uma nova função objetivo é elaborada. A modularidade do Gêmeo Digital proposto na Etapa 1 entra em cena permitindo uma modificação da estrutura do modelo. O Gêmeo Digital é reestruturado para passar a ser composto pelo modelo ideal anterior combinado com o conjunto de meta-modelos selecionados.

Cada meta-modelo está ligado a estrutura por meio de um coeficiente principal. Esses coeficientes servem como pesos, indicando o quão importante é cada meta-modelo para a representação do comportamento do sistema. Finalmente, esses meta-modelos e seus coeficientes são estimados utilizando PSO.

O modelo final do Gêmeo Digital tomará a forma:

$$DT'' = DT(p_1, p_2, \dots, p_n, x_1, x_2, \dots, x_m) + \sum U_i(z_{i1}, z_{i2}, \dots, z_{ik}), \quad (3.4)$$

onde  $DT$  é o modelo de Gêmeo Digital previamente selecionado com  $n$  parâmetros estimados e  $m$  entradas, e  $U_i$  representa cada meta-modelo matemático com seus próprios  $k$  número de parâmetros.

O objetivo da otimização é, como anteriormente, estimar os valores dos parâmetros da nova estrutura de modo que o novo modelo possa representar adequadamente os dados aqúistados do sistema em tempo real.

A otimização resulta então na formação de uma estrutura final com os coeficientes principais estimados, de forma a identificar componentes específicos para o modelo. A ideia é

que os coeficientes principais dos componentes necessários para representação adequada dos dados pelo modelo sejam maximizados, enquanto os coeficientes referentes aos componentes não necessários sejam minimizados.

A partir dos coeficientes maximizados e minimizados é possível estabelecer quais seriam os componentes matemáticos anteriormente desconhecidos do sistema. Além disso, o Gêmeo Digital é atualizado com os componentes identificados.

É importante ressaltar que, ao introduzir esses meta-modelos no Gêmeo Digital, estamos efetivamente ampliando a capacidade do modelo de representar o sistema real. Cada meta-modelo serve para representar um aspecto específico do comportamento do sistema que não é capturado pelo modelo base. Ao fazê-lo, estamos não apenas aprimorando a precisão do Gêmeo Digital, mas também melhorando sua interpretabilidade, já que cada meta-modelo é ligado a uma parte específica do sistema real e a um comportamento ou condição de falha ou operação específico.

Portanto, a terceira etapa da metodologia proposta é fundamental para garantir que o Gêmeo Digital seja não apenas mais preciso, mas também altamente interpretável e capaz de representar adequadamente o sistema real em uma ampla variedade de condições operacionais.

No entanto, é crucial destacar que a descoberta de componentes e parâmetros desconhecidos é mais do que um mero aprimoramento do modelo do Gêmeo Digital. É uma etapa essencial para a prevenção de falhas inesperadas e a melhoria contínua do desempenho do sistema. Através dessa etapa, conseguimos detectar e modelar as condições de operação e falha que não foram consideradas no modelo inicial. Isso, por sua vez, permite que o Gêmeo Digital preveja e evite problemas antes que eles ocorram, além de encontrar oportunidades para otimizar o desempenho do sistema.

Assim, a terceira etapa de nossa metodologia não só aprimora a acurácia e a interpretabilidade do Gêmeo Digital, mas também aumenta sua utilidade prática. Com a inclusão de componentes e parâmetros desconhecidos, o Gêmeo Digital se torna uma ferramenta ainda mais poderosa para o monitoramento, diagnóstico e otimização de sistemas em aplicações industriais.

### **3.3 Implementação do Gêmeo Digital**

Antes de aprofundar os detalhes da implementação, é importante entender o panorama geral do processo. A metodologia proposta é visualizada de forma clara na Figura 9, onde os componentes chave e etapas são delineados. A área pontilhada em verde representa a otimização em tempo real. Em resumo, primeiro os dados em tempo real são adquiridos do sistema. Em seguida, com base no erro de previsão, realiza-se uma otimização para estimar os parâmetros conhecidos não instrumentados e atualizar o Gêmeo Digital para DT'. Depois disso, também com base no erro de previsão, componentes e parâmetros desconhecidos são descobertos por uma segunda otimização e o Gêmeo Digital é atualizado para DT''. Se o modelo atualizado

não satisfizer os critérios de saída, o processo é reiniciado. Esta estratégia estabelece um *loop* contínuo, realizado com dados recém adquiridos.

Figura 9 – Fluxograma detalhado da metodologia proposta



Fonte: elaborado pelo autor (2023)

A implementação segue uma sequência de etapas interligadas, culminando na atualização contínua do Gêmeo Digital. Com base nessa estrutura, detalha-se a seguir o processo inicial de implementação.

A implementação da metodologia proposta começa com a criação do Gêmeo Digital (DT), apresentado na primeira etapa da metodologia. Esse processo é anterior e externo ao controle do sistema propriamente dito. O DT atua como uma réplica digital do sistema físico, desempenhando um papel crucial no controle do sistema. Isso significa que ele imita o comportamento do sistema físico em um ambiente virtual.

Nesse contexto, os controladores, que são dispositivos ou softwares responsáveis por gerenciar e regular o comportamento de um sistema em um ambiente industrial, assumem uma importância adicional. Eles não apenas gerenciam o sistema em tempo real, mas também hospedam e interagem diretamente com essa representação digital, permitindo uma tomada de decisão mais informada e proativa. Por exemplo, em um sistema de produção industrial, o DT, hospedado nesses controladores, pode simular o processo de fabricação, considerando as condições atuais e os parâmetros de entrada, para prever possíveis resultados e o desempenho geral do sistema. Desta forma, é possível experimentar diferentes cenários, otimizar os parâmetros do sistema e até prever e evitar possíveis problemas sem interferir no sistema físico real.

Nestes mesmos controladores, os dados em tempo real da máquina, como temperaturas, pressões, taxas de fluxo, entradas e saídas dos sistemas, variáveis de controle, parâmetros conhecidos instrumentados, entre outras, são medidos e adquiridos. Esses dados servirão também como base para a estimação de parâmetros online e a descoberta de componentes desconhecidos nas etapas seguintes.

A cada ciclo de operação definido - que chamamos de 'janela de iteração' ou 'janela de aquisição' - o mecanismo de adaptação do Gêmeo Digital é acionado. Neste contexto, uma 'janela' refere-se a um período específico durante o qual o sistema opera e adquire dados, semelhante a um ciclo de trabalho. Durante cada janela, as saídas do Gêmeo Digital são comparadas com os dados reais do sistema para verificar sua precisão. Se alguma discrepância for detectada, o processo de adaptação começa.

O mecanismo de adaptação do Gêmeo Digital é fundamental para garantir que o modelo continue representando o sistema real conforme os dados são adquiridos. Este mecanismo atua em duas etapas principais:

Primeiro, verifica-se se o modelo atual continua representando adequadamente o sistema real com base nos dados adquiridos. Esta é a Etapa 2 da metodologia, onde a Otimização por Enxame de Partículas (PSO) é utilizada para estimar os parâmetros do DT. O algoritmo busca os parâmetros que minimizam a discrepância entre as saídas do sistema real e do DT. Uma vez que os parâmetros ótimos são estimados, o DT é atualizado, resultando no chamado Gêmeo Digital atualizado (DT').

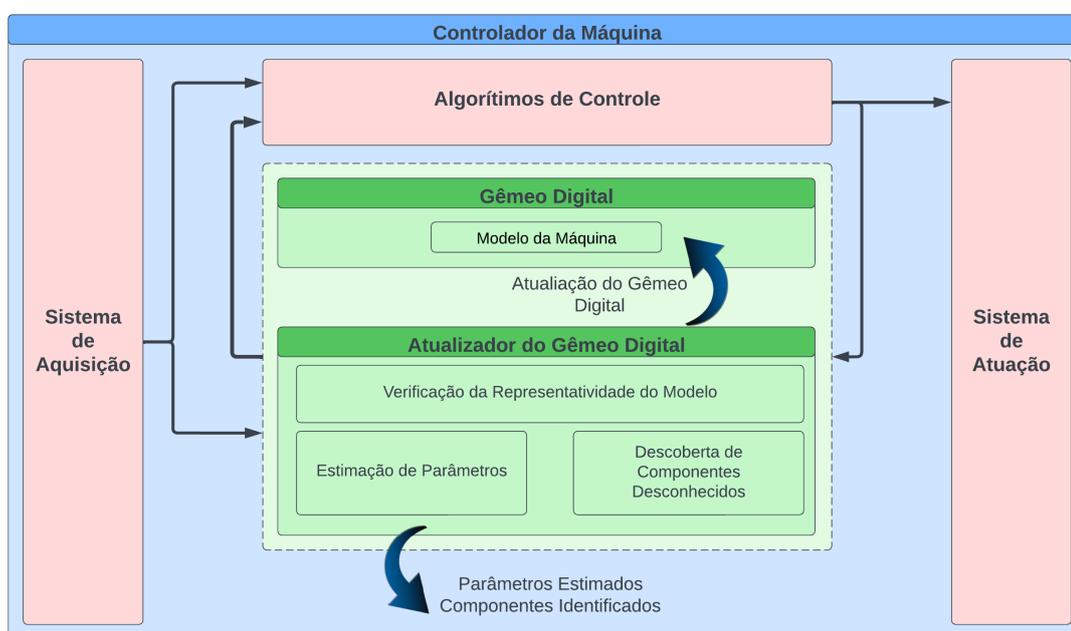
Em seguida, uma nova verificação é realizada utilizando o modelo atualizado. Se ainda houver uma discrepância significativa entre os resultados obtidos e os dados reais, passamos para a Etapa 3 da metodologia, que envolve a descoberta de componentes desconhecidos. Estes componentes representam aspectos do sistema que ainda não foram capturados pelo modelo atual do Gêmeo Digital. O PSO é aplicado novamente, mas agora com o objetivo de identificar tais componentes. O algoritmo busca encontrar estes componentes ajustando uma série de candidatos possíveis, que são explorados em paralelo, como um 'enxame'.

Cada candidato é avaliado com base em quão bem ele melhora a concordância entre o

Gêmeo Digital e o sistema real. O candidato que produz a maior melhoria é identificado como o componente desconhecido. Este componente é então integrado ao Gêmeo Digital, aumentando a sua precisão e habilidade em simular o sistema real. Considerando os meta-modelos interpretáveis, o algoritmo PSO pode efetivamente encontrar os componentes desconhecidos. O DT é então atualizado com esses componentes recém-descobertos, resultando no Gêmeo Digital adaptativo (DT’).

A Figura 10 mostra um diagrama de blocos do Gêmeo Digital e mecanismo de adaptabilidade incorporados a um controlador. Destacados em verde estão os elementos desenvolvidos pela metodologia e suas iterações com o restante do sistema em vermelho.

Figura 10 – Diagrama de blocos do Gêmeo Digital incorporado a um controlador



Fonte: elaborado pelo autor (2023)

O DT é apenas um dos produtos finais da metodologia proposta que será efetivamente construído e completado durante a operação do sistema. Ele incorpora não só os parâmetros estimados do sistema, mas também os componentes descobertos. Isto proporciona um modelo preciso e interpretável do sistema. Além disso, com a contínua aquisição de novos dados durante a operação do sistema, o DT pode ser constantemente atualizado e aprimorado, permitindo uma adaptabilidade contínua do Gêmeo Digital.

Além do DT, a segunda entrega significativa deste sistema é a disponibilização dos valores dos parâmetros desconhecidos e os componentes identificados. Estas informações são de extrema importância para o controlador e o operador da máquina, pois fornecem *insights* sobre o estado e o comportamento do sistema. Isto não só ajuda a melhorar o desempenho do sistema,

mas também auxilia na detecção precoce de falhas, otimização de processos e tomada de decisão estratégica.

Desta forma, a metodologia proposta se torna uma ferramenta indispensável na gestão e operação eficaz de sistemas complexos. Ela oferece uma abordagem sistemática e adaptável para construir um Gêmeo Digital interpretável que pode se adaptar às mudanças na operação do sistema, enquanto fornece informações valiosas para a melhoria contínua do desempenho do sistema, auxiliando também no processo de tomada de decisão.

## Capítulo 4

# Experimentos

Este capítulo é dedicado à avaliação empírica das capacidades do Gêmeo Digital desenvolvido utilizando a metodologia proposta quanto à adaptação, representatividade do sistema real e autoconsciência da máquina sob diversas condições operacionais e ambientais. Nosso objetivo é verificar a hipótese de que esse Gêmeo Digital pode representar com precisão um sistema real e adaptar-se às mudanças nas condições operacionais, fatores ambientais e alterações físicas durante a execução, utilizando os dados adquiridos do sistema.

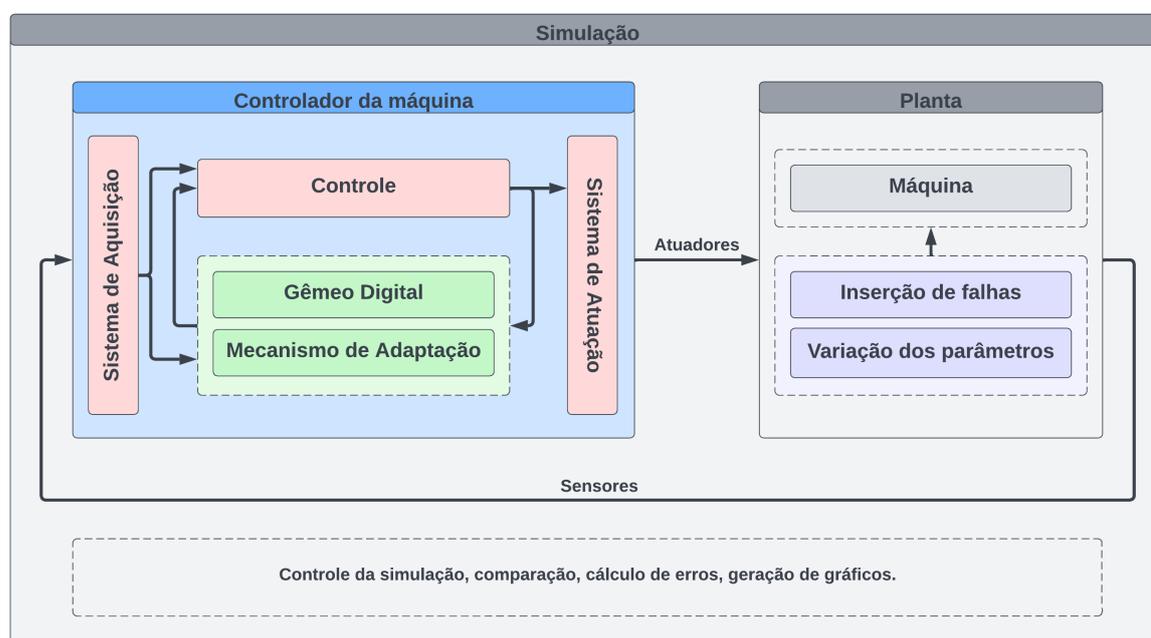
Para conduzir essas avaliações, selecionamos dois estudos de caso: um motor DC (do inglês, *Direct Current*) e um atuador hidráulico. Ambos são componentes amplamente encontrados em vários contextos industriais e, como ressaltado na literatura, apresentam desafios significativos em termos de manutenção e controle devido à variedade de falhas e condições operacionais que podem enfrentar [74] [78] [79] [80].

Os modelos do motor DC e do atuador hidráulico são criados e simulados em um ambiente virtual. Através desses modelos, pretendemos representar o comportamento dos sistemas reais, replicando o máximo possível suas operações e variabilidades. Além disso, foram feitos ajustes nos parâmetros dos modelos e inserções de falhas para avaliar a capacidade do gêmeo digital em adaptar-se a diferentes condições operacionais tais como mudanças de carga, aumento de fricção, desgaste, etc.

No mesmo ambiente virtual, o controlador de máquina é implementado conforme a metodologia proposta. Sendo usado para fornecer as entradas necessárias para os modelos dos sistemas reais, adquirir dados de entrada e saída do sistema - como tensão, corrente, força, temperatura e deslocamento - e simular a implementação do Gêmeo Digital. O desempenho e a adaptabilidade do gêmeo digital são comparados com o comportamento do sistema real simulado para avaliar sua precisão e capacidade de representar fielmente o sistema.

A Figura 11 ilustra um diagrama de blocos do ambiente virtual de simulação. Três diferentes partes do ambiente são mostradas: o controlador da máquina, a planta e o controle de simulação.

Figura 11 – Diagrama de blocos do ambiente virtual de simulação.



Fonte: elaborado pelo autor (2023)

O controlador da máquina é composto pelo Gêmeo Digital e o mecanismo de adaptação, ambos discutidos no capítulo 3. O Gêmeo Digital é responsável por representar a máquina em questão, enquanto o mecanismo de adaptação assegura que o modelo possa ajustar-se de acordo com as mudanças nas condições operacionais e variações de parâmetros. O controlador da máquina também abriga o sistema de controle e atuação, que interage diretamente com o Gêmeo Digital, fornecendo as entradas necessárias para a máquina e coletando os dados de saída. O controlador também inclui o sistema de aquisição de dados, que captura informações relevantes sobre o funcionamento da máquina.

A planta, por sua vez, abriga a simulação da máquina. Essa simulação, que representa o sistema físico real, é capaz de reproduzir o comportamento da máquina, levando em consideração seus parâmetros característicos e as entradas fornecidas pelo controlador. Além disso, a planta permite a inserção de falhas e variação dos parâmetros, simulando diversas condições de operação e cenários que a máquina pode enfrentar.

Finalmente, o controle da simulação coordena a ordem de execução das tarefas, o controle do passo de tempo (*time step*), o *loop* de simulação, o cálculo dos erros, o gerenciamento do armazenamento dos sinais e a geração de gráficos. Estes processos auxiliam na análise dos resultados e no ajuste da simulação de acordo com as necessidades da pesquisa.

A implementação da simulação segue uma estrutura bem definida que permite uma

análise aprofundada e detalhada do comportamento das máquinas e do Gêmeo Digital.

Primeiramente, condições iniciais são definidas: as variáveis para tempo, contadores e os diversos parâmetros das máquinas são inicializados. Cada máquina, seja o motor DC ou o atuador hidráulico, possui um conjunto de parâmetros que definem seu comportamento base. Esses parâmetros incluem, para o motor DC, a resistência, indutância e constantes de torque, e para o atuador hidráulico, o diâmetro do cilindro, diâmetro da haste do pistão e massa do pistão. Além disso, cada tipo de máquina tem um conjunto associado de estados e saídas que são inicialmente definidos como zero.

Uma vez que essas configurações iniciais são estabelecidas, se inicia o *loop* principal de simulação. A simulação é executada a partir do instante zero e executa até que o tempo de simulação seja atingido. As operações realizadas em cada ciclo incluem:

- Cálculo de entradas: Com base no tempo atual e outros parâmetros, as entradas para a máquina são calculadas.
- Simulação da máquina: Dado o estado atual, entradas e parâmetros da máquina, o próximo estado e saídas da máquina são calculados. Isto simula o comportamento da máquina para o dado passo de tempo.
- Execução do controlador: As saídas e estados calculados, juntamente com o tempo atual, são passados para o controlador da máquina que então gera novos sinais de controle. O controlador também pode executar uma rotina de otimização dependendo do tempo atual e do período de otimização definido.
- Aquisição e armazenamento de dados: O estado e saída da máquina, bem como as saídas do controlador, são armazenados em diferentes vetores para posterior análise e geração de gráficos. Estes incluem os valores reais e previstos para vários parâmetros.

No final da simulação, vários gráficos são criados para visualização e análise dos resultados. Estes incluem gráficos para as posições reais e previstas, pressões e coeficientes de amortecimento, bem como o erro na estimativa do coeficiente de amortecimento. Esses gráficos são usados para avaliar o desempenho do controlador e a precisão do modelo.

Essa estrutura de simulação é utilizada para examinar o comportamento do motor DC e do atuador hidráulico sob várias condições e parâmetros de operação, mas pode ser estendida para diferentes tipos de máquinas. Além disso, procura-se avaliar como o Gêmeo Digital se adapta e representa essas mudanças. As avaliações empíricas descritas neste capítulo são fundamentais para verificar a hipótese de que o Gêmeo Digital pode representar com precisão um sistema real e adaptar-se às mudanças nas condições operacionais, fatores ambientais e alterações físicas durante a execução, utilizando os dados adquiridos do sistema.

Os *insights* adquiridos a partir desses estudos de caso podem contribuir para a validação do uso de gêmeos digitais em ambientes industriais, demonstrando sua eficácia na detecção e diagnóstico de falhas, e na adaptação a condições em constante mudança.

Este capítulo é estruturado da seguinte forma: após esta introdução, a seção ‘Configuração da Simulação’ detalha o ambiente de simulação e o hardware utilizado. Em seguida, no ‘Estudo de Caso 1: Motor DC Industrial’, descrevemos o modelo do motor DC e as variações de parâmetros que serão testadas. O ‘Estudo de Caso 2: Atuador Hidráulico’ segue o mesmo formato, descrevendo o modelo do atuador e as variações de parâmetros que serão testadas.

## 4.1 Configuração da Simulação

### 4.1.1 Hardware do Computador

O sistema de computador pessoal utilizado para este estudo está equipado com um processador Intel(R) Core(TM) i7-1185G7 de 11<sup>a</sup> geração, o *clock* é de 3.00 GHz. Este processador oferece altas capacidades de computação e suporta tecnologias avançadas como inteligência artificial e aprendizado de máquina. O sistema também conta com 32.0 GB de RAM, o que permite o manuseio eficiente de grandes conjuntos de dados e cálculos complexos. O sistema opera com o sistema operacional Windows 10, 64 bits, que permite multitarefa eficiente e melhor resposta do sistema. Essas características tornam o sistema adequado para diversas tarefas computacionais, incluindo análise de dados e, especialmente, simulações científicas, que é o foco deste estudo.

### 4.1.2 Configuração do Software

Para o desenvolvimento e execução das simulações, utilizamos o ambiente de desenvolvimento integrado (IDE) PyCharm versão 2022.2.1. Essa IDE, desenvolvida pela JetBrains, oferece uma gama robusta de funcionalidades para a programação em Python, incluindo um poderoso depurador, suporte a várias bibliotecas e um eficiente sistema de gerenciamento de projetos [81].

As simulações são implementadas usando a linguagem de programação Python versão 3.9. Python é uma escolha ideal para este projeto, devido à sua sintaxe clara e legível, bem como à sua ampla gama de bibliotecas científicas e de análise de dados [82].

Além disso, diversas bibliotecas são usadas para facilitar a implementação e análise das simulações. A biblioteca Matplotlib é utilizada para a visualização dos dados e a criação de gráficos [83]. A biblioteca Pymoo é usada para algoritmos de otimização [84]. E a biblioteca csv é usada para a leitura e escrita de dados em arquivos CSV, permitindo um fácil manuseio e armazenamento de dados de entrada e saída das simulações [85].

A estrutura do projeto é organizada de forma modular, com diferentes aspectos das simulações implementados em arquivos separados. A definição dos problemas, a planta e o modelo, bem como as funções objetivo, são definidos em arquivos distintos, permitindo uma melhor organização e manutenção do código. O arquivo principal contém a definição das entradas, a implementação do controlador e a função principal que coordena a execução da simulação.

Essa organização modular e a utilização de ferramentas e bibliotecas robustas permitiram a implementação eficiente e eficaz das simulações necessárias para este estudo.

## 4.2 Estudo de Caso 1: Motor DC Industrial

O motor DC é um componente essencial em diversas aplicações industriais, incluindo sistemas de propulsão, elevadores e robôs, graças à sua simplicidade, confiabilidade e facilidade de controle [86] [87]. No entanto, esses motores estão sujeitos a várias falhas, como desvios de comportamento do motor, que podem comprometer seu desempenho.

Assim, torna-se crucial desenvolver modelos precisos que consigam prever o comportamento do motor sob variadas condições de trabalho e identificar possíveis falhas. Neste estudo, nosso foco será o desenvolvimento de um gêmeo digital para um motor DC, para demonstrar sua eficácia na detecção e diagnóstico de condições de falha.

O comportamento do motor DC pode ser descrito por duas equações fundamentais: a equação elétrica e a equação mecânica. A primeira descreve a dinâmica do fluxo elétrico no motor, enquanto a segunda descreve o comportamento mecânico do motor [88] [87].

A equação elétrica do motor DC é dada pela equação 4.1:

$$V_a = R_a I_a + L_a \frac{dI_a}{dt} + K_e \omega_r, \quad (4.1)$$

onde  $V_a$  é a tensão de armadura,  $R_a$  é a resistência elétrica da armadura,  $L_a$  é a indutância da armadura,  $I_a$  é a corrente da armadura,  $K_e$  é a constante de força eletromotriz, e  $\omega_r$  é a velocidade angular do rotor, o termo  $K_e \omega_r$  representa a tensão contra-eletromotriz.

A equação mecânica é expressa na equação 4.2:

$$J \frac{d\omega_r}{dt} + B \omega_r = T_{load} - K_t I_a, \quad (4.2)$$

onde  $J$  é o momento de inércia,  $B$  é o coeficiente de amortecimento viscoso,  $T_{load}$  é o torque de carga e  $K_t$  é a constante de torque do motor.

Essas equações são fundamentais para entender e modelar o comportamento de um motor DC sob diferentes condições de operação. As variações nesses parâmetros podem indicar condições de falha. Por exemplo, uma alteração significativa na resistência da armadura  $R_a$  pode indicar um curto-circuito, enquanto uma variação na constante de força eletromotriz  $K_e$  pode sugerir falhas no comutador ou nos enrolamentos do campo magnético [87].

Os gêmeos digitais dos motores DC, construídos com base nesses princípios, têm o potencial de identificar essas falhas de maneira mais eficaz, garantindo manutenção eficiente, otimização de processos e controle robusto. Detalhes adicionais sobre o modelo do gêmeo digital e como ele representa o comportamento do motor DC são discutidos nas seções subsequentes.

### 4.2.1 Modelo do motor DC

O modelo do motor DC, conforme abordado anteriormente, é construído com base nas equações matemáticas que representam o comportamento elétrico e mecânico do motor. Estas equações, nas suas formas contínuas, geralmente envolvem derivadas de tempo e são conhecidas como equações diferenciais. Para simulações numéricas e implementações em sistemas de controle digital, é necessário transformar estas equações contínuas em suas formas discretas. Para tal, é comumente utilizado um método numérico conhecido como método de Euler [89].

A corrente elétrica da armadura  $i_k$  e a velocidade angular do rotor  $\omega_k$  foram escolhidos como saídas do modelo, pois essas variáveis estão disponíveis para medição e oferecem informações significativas sobre a condição e o desempenho do motor. As entradas são a tensão da armadura ( $V_a$ ) e o torque de carga ( $T_{load}$ ), os valores anteriores de corrente ( $i_{k-1}$ ) e velocidade ( $\omega_{k-1}$ ) e o passo de tempo de integração ( $T_s$ ).

Assim, as equações discretas que representam a discretização das equações elétrica e mecânica são:

$$i_k = i_{k-1} + T_s \cdot \frac{V_a - R_a \cdot i_{k-1} - K_e \cdot \omega_{k-1}}{L_a} \quad (4.3)$$

e

$$\omega_k = \omega_{k-1} + T_s \cdot \frac{i_k \cdot K_t - T_{load} - B \cdot \omega_{k-1}}{J} \quad (4.4)$$

As equações 4.3 e 4.4 descrevem a atualização dos valores discretos da corrente e velocidade angular do motor DC, considerando as características elétricas e mecânicas do sistema, respectivamente.

Os parâmetros físicos do motor DC são definidos da seguinte maneira:

$R_a$ : Resistência da armadura em  $\Omega$ , que limita a corrente no circuito do motor.

$L_a$ : Indutância da armadura em  $H$ , que atua para se opor a mudanças na corrente no motor.

$J$ : Momento de inércia do rotor em  $kg * m^2$ , que afeta a aceleração angular do rotor.

$K_e$ : Constante de força eletromotriz em  $V * s/rad$ , que relaciona a velocidade angular do rotor à tensão induzida.

$K_t$ : Constante de torque do motor em  $Nm/A$ , que relaciona a corrente da armadura ao torque produzido.

$B$ : Coeficiente de amortecimento do rotor em  $Nm \cdot s/rad$ , que representa a perda de energia devido ao atrito no motor [87].

## 4.2.2 Variação dos Parâmetros

Esta seção aborda os parâmetros do motor de corrente contínua (DC) e do algoritmo de otimização por enxame de partículas (PSO - *Particle Swarm Optimization*). São detalhadas variações desses parâmetros em cenários distintos que simulam diferentes condições operacionais, fatores ambientais, alterações físicas e degradação de componentes em um sistema de motor DC.

Para a análise, um motor DC de pequeno a médio porte foi selecionado, com parâmetros que são comumente observados em motores de tamanhos e tipos similares. Tais parâmetros, muitas vezes, são fornecidos pelos fabricantes nas fichas técnicas dos seus motores, representando valores médios ou esperados que foram determinados através de extensos processos de testes e controle de qualidade.

Os valores dos parâmetros iniciais do motor DC escolhido para o estudo são mostrados na Tabela 3. Estes valores são representativos de um motor DC típico, permitindo que o gêmeo digital modele um motor genérico de pequeno a médio porte, aumentando assim a aplicabilidade dos resultados para uma ampla gama de motores similares em diversas aplicações do mundo real.

Tabela 3 – Parâmetros iniciais do motor DC simulado.

Parâmetro	Valor
$R_a$	6.5 $\Omega$
$L_a$	0.673 H
$J$	0.001171 kg $\cdot$ m <sup>2</sup>
$K_e$	0.038 V $\cdot$ s/rad
$K_t$	0.038 N $\cdot$ m/A
$B$	0.00143 N $\cdot$ m/s $\cdot$ rad

Fonte: elaborado pelo autor (2023)

Neste estudo, foi utilizada a implementação do algoritmo PSO da biblioteca pymoo [84], uma biblioteca de otimização multiobjetivo em Python. Esta biblioteca foi escolhida por sua ampla aplicabilidade, eficiência e a diversidade de algoritmos de otimização que implementa. Na implementação do PSO pela biblioteca pymoo, os seguintes parâmetros são utilizados:

- $\omega$ : peso da inércia, controlando o impacto da velocidade anterior na velocidade atual
- $c_1$ : peso cognitivo (referente ao melhor local encontrado pela partícula)
- $c_2$ : peso social (referente ao melhor global encontrado pelo enxame)
- $r_1$  e  $r_2$ : valores aleatórios entre 0 e 1, utilizados como fatores estocásticos na atualização da velocidade

A atualização da velocidade é dada pela equação 4.5:

$$\mathbf{V}_i(k+1) = \omega \mathbf{V}_i(k) + c_1 r_1 (\mathbf{P}_i(k) - \mathbf{X}_i(k)) + c_2 r_2 (\mathbf{G}_i(k) - \mathbf{X}_i(k)). \quad (4.5)$$

Enquanto a atualização da posição é feita pela equação 4.6:

$$\mathbf{X}_i(k+1) = \mathbf{X}_i(k) + \mathbf{V}_i(k+1), \quad (4.6)$$

onde:

- $\mathbf{V}_i(k)$ : velocidade da partícula  $i$  no instante  $k$ .
- $\mathbf{X}_i(k)$ : posição da partícula  $i$  no instante  $k$ .
- $\mathbf{P}_i(k)$ : melhor posição pessoal da partícula  $i$  no instante  $k$ .
- $\mathbf{G}_i(k)$ : melhor posição global do enxame no instante  $k$ .

Os parâmetros padrões do algoritmo PSO da biblioteca pymoo foram propostos com base em estudos extensivos para garantir um bom equilíbrio entre os componentes cognitivo e social. No entanto, esses parâmetros foram refinados por experimentos iniciais permitindo que o algoritmo oferecesse um melhor desempenho neste estudo de caso, em especial, o aumento do ‘tamanho do enxame’, que se refere ao número de partículas na população do PSO, para além do valor selecionado não representou melhoria significativa que justificasse o seu uso.

Os parâmetros selecionados são mostrados na Tabela 4.

Tabela 4 – Parâmetros da otimização por PSO

Parâmetro	Símbolo	Valor
Tamanho do enxame	$N_{\text{swarm}}$	15
Máximo número de iterações	$N_{\text{max}}$	1000
Inércia	$w$	0.9
Parâmetro Cognitivo	$c_1$	2.0
Parâmetro Social	$c_2$	2.0

Fonte: elaborado pelo autor (2023)

O valor referência de velocidade segue uma função escada onde a velocidade muda para valores de  $0\text{rad/s}$ ,  $5\text{rad/s}$ ,  $10\text{rad/s}$ ,  $15\text{rad/s}$  e  $20\text{rad/s}$  em diferentes momentos. A velocidade é controlada usando um Controlador Proporcional-Integrativo com ganhos  $K_p = 0.3$  e  $K_i = 0.1$  que ajusta a entrada de tensão do motor. O torque de carga é proporcional à velocidade do rotor com um coeficiente de  $0.006\text{Nm} \cdot \text{s/rad}$ . O tempo de estimativa é avaliado como  $2\text{s}$ ,  $4\text{s}$  e  $10\text{s}$  para que o intervalo de tempo adequado possa ser selecionado.

Três cenários foram projetados para as simulações. Estes cenários são inspirados por falhas comuns que ocorrem em motores de corrente contínua na indústria, onde alterações no

ambiente, desgaste e degradação de componentes podem afetar o desempenho do motor. Estas falhas podem levar a perdas financeiras significativas devido à necessidade de manutenção ou substituição do motor, bem como à perda de produção durante o tempo de inatividade. Portanto, é essencial para a indústria ser capaz de prever e mitigar essas falhas [87].

No primeiro cenário, é simulada a degradação da resistência da armadura. Na indústria, a resistência da armadura de um motor DC pode se degradar devido a fatores como corrosão ou danos físicos. Tal degradação pode levar a um aumento da corrente do motor, o que pode resultar em sobreaquecimento e possíveis falhas no motor [86].

Assim, um desvio na resistência da armadura é introduzido para simular a degradação desse componente. Uma simulação de 1200 segundos ocorre enquanto  $R_a$  é diminuída ao longo do tempo de  $6.5\Omega$  para cerca de  $5.6\Omega$  usando um decaimento exponencial  $-0.044 * \exp(0.003 * t) + 0.044$  e a cada passo de tempo iniciando em  $160s$ .

No segundo cenário, é simulado o desgaste do rolamento. Na indústria, o desgaste do rolamento é uma causa comum de falha de motores, frequentemente devido à falta de lubrificação adequada, sobrecarga ou operação em altas temperaturas [74]. O desgaste do rolamento pode levar a um aumento da vibração e do ruído do motor, além de diminuir a eficiência do motor.

Para tanto, o coeficiente de amortecimento ( $B$ ) é degradado para simular um desgaste do rolamento. Uma simulação de 1200 segundos é usada enquanto  $B$  aumenta ao longo do tempo a partir do valor inicial para cerca de  $0.00227H$  usando uma inclinação exponencial  $0.00003806 * \exp(0.003 * t) - 0.00003806$  a cada passo de tempo iniciando em  $160s$ .

Finalmente, no terceiro cenário, é simulado um eixo desbalanceado. Na indústria, um eixo desbalanceado pode ocorrer devido a desgaste irregular ou a danos físicos ao eixo. Isso pode causar vibração excessiva, o que pode levar a um desgaste acelerado de outras partes do motor e, eventualmente, a falhas no motor [78].

Para simular o eixo desbalanceado, são introduzidos desvios na velocidade do rotor. Um erro senoidal é adicionado ao cálculo da velocidade a cada passo de tempo. A amplitude do erro é definida como  $5rad/s^2$  que é multiplicada pelo tempo de amostragem da simulação. A frequência angular é escolhida para ser fixa em  $10rad/s$ . Assim, a simulação do eixo desbalanceado é realizada modificando a equação 4.4 na equação 4.7

$$\omega_k = \omega_{k-1} + T_s \cdot \frac{i_k \cdot K_t - T_{load} - B \cdot \omega_{k-1}}{J} + T_s \cdot 5 \cdot \sin(10t), \quad (4.7)$$

onde  $t$  é o tempo no instante  $k$ . A equação 4.7 representa a atualização do valor discretizado da velocidade angular do motor DC durante a simulação do eixo desbalanceado.

Os dois primeiros cenários, isto é, degradação da resistência da armadura e desgaste do rolamento, avaliam a etapa de estimação dos parâmetros. Finalmente, o eixo desbalanceado avalia as capacidades de descoberta de componentes desconhecidos.

Em cada um destes cenários, o objetivo é estimar o estado atual do motor, identificar a

presença de qualquer uma dessas falhas e, finalmente, adaptar o controle do motor para mitigar o efeito dessas falhas. Assim, estes cenários representam situações práticas relevantes para a indústria.

### 4.3 Estudo de Caso 2: Atuador Hidráulico

O segundo estudo de caso se concentra na aplicação do Gêmeo Digital em um atuador hidráulico. Atuadores hidráulicos são fundamentais em diversas indústrias, como a aeroespacial, automotiva, e em maquinários pesados, devido à sua capacidade de gerar forças elevadas e controlar com precisão a posição dos atuadores. No entanto, eles estão propensos a uma variedade de falhas e condições operacionais adversas, como variações de temperatura, desgaste de selos e vazamentos, que podem impactar significativamente o seu desempenho [90].

Nesse contexto, o Gêmeo Digital atua como uma ferramenta poderosa para diagnosticar falhas e otimizar a operação do atuador hidráulico. Isso é possível por meio da simulação de diferentes cenários operacionais no Gêmeo Digital, que permite a identificação precoce de falhas e a implementação de medidas corretivas antes que falhas graves ocorram, além do uso do modelo em *loops* de controle.

Este estudo de caso aborda a modelagem de um sistema hidráulico simplificado, que inclui uma bomba de deslocamento constante, uma válvula controlada e um cilindro de pistão. Ainda que este modelo seja uma aproximação simplificada do sistema hidráulico, ele oferece uma representação bastante precisa de um atuador hidráulico sob diversas condições. Por fim, a modelagem deste tipo de sistema é relevante, pois ajuda a compreender melhor como variações nos componentes e condições operacionais podem afetar o desempenho geral.

O esquema do sistema hidráulico é apresentado na Figura 12. A figura apresenta os componentes com a saída de uma bomba de deslocamento constante conectada a entrada de um cilindro de pistão e a válvula de controle que por sua vez conecta ao reservatório de fluido. O "carro", representa uma carga, a posição do pistão é então mensurada pelo sensor U/F e passa ao controlador da válvula.

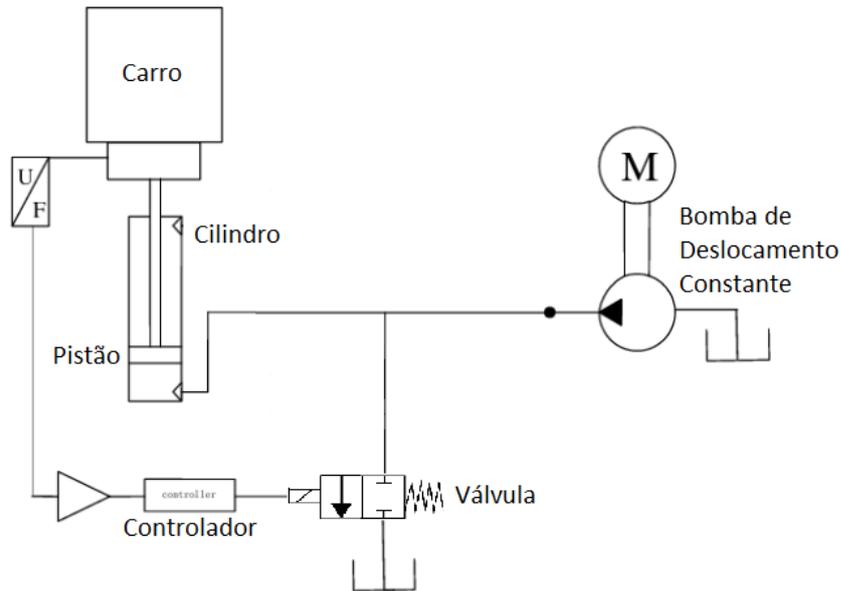
Nesse sistema, a bomba de deslocamento constante produz uma vazão de fluido  $q_{bomba}$  em direção ao cilindro, enquanto a seção transversal do orifício da válvula  $A_{válvula}$  é ajustada para controle da vazão  $q_{válvula}$ . Esse controle influencia diretamente na velocidade e deslocamento do pistão dentro do cilindro, e conseqüentemente, o deslocamento da carga.

Assumindo que  $p_{sistema}$  é a pressão do sistema em unidades de pressão, a velocidade do fluido na válvula  $v_{válvula}$  pode ser estimada pela lei de Bernoulli, conforme a equação 4.8:

$$v_{válvula} = \sqrt{2 \cdot p_{sistema}}, \quad (4.8)$$

que descreve a relação entre a pressão do sistema e a velocidade do fluido na válvula. Ela indica que a velocidade do fluido é proporcional à raiz quadrada da pressão do sistema.

Figura 12 – Esquema do sistema hidráulico abordado.



Fonte: elaborado pelo autor (2023)

Essa é uma simplificação da equação de Bernoulli, que é válida em situações onde as perdas de energia são insignificantes, não há variação significativa de altura e as velocidades de fluxo não são extremamente altas. Nessa aproximação, a energia potencial é negligenciada, e apenas a pressão estática é considerada como fonte de energia cinética.

Assim, a vazão na válvula pode ser expressa como:

$$q_{valvula} = A_{valvula} \cdot \sqrt{2 \cdot p_{sistema}}. \quad (4.9)$$

Através da equação 4.9, é possível estimar a vazão na válvula com base na área de seção transversal e na pressão do sistema. Essa relação é importante para o dimensionamento e controle de sistemas hidráulicos, permitindo avaliar e ajustar o fluxo de fluido através da válvula de acordo com as necessidades do sistema.

A velocidade do pistão, denotada como  $v$ , pode então ser obtida pela equação equação (4.10)

$$v = \frac{q_{bomba} - q_{valvula}}{A_{pistao}}, \quad (4.10)$$

onde  $A_{pistao}$  é a área do pistão.

A posição do pistão ao longo do tempo pode ser obtida pela integração da velocidade:

$$x(t) = \int v dt. \quad (4.11)$$

A equação 4.12 permite calcular a pressão no sistema hidráulico com base nas forças envolvidas e na área do pistão. Essa pressão é um indicativo da força exercida pelo fluido sobre

o pistão, considerando os efeitos da carga, força elástica, força de amortecimento e força de resistência interna. A pressão no sistema pode ser calculada somando-se as forças atuantes no pistão e dividindo pela sua área.

$$p_{sistema} = \frac{F_{carga} + F_{mola} + F_{amort} + F_{resist}}{A_{pistao}}, \quad (4.12)$$

onde  $F_{carga}$  é a força de carga,  $F_{mola}$  é a força elástica,  $F_{amort}$  é a força de amortecimento, e  $F_{resist}$  é a força de resistência interna.

Essas equações, derivadas das leis fundamentais da dinâmica dos fluidos e do movimento, permitem que o comportamento do atuador hidráulico seja simulado em diferentes cenários. Ao modelar esses cenários no Gêmeo Digital, é possível identificar potenciais falhas no desempenho do atuador, permitindo assim uma operação otimizada.

### 4.3.1 Modelo do Atuador Hidráulico

Semelhante ao modelo do motor DC, o modelo do atuador hidráulico é baseado nas equações físicas que descrevem seu comportamento. O método de Euler foi utilizado para transformar as equações diferenciais contínuas para um modelo de tempo discreto. Este processo é demonstrado com a equação de posição do pistão.

Usando a aproximação de Euler, podemos discretizar a equação (4.11) da seguinte forma:

$$x_k = x_{k-1} + T_s * v_{k-1}, \quad (4.13)$$

onde,  $T_s$  é o passo de tempo de integração e  $k$  é o índice que denota o instante de tempo discreto. A posição do pistão no instante  $k$  é dada pela sua posição no instante anterior mais o produto da velocidade do pistão no instante anterior e o passo de tempo.

Substituindo a equação de velocidade (4.10) em função do tempo discreto na equação (4.13), temos:

$$x_k = x_{k-1} + T_s * \frac{q_{bomba} - A_{valvula} \sqrt{2 \cdot p_{k-1}}}{A_{pistao}}. \quad (4.14)$$

O uso do modelo de tempo discreto facilita a implementação do modelo em sistemas de controle digital e permite a realização de simulações numéricas. No entanto, é importante lembrar que a precisão da discretização do modelo é limitada, especialmente para passos de tempo maiores devido às aproximações feitas. Assim, é necessário considerar um passo de tempo pequeno para garantir a precisão do modelo.

As saídas do nosso modelo são a pressão do sistema  $p_k$  e a posição do pistão  $x_k$  a cada instante  $k$ , e as entradas são a seção transversal controlada da válvula  $A_{valvula}$ , a força de carga  $F_{carga}$ , a posição  $x_{k-1}$  e a pressão  $p_{k-1}$  do instante anterior, e o passo de tempo de integração  $T_s$ .

Assim, a pressão no instante  $k$  é dada pela equação (4.15):

$$p_k = \frac{F_{carga} + F_{mola} + F_{amort} + F_{resist}}{A_{pistao}}, \quad (4.15)$$

onde,  $F_{mola} = k_{mola} * x_k$  e  $F_{amort} = D * v_k$  e representam as forças da mola e do amortecedor, respectivamente.

Os parâmetros físicos do sistema hidráulico são definidos da seguinte maneira:

$k_{mola}$ : Constante elástica do sistema em  $N/m$ .

$D$ : Coeficiente de amortecimento do sistema em  $N/(m/s)$ .

$q_{bomba}$ : Vazão da bomba de deslocamento constante em  $m^3/s$ .

$A_{max}$ : Máxima seção transversal da Válvula em  $m^2$ .

$A_{pistao}$ : Área do pistão em  $m^2$ .

### 4.3.2 Variação dos Parâmetros

O atuador hidráulico escolhido para este estudo representa um sistema genérico de elevador automotivo. Como objetivo principal era desenvolver e validar a metodologia proposta, foi selecionado um sistema simplificado que permitisse uma análise eficiente e uma compreensão abrangente dos resultados.

Os parâmetros iniciais do atuador hidráulico selecionado, juntamente com suas unidades correspondentes, são apresentados na Tabela 5. Esses parâmetros foram determinados com base em considerações típicas de um sistema de elevador automotivo e foram estabelecidos para fornecer um bom equilíbrio entre a simplicidade do modelo e a representação razoável do comportamento hidráulico.

Tabela 5 – Parâmetros iniciais do atuador hidráulico simulado usado no experimento.

Parâmetro	Valor
$k_{mola}$	200 N/m
$D$	100 N/(m/s)
$q_{bomba}$	0.02 $m^3/s$
$A_{max}$	10e-5 $m^2$
$A_{pistao}$	0.196349375 $m^2$

Fonte: elaborado pelo autor (2023)

A seleção dos parâmetros iniciais para o atuador hidráulico do elevador automotivo foi baseada em considerações típicas de projeto. Foi escolhida uma mola de rigidez moderada, adequada para sustentar a carga do elevador com estabilidade, enquanto o coeficiente de amortecimento foi definido para garantir um movimento controlado e eficiente do sistema. A taxa de deslocamento da bomba foi determinada levando em conta a velocidade de elevação desejada e a capacidade da bomba. Além disso, os valores das áreas de seção transversal foram selecionados considerando a capacidade de carga do elevador e o deslocamento necessário para operação segura.

Com o objetivo de simular ciclos de subida e descida do atuador, como um elevador hidráulico, o valor de referência de posição é uma função senoidal com amplitude  $0.45m$ , e frequência de  $0,005Hz$ .

Para simular a entrada do sistema, a força de carga foi estabelecida como uma carga vertical fixa de  $1000kg$ . O tempo de estimativa é avaliado com 3 diferentes valores,  $2s$ ,  $4s$  e  $10s$  para que o intervalo de tempo adequado possa ser determinado.

A posição do atuador é controlada usando um Controlador Proporcional-Integrativo-Derivativo (PID) com os ganhos e fator de filtro expressos na Tabela 6.

Tabela 6 – Parâmetros do Controlador PID para a controle da área da seção transversal da Válvula.

Parâmetro	Valor
$k_p$	0.000346498195200285
$k_i$	3.51340675941226e-05
$k_d$	0.000119950131059468
$N$	2.07674341980282

Fonte: elaborado pelo autor (2023)

A equação 4.16 representa o cálculo da seção transversal controlada da válvula  $A_{válvula}$ , baseado no controlador PID na sua forma discreta.

$$A_{válvula} = Erro \cdot \left( k_p + k_i \cdot T_s \cdot \frac{1}{z-1} + k_d \cdot \frac{N}{1 + N \cdot T_s \cdot \frac{1}{z-1}} \right). \quad (4.16)$$

A equação incorpora termos proporcionais, integrativos e derivativos para o controle, representados pelos coeficientes  $k_p$ ,  $k_i$  e  $k_d$ , respectivamente.  $T_s$  é o passo de tempo de integração. O termo  $z$  representa o operador de avanço no domínio Z, usado para modelar a dinâmica discreta do sistema. O termo  $z - 1$  denota um atraso de uma amostra, comum em sistemas discretos.

Este controle ajusta a seção transversal da válvula  $A_{válvula}$  pelo *Erro* entre a posição desejada e a real. Os valores dos parâmetros do controlador PID foram determinados por meio de técnicas de simulação e sintonia, visando obter um desempenho ótimo do sistema de controle. Esses parâmetros foram selecionados para garantir um controle preciso e estável do atuador hidráulico, permitindo o posicionamento adequado do elevador automotivo.

Dois cenários foram desenvolvidos para simular diferentes condições operacionais ou alterações físicas nos componentes que podem ocorrer neste tipo de sistema. Estes cenários proporcionam um importante contexto para testar e analisar a robustez e precisão do Gêmeo Digital.

O primeiro cenário propõe uma alteração na viscosidade do fluido hidráulico, o que reflete diretamente no coeficiente de amortecimento do sistema. Esta condição pode ser representativa de uma situação em que ocorre uma degradação do fluido hidráulico, causando um aumento na

viscosidade e, por consequência, no coeficiente de amortecimento. Fatores como envelhecimento, contaminação e variações de temperatura e pressão podem causar essa degradação.

Em particular, a contaminação do fluido pode ser um problema crítico em sistemas hidráulicos, podendo causar desgaste nos componentes, aumentar a fricção e, conseqüentemente, alterar o coeficiente de amortecimento do sistema [91].

Os efeitos dessa alteração são significativos: como o amortecimento atua para dissipar energia, o aumento do coeficiente de amortecimento pode resultar em uma resposta mais lenta do sistema, redução na eficiência energética e aumento da vibração, afetando a suavidade do movimento.

Para simular essa condição, foi permitido que o coeficiente de amortecimento  $D$  aumentasse gradualmente ao longo de uma simulação de 600 segundos. A partir do valor inicial para cerca de  $100N/(m/s)$  usando uma inclinação exponencial  $0.044 * \exp(0.003 * t) - 0.044$  a cada passo de tempo iniciando em  $160s$ , instante inicial de degradação.

Outro aspecto crítico que afeta o desempenho e a eficiência de um sistema hidráulico é a ocorrência de vazamentos. Na prática, o vazamento de fluido pode afetar significativamente a pressão e o desempenho geral do sistema, especialmente em operações de longo prazo.

Então, o segundo cenário considera a ocorrência de um vazamento de fluido no sistema. O objetivo deste cenário é testar a capacidade de "Descoberta de Componentes Desconhecidos" do Gêmeo Digital, ou seja, verificar se o modelo é capaz de identificar e modelar precisamente a ocorrência e o impacto do vazamento no desempenho do sistema [80].

Para simular essa condição, o modelo original foi modificado para incluir um termo de vazamento. Este componente, que inicialmente é desconhecido pelo Gêmeo Digital, é adicionado ao modelo original da planta do atuador hidráulico, especificamente à equação de atualização da pressão do sistema, agora considerando uma fração de vazamento. A equação 4.17 mostra esse novo cálculo:

$$p_k = (1 + C) * \frac{F_{carga} + F_{mola} + F_{amort} + F_{resist}}{A_{pistao}}, \quad (4.17)$$

onde,  $C$  representa o coeficiente de vazamento impactando na pressão do sistema.

O impacto deste componente de vazamento será avaliado nas respostas do sistema, particularmente na pressão do sistema e na seção transversal do orifício da válvula, permitindo testar a robustez e a precisão do Gêmeo Digital sob condições operacionais mais desafiadoras.

Finalmente, a capacidade de detectar e modelar a ocorrência de vazamentos, como no segundo cenário, tem implicações significativas para a detecção de falhas e a manutenção preditiva. Isso poderia resultar em uma operação mais segura e eficiente, minimizando custos e riscos associados a falhas do sistema.

O propósito de cada um desses cenários é testar a robustez e a precisão do Gêmeo Digital do atuador hidráulico sob diferentes condições operacionais. Isso permite uma validação das

previsões teóricas da metodologia proposta. Além disso, o uso de Gêmeos Digitais para simular essas condições pode permitir uma avaliação mais precisa das condições de funcionamento do atuador em tempo real, fornecendo informações úteis para otimizar o desempenho do atuador.

# Capítulo 5

## Resultados e discussão

### 5.1 Introdução

Neste capítulo, são apresentados os resultados obtidos a partir da aplicação da metodologia proposta nos dois estudos de caso selecionados - o motor DC e o atuador hidráulico. Esses estudos foram cuidadosamente escolhidos para ilustrar as funcionalidades e vantagens do modelo de Gêmeo Digital, destacando os aspectos de adaptação, representatividade do sistema real, autoconsciência da máquina e variabilidade das condições operacionais e ambientais, como descrito no capítulo anterior.

Inicialmente, a análise abrange os diferentes cenários de degradação e variações nos sistemas para ambos os estudos de caso. Aqui, é demonstrado como o Gêmeo Digital se adapta e representa precisamente o comportamento do sistema real sob várias condições operacionais e ambientais adversas. Esta análise contribui para a compreensão da aplicabilidade prática do Gêmeo Digital em contextos reais de engenharia e manutenção industrial.

Posteriormente, é realizada uma avaliação do tempo de aquisição, um componente crucial para permitir a autoconsciência da máquina e a adaptação do modelo. O tempo de aquisição se refere ao período necessário para coletar dados suficientes que permitam ao modelo aprender e adaptar-se aos parâmetros do sistema. Durante este intervalo, o desempenho do Gêmeo Digital é comparado com o sistema real simulado, empregando o erro percentual para avaliar a precisão e eficácia do modelo adaptável para os diferentes tempos de aquisição.

Por fim, discutimos os resultados obtidos para cada cenário, avaliando a eficácia da metodologia proposta na captura precisa da dinâmica do sistema e na autoconsciência da máquina, rastreando não apenas a degradação dos componentes do sistema, mas também o estado atual da máquina. A seção final realça a interpretabilidade do Gêmeo Digital, enfatizando sua capacidade de fornecer *insights* úteis sobre o estado e desempenho do sistema, demonstrando assim a fidelidade da representação do sistema real pelo Gêmeo Digital.

## 5.2 Estudo de Caso 1: Motor DC

Neste estudo, são examinados os três cenários de degradação comuns em motores DC: degradação da resistência da armadura, desgaste do rolamento e desbalanceamento de eixo. O objetivo desta análise é avaliar o desempenho do Gêmeo Digital em capturar a dinâmica do sistema e se adaptar a esses diferentes cenários de degradação.

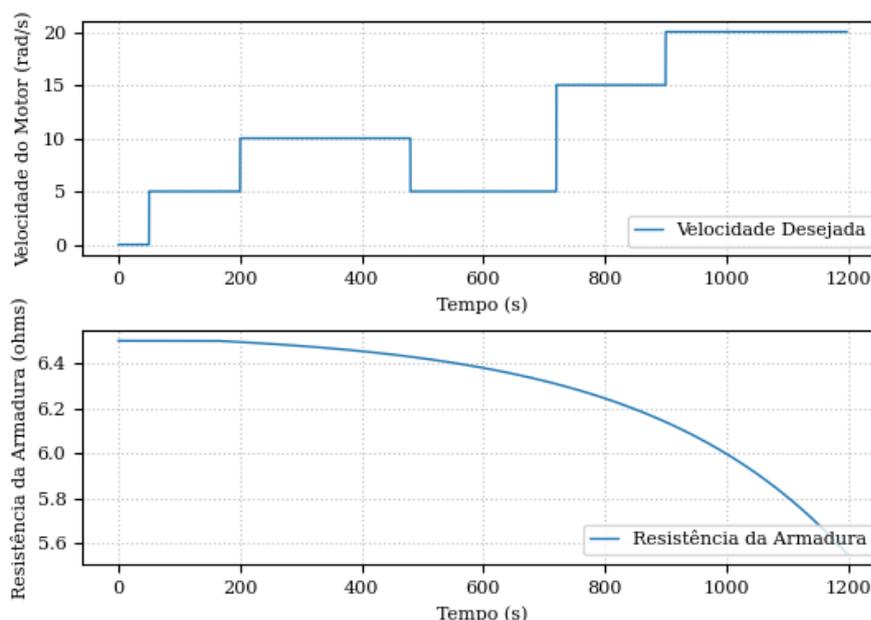
Apesar de o tempo de aquisição ser um componente fundamental no contexto geral, para esta primeira etapa da análise é utilizado um tempo de aquisição fixo, concentrando os esforços na avaliação do desempenho do modelo. Posteriormente, será realizada a análise do impacto do tempo de aquisição nos resultados obtidos.

### 5.2.1 Degradação da Resistência da Armadura

A resistência da armadura de um motor DC, submetida a fatores como tempo de uso e condições ambientais, pode ter seu valor alterado, impactando diretamente o desempenho do motor. Neste contexto, investigamos a capacidade do Gêmeo Digital em capturar e adaptar-se a essas alterações.

A Figura 13 ilustra a velocidade desejada para o motor como também a degradação na resistência da armadura ao longo do tempo. A curva em escada serve como *setpoint* para o sistema de controle, enquanto é possível observar a natureza exponencial da curva de resistência.

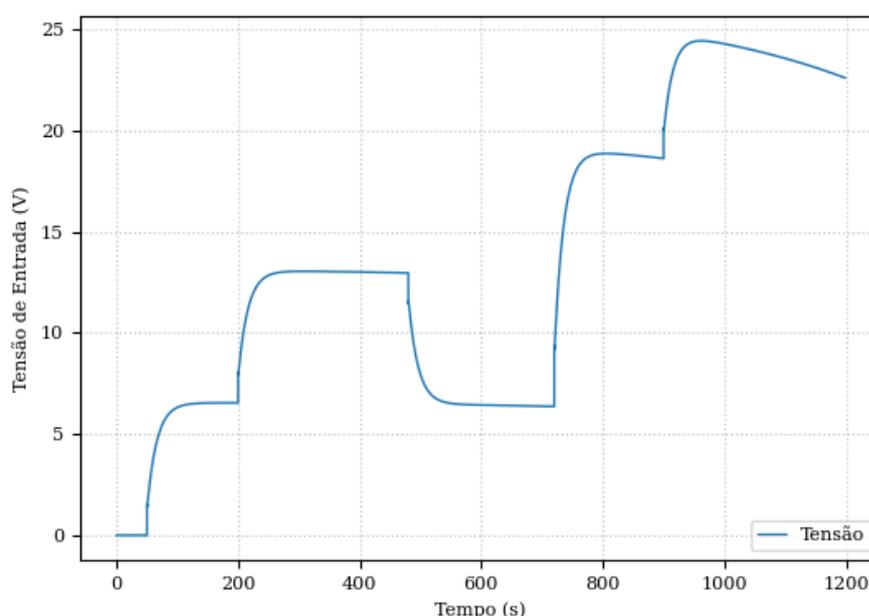
Figura 13 – Velocidade desejada (a) e degradação na resistência de armadura do motor DC (b) ao longo da simulação.



Fonte: elaborado pelo autor (2023)

A Figura 14 ilustra a tensão de entrada do motor DC durante o tempo de operação. Com a degradação da resistência da armadura, percebe-se um desvio notável na tensão, em especial onde há uma variação mais brusca nos instantes finais da simulação. Destaca-se que esta tensão de entrada representa o esforço do sistema de controle para manter a velocidade de referência. Particularmente entre os instantes 900s e 1200s apesar de a velocidade de referência ser fixada em 20 rad/s, onde ocorre uma queda da tensão de entrada em resposta à variação da resistência.

Figura 14 – Tensão de entrada do motor DC no cenário de degradação da resistência da armadura.



Fonte: elaborado pelo autor (2023)

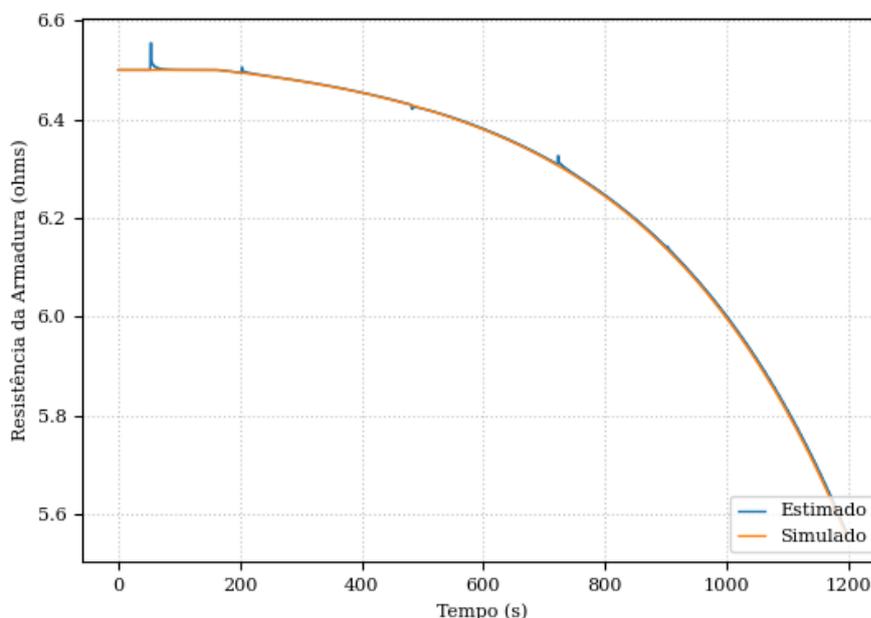
Analisando a Figura 15, que representa os valores simulados e estimados pelo Gêmeo Digital da resistência da armadura, observa-se que a estimativa permanece adequada ao longo da simulação. Nota-se a presença de alguns picos de desvio nos pontos de alteração no valor da função escada da velocidade de referência que são rapidamente estabilizados.

A Figura 16 demonstra o erro percentual na estimativa da resistência da armadura. A presença de picos no erro de estimativa é atribuída à tensão de entrada do sistema, modelada como uma função escada. No entanto, é fundamental destacar que, mesmo com essa característica e com a degradação exponencial da resistência da armadura, o erro se mantém abaixo de 1% durante toda a simulação. Esta magnitude de erro é consideravelmente pequena, evidenciando a eficácia do método de estimação empregado.

No contexto do estudo de caso do motor DC, a resistência da armadura foi modelada para diminuir exponencialmente com o tempo. Esta característica implica que, embora os intervalos de tempo entre as aquisições sejam constantes, a variação da resistência da armadura não é

uniforme ao longo desses intervalos. Em fases iniciais, essa variação pode ser sutil, mas à medida que o tempo avança, ela se torna mais pronunciada.

Figura 15 – Valores simulados e estimados da resistência da armadura no cenário de degradação da resistência da armadura.



Fonte: elaborado pelo autor (2023)

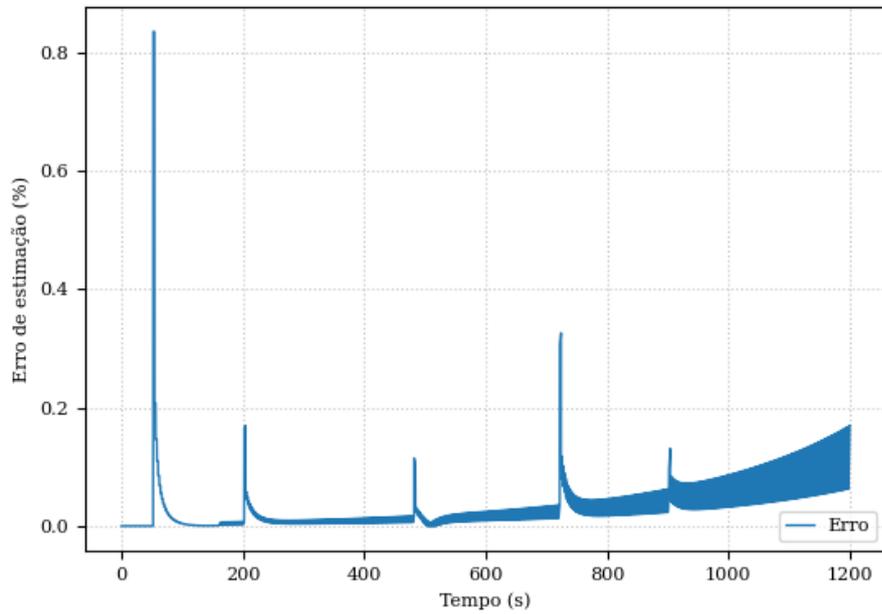
A combinação da natureza exponencial da degradação da resistência da armadura e da tensão de entrada do sistema como uma função escada são fatores que influenciam o perfil do erro observado na Figura 16. No entanto, o desempenho consistente do método de estimação em manter o erro abaixo de 1% destaca sua robustez diante desses desafios.

A alteração na resistência da armadura tem um impacto direto na velocidade de saída do motor, contudo, conforme pode ser observado na Figura 17, o controle é devidamente aplicado, causando um impacto no esforço da tensão de controle. Os resultados evidenciam uma congruência entre a velocidade prevista pelo Gêmeo Digital e a velocidade adquirida durante a simulação, indicando a eficácia do método de estimação de parâmetros proposto.

Finalmente a Figura 18 ilustra o erro relativo de previsão da saída do Gêmeo Digital em comparação à saída simulada. Excluindo-se a primeira estimativa, em que a qualidade dos dados pode ser questionável devido às condições de aquisição, o erro relativo permanece abaixo de 1%, com picos não ultrapassando os 2.5%.

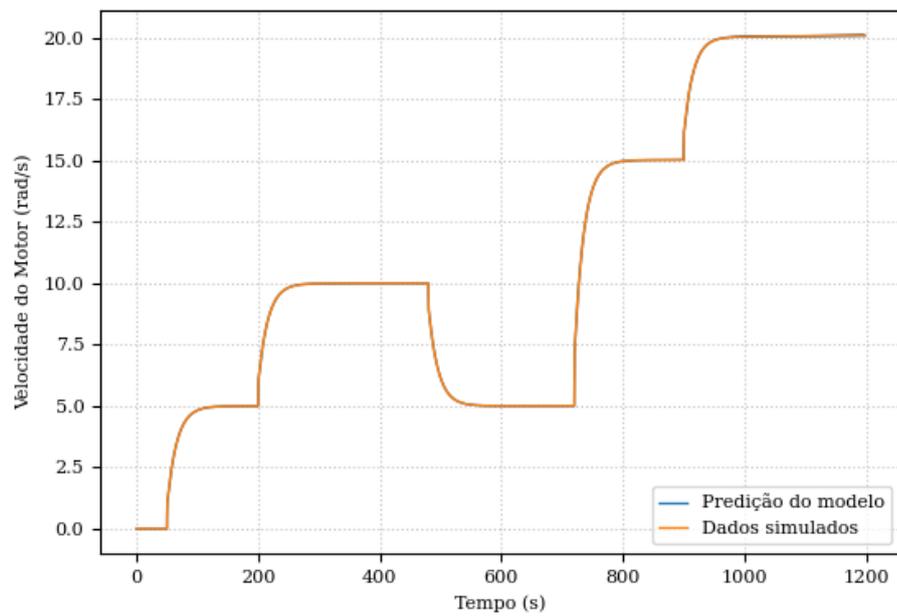
Em resumo, a resistência da armadura em um motor DC desempenha um papel crítico na performance do motor, com sua degradação potencialmente afetando de forma considerável a operação do sistema de controle. Diante desse cenário, o emprego do Gêmeo Digital é

Figura 16 – Erro de estimação relativo para a Resistência da armadura no cenário de degradação da resistência da armadura.



Fonte: elaborado pelo autor (2023)

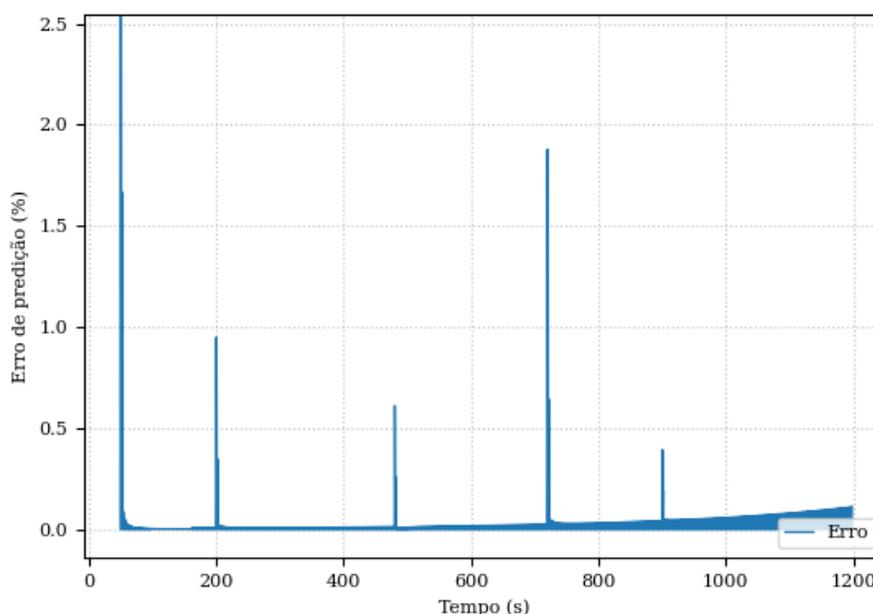
Figura 17 – Comparação entre saída de velocidade predita e adquirida do motor DC no cenário de degradação da resistência da armadura.



Fonte: elaborado pelo autor (2023)

demonstrado como uma ferramenta valiosa, nesse caso, não para o controle do sistema, mas para a compreensão profunda dos estados da máquina.

Figura 18 – Erro relativo entre saída de velocidade predita e aquirstada do motor DC no cenário de degradação da resistência da armadura.



Fonte: elaborado pelo autor (2023)

O Gêmeo Digital destaca-se por sua capacidade de rastrear precisamente o parâmetro em mutação - a resistência da armadura - ao longo do tempo. Isso proporciona uma representação confiável e interpretável da máquina, mesmo diante de variações significativas em seus parâmetros. A congruência entre a velocidade de saída prevista pelo Gêmeo Digital e a velocidade adquirida durante a simulação é um forte indicativo de sua eficácia. Essa alta fidelidade e a adaptabilidade do Gêmeo Digital mostram-se vitais em cenários reais, onde a previsão e o monitoramento do desgaste e falhas são essenciais para garantir uma operação segura e eficiente do sistema.

Por fim, os resultados aqui apresentados validam a eficácia do Gêmeo Digital na estimativa de parâmetros e na representação fiel do sistema físico. Ao acompanhar a degradação da resistência da armadura e adaptar-se a ela, o Gêmeo Digital confirma sua relevância e aplicabilidade em contextos reais, oferecendo um recurso valioso para o monitoramento, a previsão de desgastes e a manutenção preventiva.

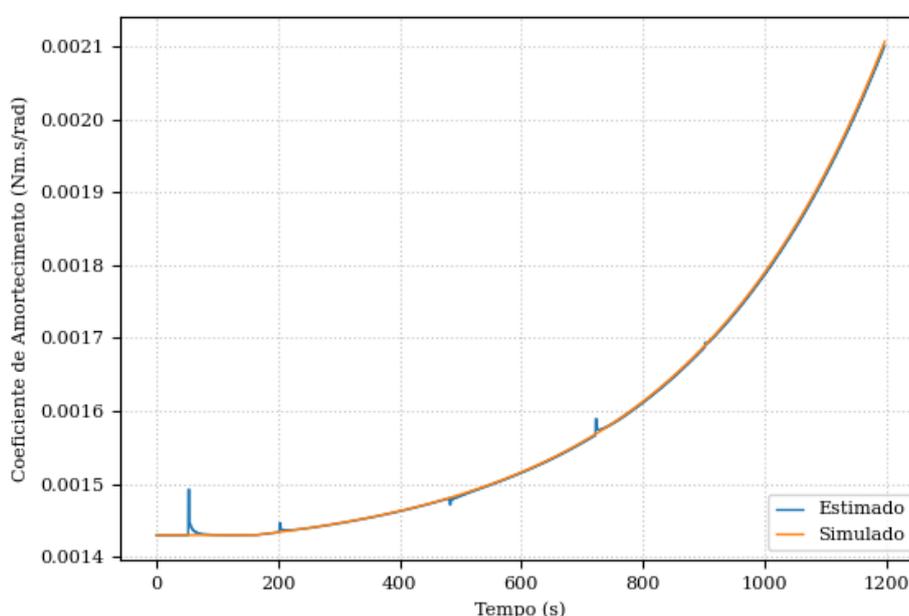
## 5.2.2 Desgaste do Rolamento

O desgaste dos rolamentos em um motor DC pode ter um impacto significativo no desempenho do sistema, afetando diretamente a eficiência energética, a velocidade de saída e,

consequentemente, a vida útil do motor. Diante disso, a análise se volta para a capacidade do Gêmeo Digital em estimar essas variações de maneira precisa e sua adaptabilidade às mesmas.

A Figura 19 mostra os valores estimados e simulados do coeficiente de amortecimento. Enquanto que a Figura 20 mostra o erro percentual na estimação. O coeficiente de amortecimento pode ser interpretado como uma representação da condição do rolamento, pois o desgaste do rolamento provoca um aumento nesse coeficiente, sinalizando que mais energia está sendo dissipada pelo sistema.

Figura 19 – Valores estimados e simulados do coeficiente de amortecimento no cenário de desgaste do rolamento.

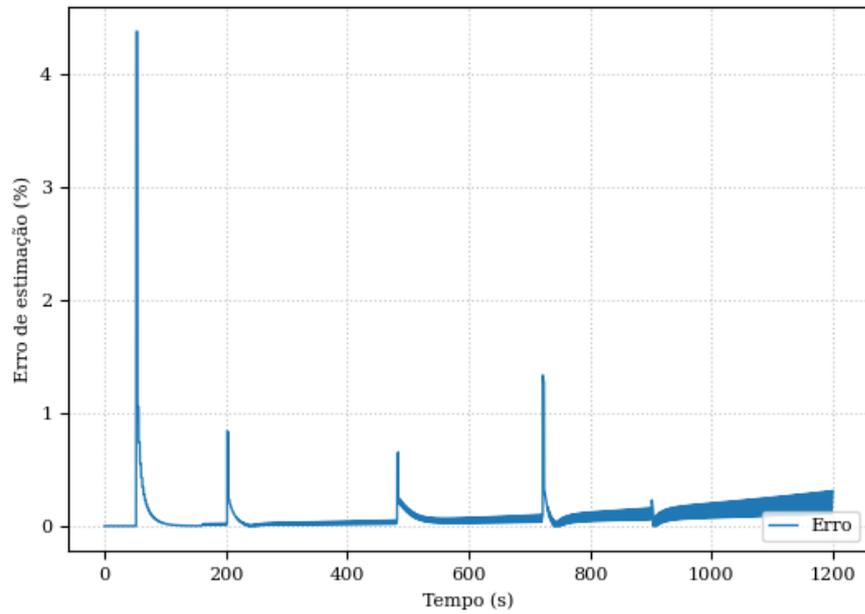


Fonte: elaborado pelo autor (2023)

Observamos que o Gêmeo Digital consegue estimar apropriadamente este coeficiente ao longo da simulação, com um erro geralmente abaixo de 0.5%. Alguns picos de erro são perceptíveis durante as mudanças de velocidade, no entanto, são corrigidos rapidamente, o que demonstra a resiliência e a confiabilidade do Gêmeo Digital. Por outro lado, se pode notar que a faixa de erro, ainda que pequena, se torna maior a medida que o desvio do coeficiente é mais acentuado, com a dinâmica do sistema mudando ao longo da aquisição, indicando que a estimação de parâmetros é desafiada por alterações mais abruptas ou não lineares no sistema.

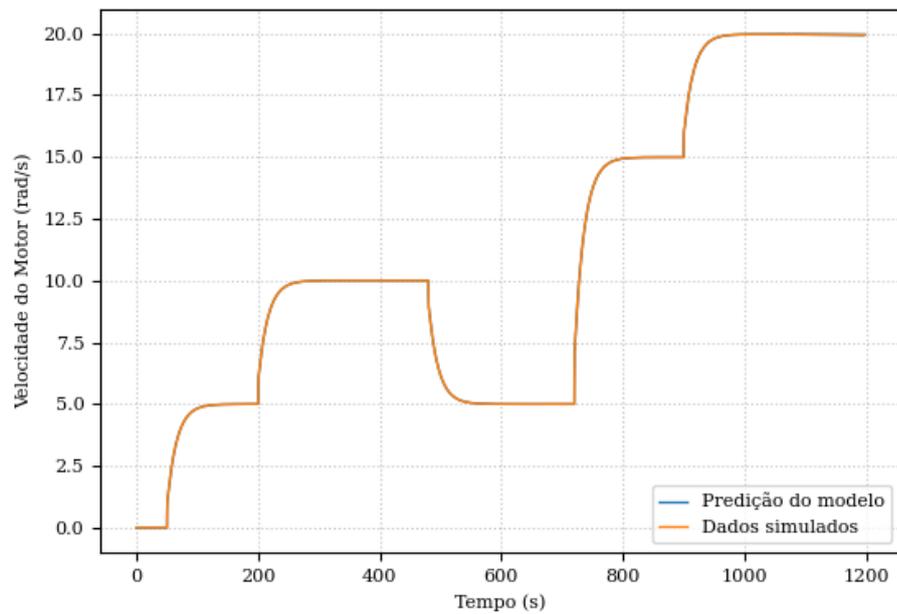
A Figura 21 mostra a comparação entre a velocidade de saída predita pelo Gêmeo Digital e a velocidade adquirida durante a simulação. A correspondência notável entre as duas reafirma a eficácia do método de estimação proposto, validando, mais uma vez, o uso do Gêmeo Digital como uma ferramenta confiável de monitoramento.

Figura 20 – Erro percentual na estimação do coeficiente de amortecimento no cenário de desgaste do rolamento.



Fonte: elaborado pelo autor (2023)

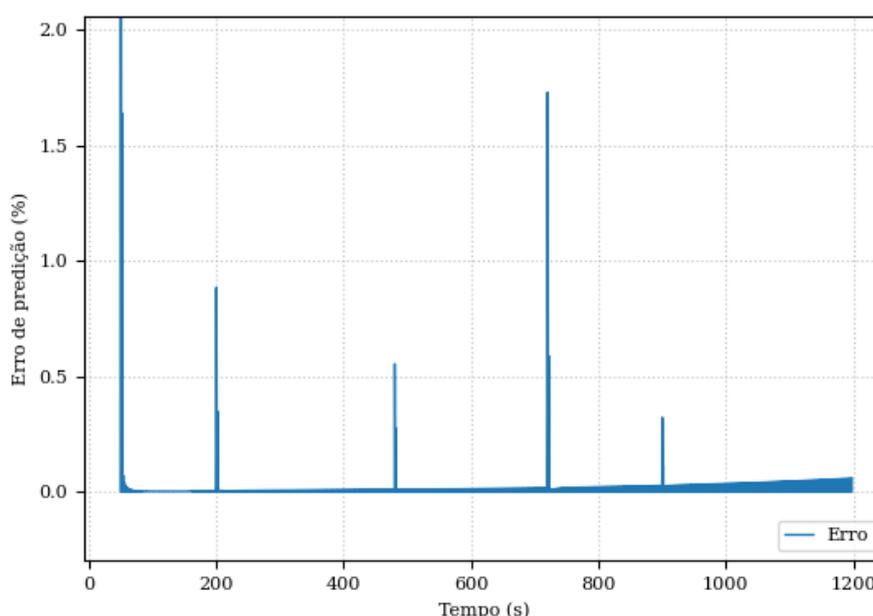
Figura 21 – Comparação entre a velocidade de saída predita e a adquirida no cenário de desgaste do rolamento.



Fonte: elaborado pelo autor (2023)

Finalmente, a Figura 22 ilustra o erro relativo de predição da saída do Gêmeo Digital em relação à saída simulada. Similar ao caso anterior, o erro relativo é predominantemente mantido abaixo de 1%, com alguns picos abaixo de 2.5% devido à mudança de velocidade que são prontamente corrigidos.

Figura 22 – Erro relativo na predição da velocidade de saída no cenário de desgaste do rolamento.



Fonte: elaborado pelo autor (2023)

O comportamento do erro relativo na predição da saída do Gêmeo Digital, mostra uma semelhança com as observações feitas anteriormente devido à natureza interdependente dos processos de estimação e predição no Gêmeo Digital. A precisão na predição do Gêmeo está intrinsecamente ligada à precisão da estimação, pois os valores estimados são utilizados como *inputs* no modelo adaptado para prever as saídas. Dessa forma, se a estimação do coeficiente ou de qualquer outra variável relevante não for precisa, isso terá um efeito cascata na precisão das predições do modelo.

Os picos observados no erro podem ser atribuídos a mudanças rápidas na dinâmica do sistema, especialmente nos degraus de velocidade. Tais mudanças podem desafiar a capacidade do Gêmeo Digital de se adaptar em tempo hábil, resultando em breves momentos de imprecisão. No entanto, é relevante notar que o modelo se auto-corrigue prontamente após essas perturbações, o que indica sua robustez e adaptabilidade diante de alterações nas condições operacionais.

A análise desses resultados revela o poder do Gêmeo Digital em proporcionar uma visão profunda da condição operacional do motor DC, particularmente no que se refere ao desgaste do rolamento. O Gêmeo Digital, através de sua capacidade de estimar com precisão o coeficiente de amortecimento, oferece uma medida quantitativa e dinâmica da condição do rolamento. Isso

permite um monitoramento contínuo e em tempo real de um parâmetro crucial da máquina ao longo de sua operação, um benefício trazido pela capacidade de estimação do Gêmeo Digital.

Isso é um indicativo da sua utilidade em contextos industriais para a detecção precoce de falhas e ações corretivas antes que o desempenho do sistema seja significativamente impactado. Com o Gêmeo Digital, é possível agir proativamente em vez de reativamente, o que pode levar a uma redução de tempo de inatividade e a economias significativas em termos de custos de manutenção e substituição de equipamentos.

Os resultados também destacam a adaptabilidade e a interpretabilidade do Gêmeo Digital. Apesar de picos de erro ocasionais em resposta às mudanças de velocidade, a rápida correção desses erros atesta a eficácia do Gêmeo Digital em se adaptar às mudanças dinâmicas na operação do sistema. A capacidade do Gêmeo Digital de se ajustar a estas variações não apenas reforça sua precisão, mas também facilita a compreensão dos eventos que ocorrem na máquina.

Isso é particularmente importante, pois a interpretabilidade é uma característica valiosa no campo do monitoramento da condição de máquinas. Ser capaz de entender o que está acontecendo com a máquina através do Gêmeo Digital permite que os técnicos, engenheiros e tomadores de decisão avaliem a situação de forma mais informada, contribuindo para uma operação mais segura e eficiente.

### 5.2.3 Desbalanceamento de Eixo

O desbalanceamento de eixo é uma condição comum que pode ocorrer em qualquer máquina rotativa, levando a um funcionamento irregular, aumentando as vibrações e reduzindo a vida útil do equipamento. Em muitos casos, pode ser difícil identificar esse problema apenas observando os parâmetros convencionais do motor. Por isso, é fundamental ter uma ferramenta capaz de identificar esses problemas ocultos para garantir a operação ideal do equipamento.

Quando introduzimos um erro senoidal de velocidade na simulação, descobrimos que a simples estimativa dos parâmetros não é suficiente para garantir o desempenho de previsão do modelo. Como pode ser observado na Figura 23, há uma discrepância significativa entre a velocidade de saída predita e a adquirida. Este resultado indica que há um componente não modelado, o que leva a uma degradação na qualidade da previsão.

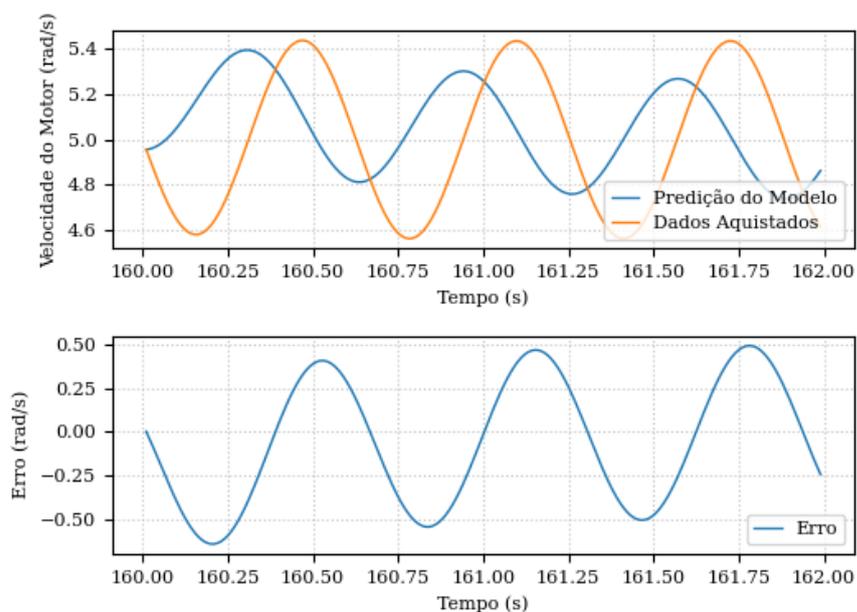
Entretanto, quando aplicamos o processo de descoberta de componentes desconhecidos, o Gêmeo Digital é capaz de identificar a presença de uma função periódica, indicativa do desbalanceamento de eixo. Com a descoberta deste componente, o Gêmeo Digital modifica o modelo da máquina e melhora significativamente seu desempenho de previsão.

O modelo complementar descoberto para essa janela de tempo de estimação é apresentado na equação 5.1:

$$f(t) = 4.91985774 * \sin(-9.97780433 * t - 0.46427915), \quad (5.1)$$

onde o custo calculado para a janela de otimização foi de 0.01620499, indicando uma boa correspondência entre o modelo atualizado e os dados observados.

Figura 23 – Comparação entre velocidade de saída predita e adquirida antes da descoberta de componentes desconhecidos.



Fonte: elaborado pelo autor (2023)

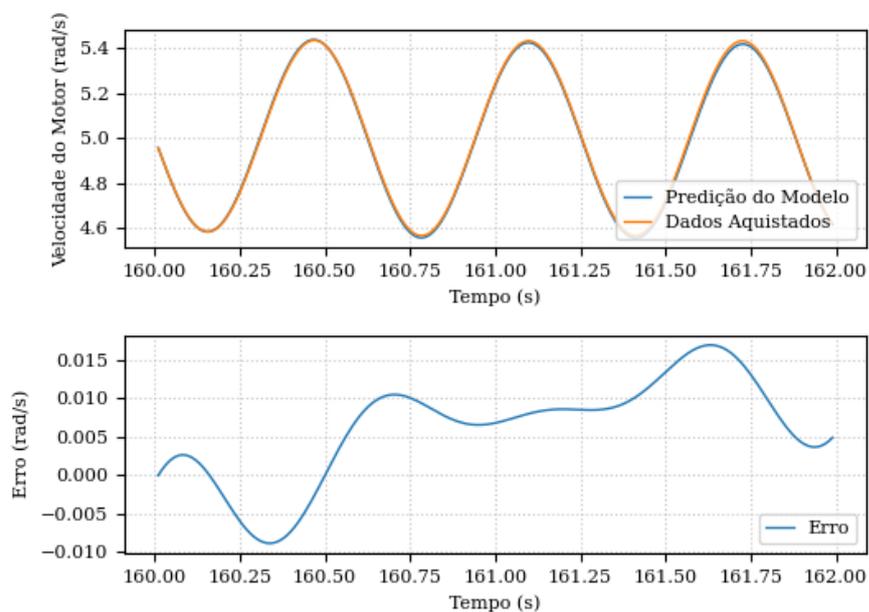
O Gêmeo Digital modifica o modelo da máquina para calcular a velocidade do motor no instante  $k$  pela equação 5.2, que é uma junção das equações 4.4 e 5.1.

$$\omega_k = \omega_{k-1} + T_s \cdot \frac{i_k \cdot K_t - T_{load} - D \cdot \omega_{k-1}}{J} + 4.91985774 * \sin(-9.97780433 * t - 0.46427915). \quad (5.2)$$

Com a inclusão deste novo componente no modelo, vemos que o desempenho da previsão melhora significativamente, como mostrado na Figura 24. O erro absoluto máximo é reduzido de 0.5rad/s para menos de 0.02rad/s, demonstrando a eficácia da descoberta de componentes desconhecidos para identificar e modelar problemas de desbalanceamento de eixo.

No âmbito do desbalanceamento de eixo, uma condição recorrente em máquinas rotativas, a capacidade do Gêmeo Digital em identificar e modelar componentes desconhecidos, como uma função periódica de certa amplitude e frequência, é de vital importância. Essa condição pode levar a um funcionamento irregular, intensificando as vibrações, e reduzindo a vida útil do equipamento. Portanto, a possibilidade de identificar e mitigar esses problemas latentes por meio do Gêmeo Digital proporciona uma oportunidade essencial para os engenheiros e operadores intervir de maneira eficaz.

Figura 24 – Comparação entre velocidade de saída predita e adquirida após a descoberta de componentes desconhecidos.



Fonte: elaborado pelo autor (2023)

Nesse sentido, a interpretabilidade do modelo atualizado é um trunfo valioso. Em cenários onde apenas a análise de parâmetros convencionais é realizada, tais falhas podem persistir até que resultem em interrupções críticas da operação. Contudo, ao incluir a função periódica representativa do desbalanceamento no modelo do Gêmeo Digital, aspectos anteriormente ocultos são revelados. Esta transparência, aliada à clareza do modelo, auxilia na identificação não só do fenômeno problemático (como a irregularidade da velocidade), mas também de sua causa raiz - neste caso, o desbalanceamento de eixo.

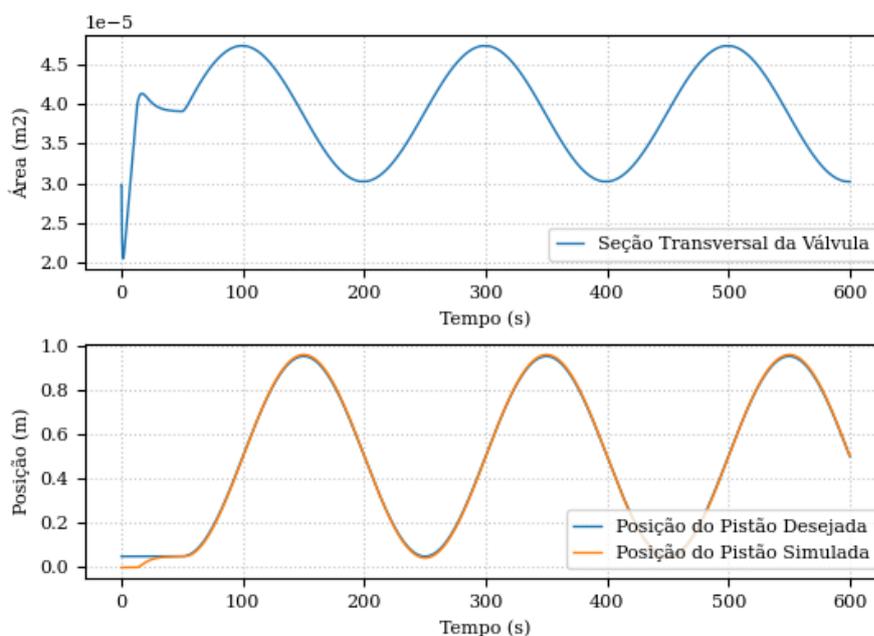
Especificamente, a magnitude e a frequência do componente desconhecido (desbalanceamento de eixo) descoberto são apresentadas explicitamente na função periódica integrada ao modelo. Essas informações podem ser utilizadas pelos operadores para determinar a gravidade do problema de desbalanceamento e tomar decisões adequadas de manutenção.

Os resultados desta análise enfatizam a importância da descoberta de componentes desconhecidos quando se trabalha com sistemas complexos, como motores DC. O Gêmeo Digital provou ser uma ferramenta valiosa não apenas para estimar parâmetros conhecidos, mas também para identificar e modelar componentes desconhecidos do sistema. Estas ferramentas não apenas melhoram a precisão das estimativas e a confiabilidade das previsões, mas também permitem uma operação e manutenção mais eficientes dos sistemas. Isso pode levar a economias significativas de recursos, maior segurança operacional e uma vida útil prolongada do equipamento.

## 5.3 Estudo de Caso 2: Atuador Hidráulico

Neste sistema hidráulico, a posição do atuador é controlado pela variação na seção transversal da válvula. A Figura 25 mostra a entrada de controle de posição do sistema, isto é, a seção transversal da válvula, e a posição desejada e simulada do atuador. Este perfil de posição desejada é utilizada ao longo das próximas avaliações.

Figura 25 – Controle de posição do atuador hidráulico.



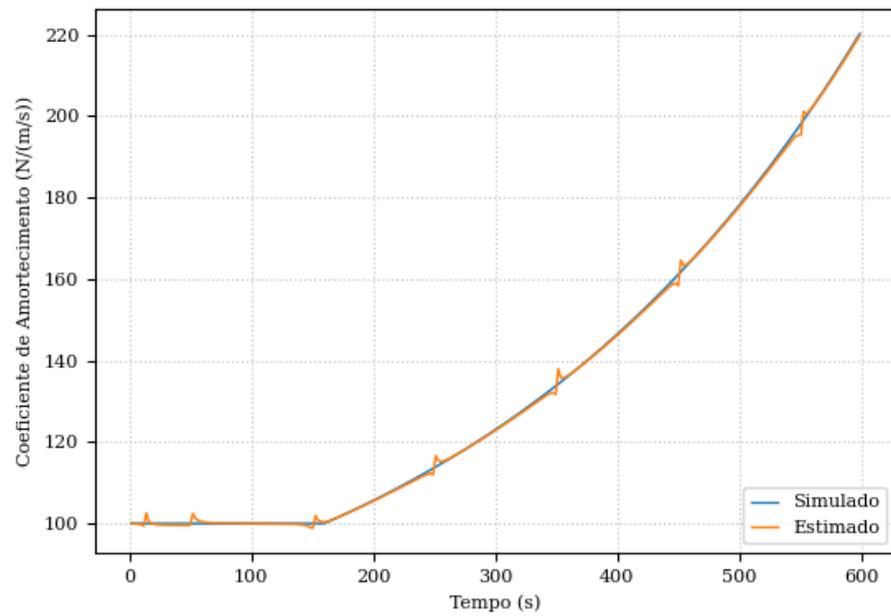
Fonte: elaborado pelo autor (2023)

O controle desenvolvido pode ser considerado como robusto e suficiente para adaptar as entradas do sistema e garantir que a posição desejada seja atingida mesmo em situações adversas. Com isso em mente, o foco da discussão será mantido não no controle do processo em si, mas nas possíveis implicações dos desvios dos parâmetros do sistema e condições de operação adversas, que podem ser interpretados como falhas ou futuras falhas da máquina.

### 5.3.1 Degradação do fluido hidráulico

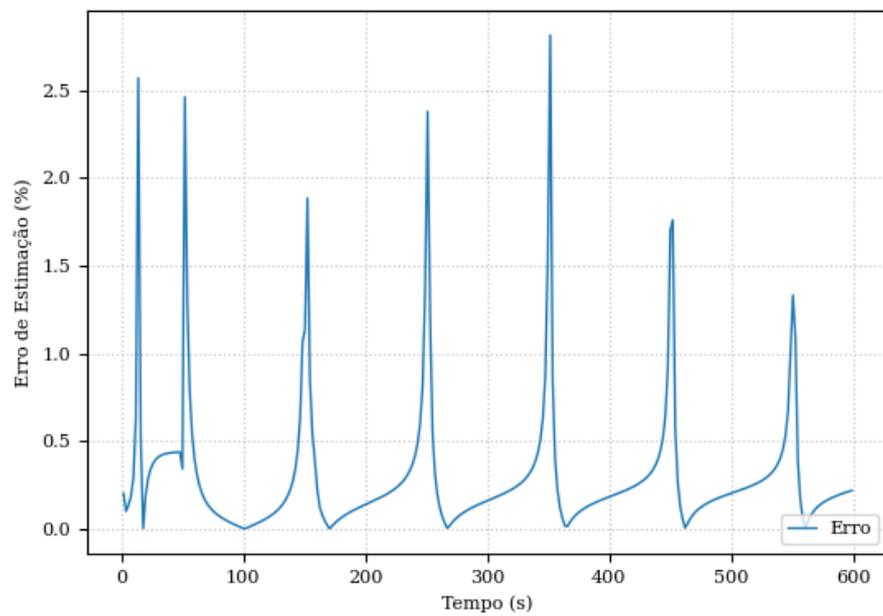
No primeiro cenário, investigamos o impacto da degradação do fluido hidráulico, um problema comum na operação de sistemas hidráulicos, que se manifesta como uma variação no coeficiente de amortecimento ao longo do tempo. A Figura 26 ilustra a evolução desse coeficiente, que começa a aumentar exponencialmente a partir dos 160 segundos, seguindo a função  $0.044 * \exp(0.003 * t) - 0.044$ . Esta é uma situação complexa que coloca à prova a capacidade do Gêmeo Digital de adaptar-se a variações dinâmicas nos parâmetros do sistema.

Figura 26 – Coeficiente de Amortecimento estimado e simulada.



Fonte: elaborado pelo autor (2023)

Figura 27 – Erro relativo de estimação do Coeficiente de Amortecimento.



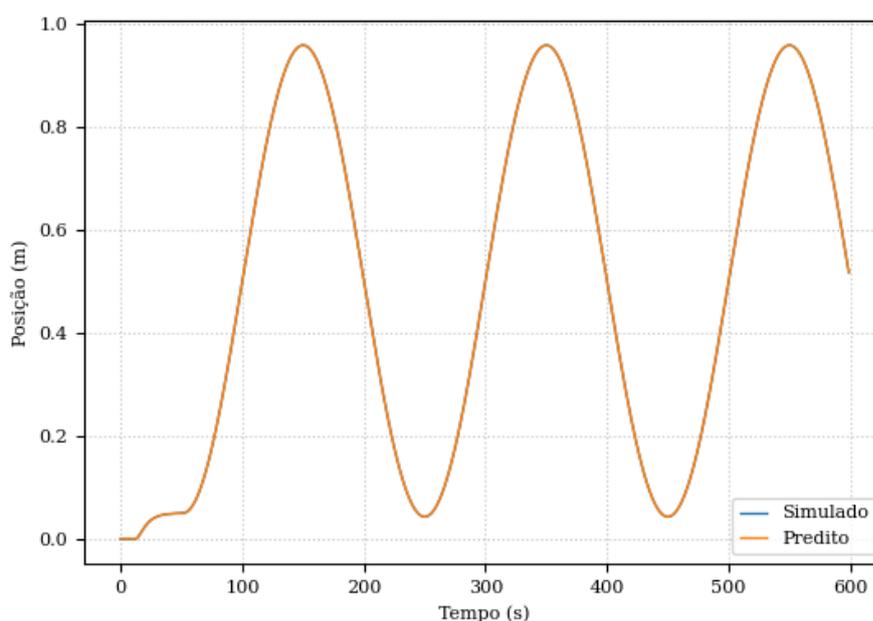
Fonte: elaborado pelo autor (2023)

O erro relativo de estimação do parâmetro ficou abaixo de 3% como mostrado na Figura 27. É importante notar que os picos no erro podem ser atribuídos ao comportamento

senoidal do sistema, com um maior erro observado quando a variação nos dados adquiridos é menor. Estes picos ocorrem precisamente quando o atuador atinge a amplitude máxima do movimento, evidenciado por um gradiente na função próximo a zero, um ponto desafiador nesse sistema.

Este primeiro cenário foi usado principalmente para avaliar a capacidade do Gêmeo Digital de se adaptar às mudanças no sistema. Nesse sentido, os resultados foram promissores. Mesmo com as alterações no coeficiente de amortecimento, o Gêmeo Digital conseguiu adaptar-se e continuar a fornecer previsões precisas para posição e a pressão do sistema como ilustrado nas Figuras 28 e 29.

Figura 28 – Posição simulada e predita pelo Gêmeo Digital para o cenário de modificação do coeficiente de amortecimento.



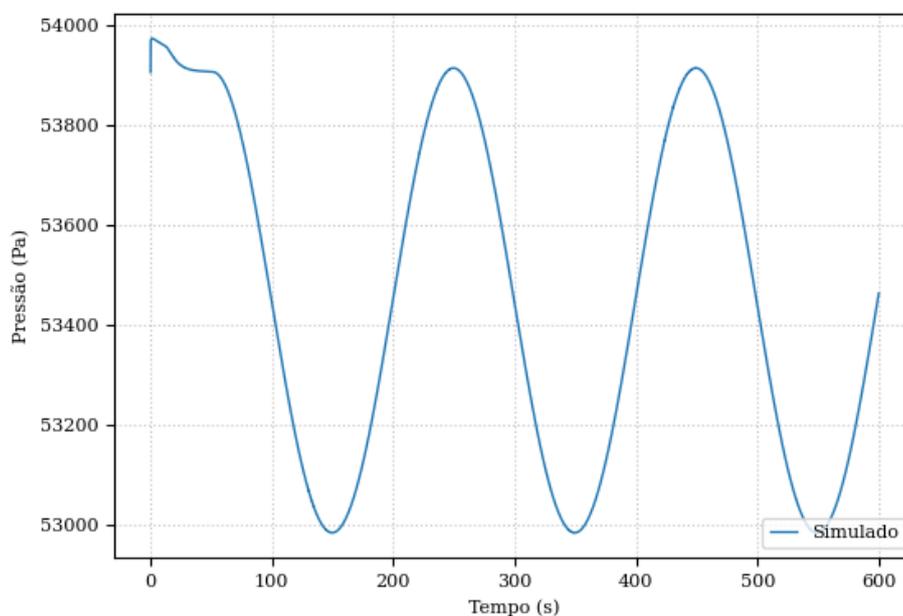
Fonte: elaborado pelo autor (2023)

Os resultados deste cenário evidenciam mais uma vez a eficácia da estimação de parâmetros do Gêmeo Digital em um ambiente de operação dinâmica. O desvio no coeficiente de amortecimento leva à interpretação de uma degradação do fluido hidráulico, uma condição que pode ter implicações significativas na operação de sistemas hidráulicos, isso reforça a aplicabilidade do Gêmeo Digital no gerenciamento de saúde de máquinas em ambientes industriais.

Esta aplicação é particularmente relevante em setores onde os equipamentos estão sujeitos a condições operacionais severas ou variáveis, como o setor de energia, mineração ou manufatura. Nestes contextos, a detecção precoce de problemas como a degradação do fluido hidráulico pode prevenir falhas catastróficas, reduzir os custos de manutenção e melhorar a segurança do

operador.

Figura 29 – Pressão simulada do sistema para o cenário de modificação do coeficiente de amortecimento.



Fonte: elaborado pelo autor (2023)

Adicionalmente, a eficácia do Gêmeo Digital em se adaptar a mudanças e fornecer previsões precisas pode ser explorada para o desenvolvimento de estratégias de manutenção preditiva. Com uma compreensão mais aprofundada das condições operacionais e dos parâmetros da máquina, as empresas podem otimizar seus programas de manutenção, programando intervenções baseadas em condições reais, em vez de estimativas grosseiras baseadas no tempo.

### 5.3.2 Vazamento interno

A seguir, apresentamos os resultados do segundo cenário, onde um componente de vazamento foi adicionado ao modelo. Este cenário é usado para testar a capacidade do Gêmeo Digital de identificar componentes desconhecidos, neste caso, um vazamento interno dentro do sistema hidráulico.

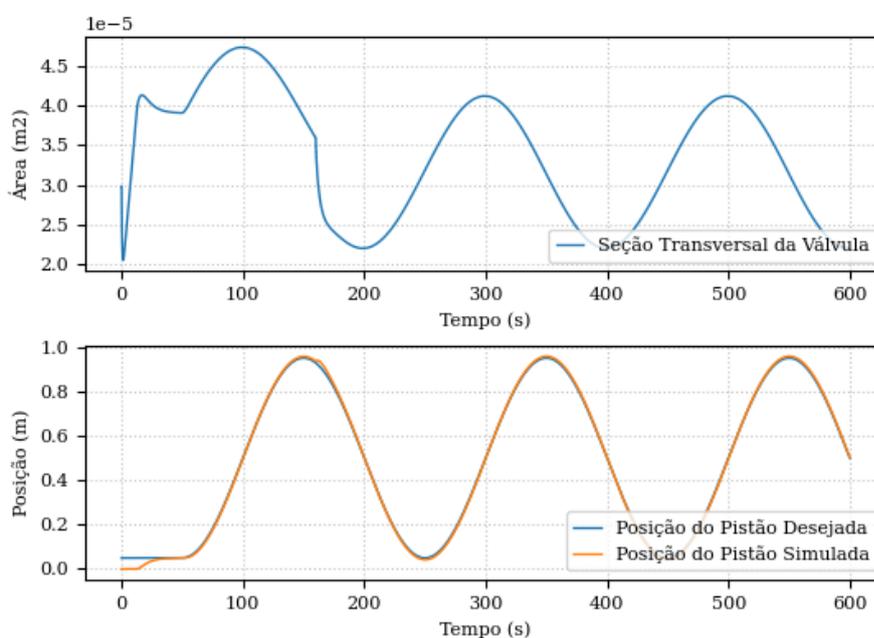
O coeficiente de vazamento foi estabelecido como um valor fixo no modelo de 0,2, influenciando a taxa de fluxo da válvula e a pressão geral do sistema. À medida que o vazamento aumenta, a pressão do sistema diminui, levando a mudanças na seção transversal da válvula e na posição do pistão.

Neste cenário, o fluxo de vazamento é computado através do coeficiente de vazamento e da pressão existente. Esse fluxo de vazamento é então subtraído do fluxo da válvula, resultando

em uma diminuição efetiva na taxa de fluxo da válvula. Isso tem impactos diretos tanto na posição do pistão quanto na pressão do sistema.

A Figura 30 mostra no primeiro gráfico a área da seção transversal da válvula durante a simulação. É possível observar as adaptações na seção transversal, especialmente no instante 160 s, para compensar o vazamento interno e manter a operação do sistema o mais próximo possível do desempenho desejado. O segundo gráfico, por outro lado, mostra a posição do pistão durante a simulação. Apesar do vazamento, o controle do sistema conseguiu manter a posição do pistão próxima ao valor desejado. No entanto há uma perda de eficiência no processo que precisa ser enfrentada.

Figura 30 – Modificação na seção transversal da válvula devido ao vazamento.

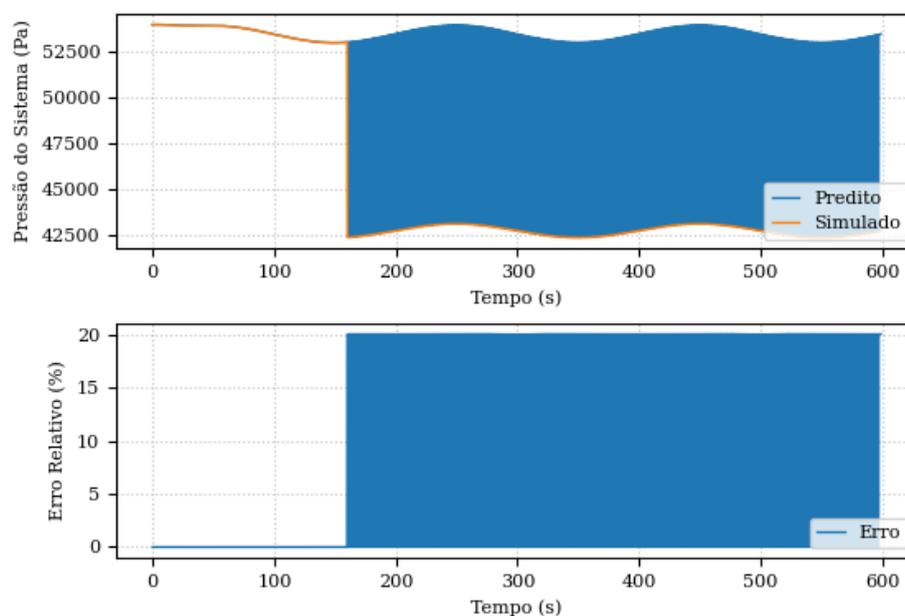


Fonte: elaborado pelo autor (2023)

De uma perspectiva externa, a primeira indicação de um problema no sistema pode ser simplesmente um aumento percebido no esforço para controlar a operação do sistema. Este aumento do esforço de controle é um sintoma de um problema subjacente - neste caso, o vazamento interno - e é crucial para identificar e resolver a causa raiz desse esforço adicional.

No topo, a Figura 31 apresenta a comparação entre os valores de pressão previstos pelo Gêmeo Digital e os valores simulados pelo sistema antes da descoberta de componentes desconhecidos, enquanto que no fundo temos o erro relativo entre a previsão e a pressão simulada. Os gráficos mostram uma grande variação na previsão da pressão do sistema pelo Gêmeo Digital, embora seja possível observar uma tendência geral da pressão no sistema, a estimação de parâmetros do modelo somente não é suficiente para eliminar as discrepâncias existentes nos dados. Estas diferenças destacam a necessidade de complementação do modelo existente.

Figura 31 – Pressão predita e simulada do sistema antes da Descoberta de Componentes Desconhecidos.



Fonte: elaborado pelo autor (2023)

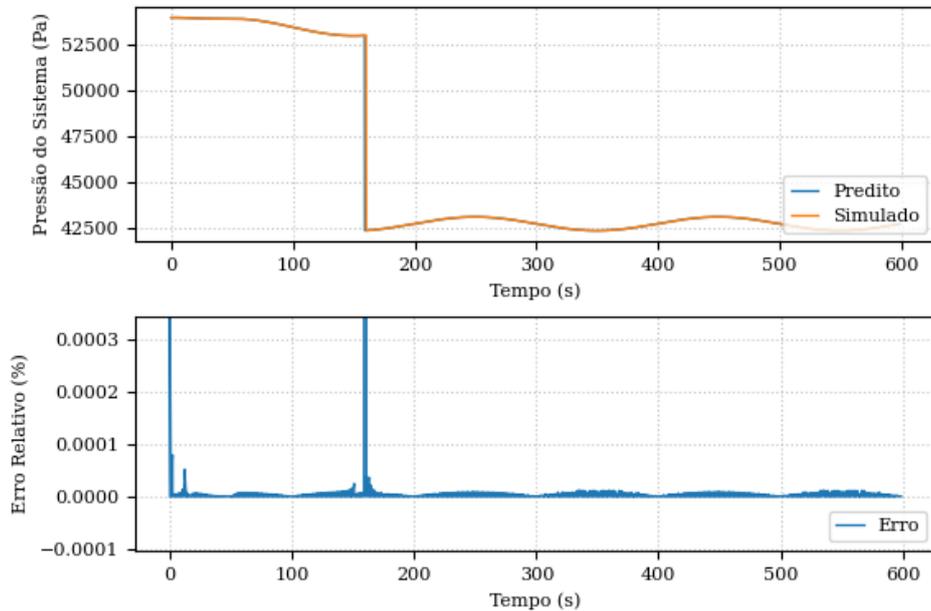
A Figura 32, por outro lado, mostra a mesma comparação de pressão depois de o Gêmeo Digital executar a descoberta de componentes desconhecidos. Novamente no topo temos as pressões predita e simulada, enquanto no fundo o erro relativo entre elas. É notável a melhoria na precisão das previsões, com o Gêmeo Digital agora sendo capaz de acompanhar as mudanças na pressão do sistema mais de perto. As curvas estão sobrepostas.

Em relação a posição do pistão do atuador, a Figura 33 exibe a comparação entre a posição prevista e a posição simulada do sistema antes da descoberta de componentes desconhecidos. Similarmente ao gráfico de pressão, observamos que existem algumas divergências entre as posições previstas e as reais: um ruído na forma senoidal da posição predita a partir do instante 160 s onde se iniciou a degradação do sistema.

A Figura 34 mostra a comparação da posição do sistema após a descoberta de componentes desconhecidos. Novamente, é evidente a melhoria na precisão das previsões, com o Gêmeo Digital demonstrando uma capacidade aprimorada de acompanhar as variações na posição do sistema.

Um detalhamento de uma janela de otimização de 2s pode ser visto na Figura 35, para a comparação entre a pressão prevista e a simulada antes da descoberta dos componentes. Enquanto que a Figura 36 detalha na mesma janela de otimização a mesma comparação depois da descoberta do componente. Ilustrando a diminuição do erro de previsão ao longo do processo de descoberta de componentes desconhecidos.

Figura 32 – Pressão predita e simulada do sistema após a Descoberta de Componentes Desconhecidos.



Fonte: elaborado pelo autor (2023)

A descoberta de componentes desconhecidos trouxe luz a um elemento crucial que não estava inicialmente presente no modelo. Esse componente foi incorporado na estrutura do modelo, desativando metamodelos menos significativos e refinando a simulação do sistema.

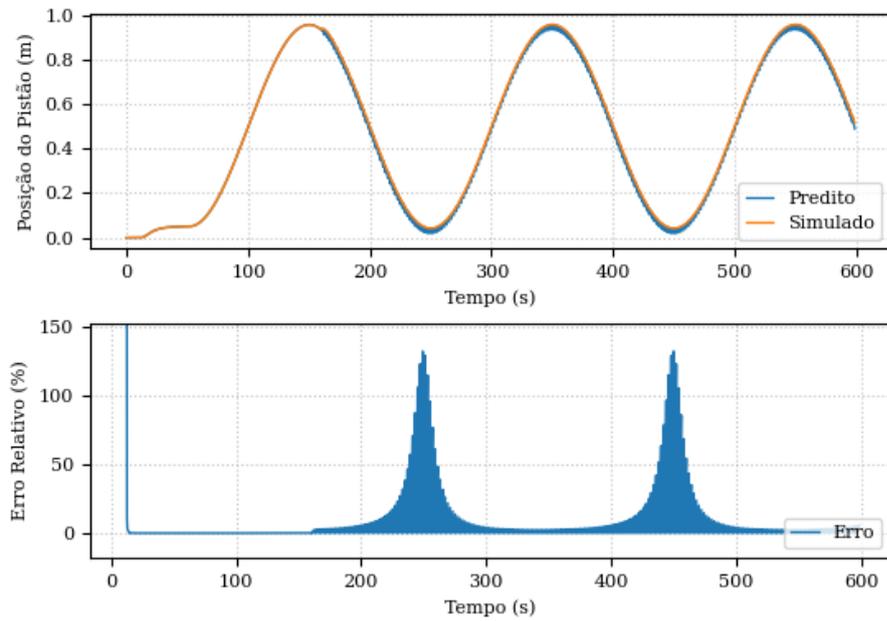
O modelo complementar descoberto para essa janela de tempo de estimação é mostrado na equação 5.3, onde  $C$  é o coeficiente angular da função linear descoberta, e a pressão do sistema se torna a entrada dessa função. A termo de interpretabilidade, o componente descoberto possui a forma de um vazamento interno do sistema hidráulico. Assim, este novo termo representa a taxa de fluxo devido ao vazamento no sistema, que é uma função da pressão atual *Pressure*.

$$C * Pressure \quad (5.3)$$

Com a adição deste componente, o Gêmeo Digital ajustou-se às novas condições do sistema, demonstrando sua capacidade de autoconsciência e adaptabilidade. O novo modelo descoberto pela adaptação do Gêmeo Digital atualiza a pressão do sistema através da equação 5.4, com  $p'_k$  indicando a saída do modelo fixo e  $p_k$  indicando a nova pressão de saída do sistema para o modelo adaptado. O custo calculado, uma métrica quantitativa da discrepância entre a saída prevista e a saída simulada do sistema, diminuiu para um valor absoluto para cada janela de otimização aproximado de 0.00047906.

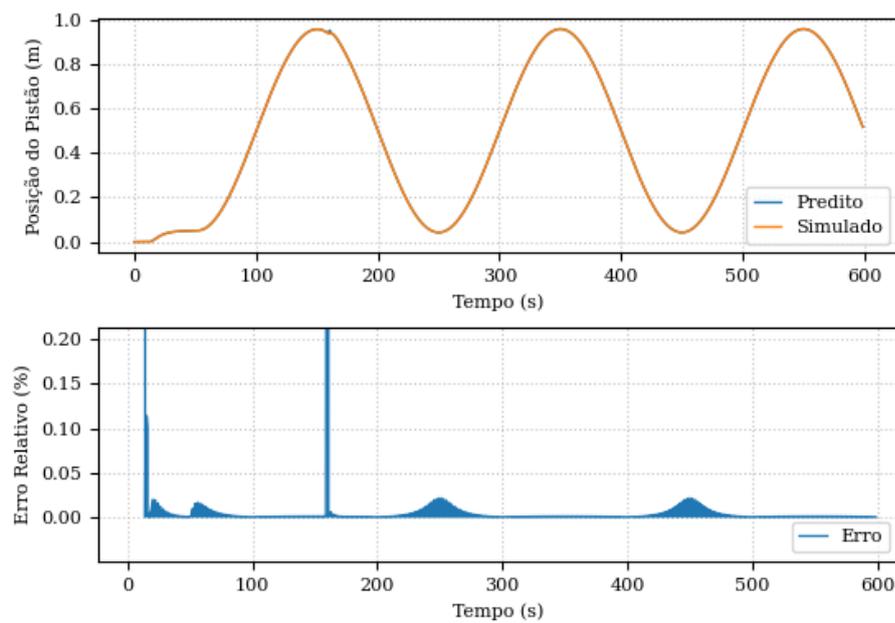
$$p_k = p'_k - 0.19999991 * p'_k \quad (5.4)$$

Figura 33 – Posição predita e simulada do pistão antes da Descoberta de Componentes Desconhecidos.



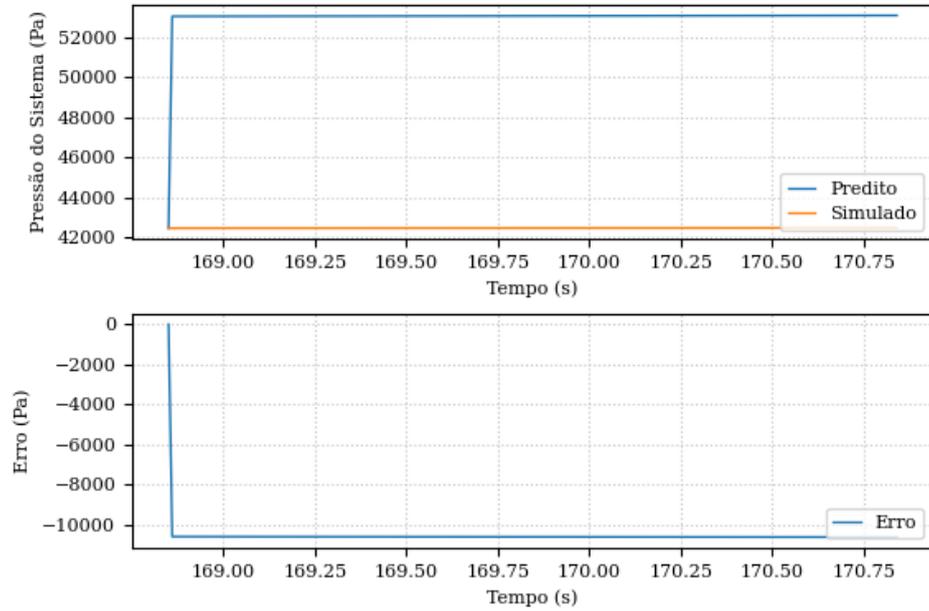
Fonte: elaborado pelo autor (2023)

Figura 34 – Posição predita e simulada do pistão após a Descoberta de Componentes Desconhecidos.



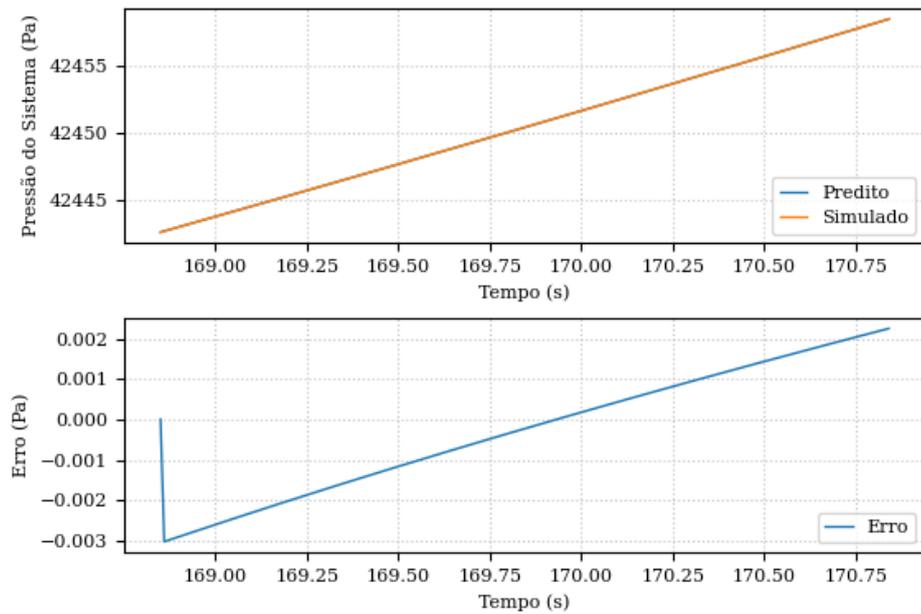
Fonte: elaborado pelo autor (2023)

Figura 35 – Antes: Detalhe para janela de otimização na previsão versus pressão simulada (a) e erro absoluto de previsão (b).



Fonte: elaborado pelo autor (2023)

Figura 36 – Depois: Detalhe para janela de otimização na previsão versus pressão simulada do sistema (a) e erro absoluto de previsão (b).



Fonte: elaborado pelo autor (2023)

A descoberta do componente desconhecido também ilustra a interpretabilidade proporcionada pelo Gêmeo Digital. Isto é, não se trata apenas de que o Gêmeo Digital identificou uma mudança, mas sim que o modelo adaptável final que ele provê é tal que os operadores (sejam humanos ou máquinas) podem interpretar essa mudança em termos dos componentes e operações do sistema. Neste sentido, o Gêmeo Digital não só sinalizou que o esforço de controle aumentou, mas forneceu um modelo em que a razão dessa mudança poderia ser corretamente identificada como um vazamento interno.

Este cenário reafirma a validade da terceira etapa da metodologia proposta - a Descoberta de Componentes Desconhecidos. O sistema em análise, ao experimentar um vazamento interno, passou por uma alteração que não estava presente no modelo inicial do Gêmeo Digital. Foi a Descoberta de Componentes Desconhecidos que permitiu ao Gêmeo Digital identificar essa mudança, adaptar-se a ela e, por fim, melhorar a precisão de suas previsões.

## 5.4 Análise do Tempo de Aquisição

Para aprofundar nosso entendimento sobre a importância do tempo de aquisição de dados na eficácia do modelo de Gêmeo Digital, conduzimos uma análise comparativa, explorando diferentes tempos de aquisição - 0.1s, 1s, 2s, 4s e 10s - e avaliando o impacto na estimativa no primeiro cenário de degradação no caso do motor DC: degradação da resistência da armadura.

No decorrer dos testes, foram ajustados os tempos de aquisição para os valores supracitados, mantendo-se as demais condições constantes. Com a finalidade de comparar o impacto do tempo de aquisição sobre a eficácia do Gêmeo Digital, monitoramos as métricas de desempenho, como o erro na estimativa de parâmetros e a qualidade do modelo gerado.

### 5.4.1 Degradação da Resistência da Armadura

A Figura 37 e a Figura 38 exibem, respectivamente, o erro absoluto e relativo da estimação de parâmetros para a degradação da resistência da armadura em diferentes tempos de aquisição. A partir dessas figuras, é possível observar que o erro de estimação tende a aumentar com o aumento do tempo de aquisição. Esse padrão sugere que um maior tempo de aquisição pode introduzir uma maior incerteza na estimativa dos parâmetros, potencialmente diminuindo a precisão do modelo de gêmeo digital.

No entanto, um aspecto interessante a se notar é que, apesar do aumento geral no erro de estimação, os picos de erro durante as mudanças de degrau de velocidade são atenuados à medida que o tempo de aquisição aumenta. Esta observação indica que um tempo de aquisição maior pode proporcionar uma certa "suavização" dos erros de estimação durante estas transições abruptas de velocidade, o que pode ser benéfico em certos cenários de aplicação.

Além disso, foi observada uma tendência de que o erro de estimação aumenta quanto

maior for o desvio no parâmetro entre uma janela de aquisição e a próxima. Esta tendência indica que variações bruscas nas condições de operação ou na saúde do motor podem levar a maiores erros de estimação, ressaltando a importância de estratégias eficazes de controle e manutenção para minimizar tais variações em aplicações reais.

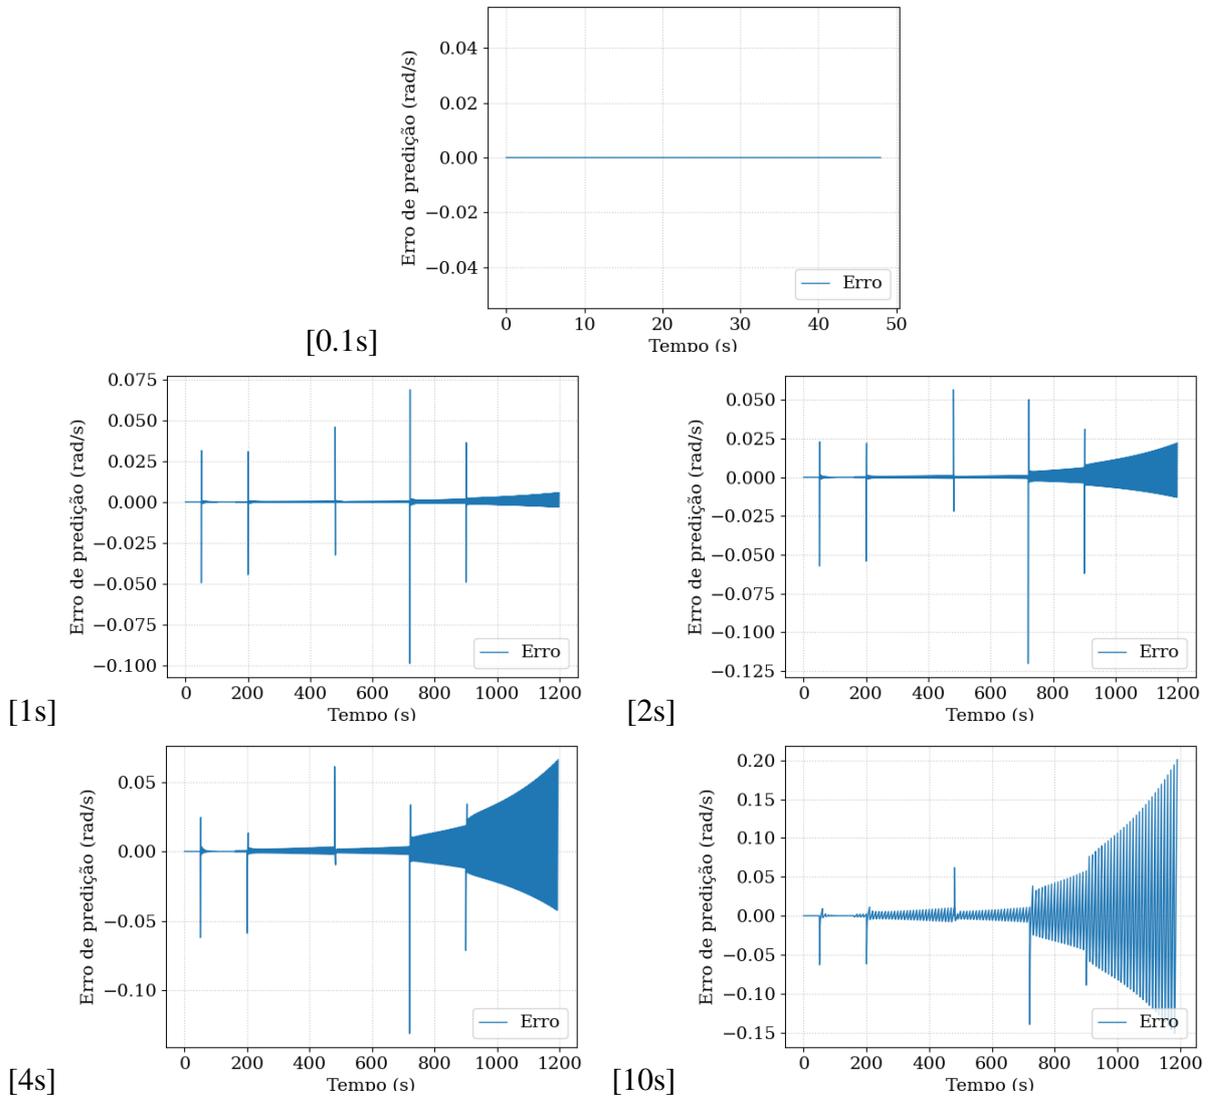


Figura 37 – Erro absoluto da estimação de parâmetros para a degradação da resistência da armadura em diferentes tempos de aquisição.

A Figura 39 mostra a comparação entre a velocidade de saída predita pelo modelo e a simulada. Este resultado evidencia que, devido ao erro de estimação ser relativamente pequeno, o erro na predição da velocidade de saída pelo modelo adaptado também se mantém reduzido. Esta eficácia na previsão persiste em todos os tempos de aquisição avaliados, o que destaca a robustez do Gêmeo Digital.

No entanto, é importante notar que o erro de predição torna-se mais significativo à medida que aumentamos o tempo de aquisição e o desvio no parâmetro entre uma janela de aquisição e a próxima. Este é um ponto crucial a ser considerado ao escolher o tempo de aquisição, já que uma

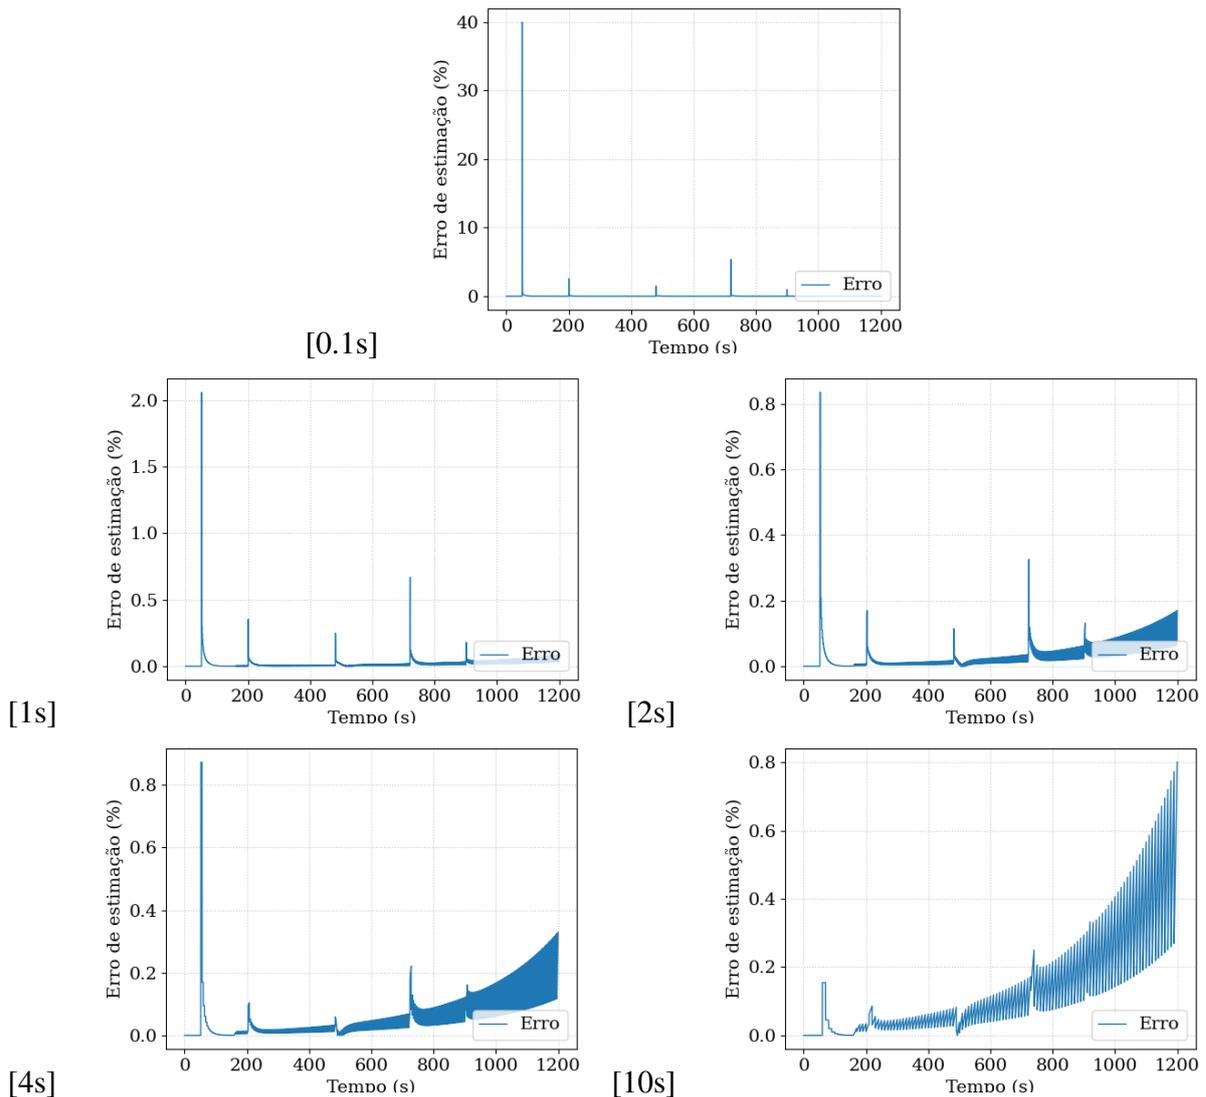


Figura 38 – Erro relativo da estimação de parâmetros para a degradação da resistência da armadura em diferentes tempos de aquisição.

grande variação no parâmetro ou um tempo de aquisição excessivamente longo podem resultar em previsões menos precisas.

Assim, a escolha do tempo de aquisição ideal pode necessitar de um equilíbrio entre a precisão desejada da estimativa do parâmetro e a capacidade de lidar eficazmente com transições abruptas de velocidade ou grandes variações no estado operacional ou de saúde do motor.

Apesar desses desafios, o Gêmeo Digital se mostrou altamente eficiente na previsão do comportamento do motor DC em todos os tempos de aquisição testados. Isso sugere que, com a escolha apropriada do tempo de aquisição, o Gêmeo Digital pode fornecer estimativas e previsões precisas em uma variedade de cenários e condições operacionais.

Contudo, é importante enfatizar que o tempo de aquisição adequado pode variar dependendo da aplicação e das características específicas de cada máquina. Assim, será necessária

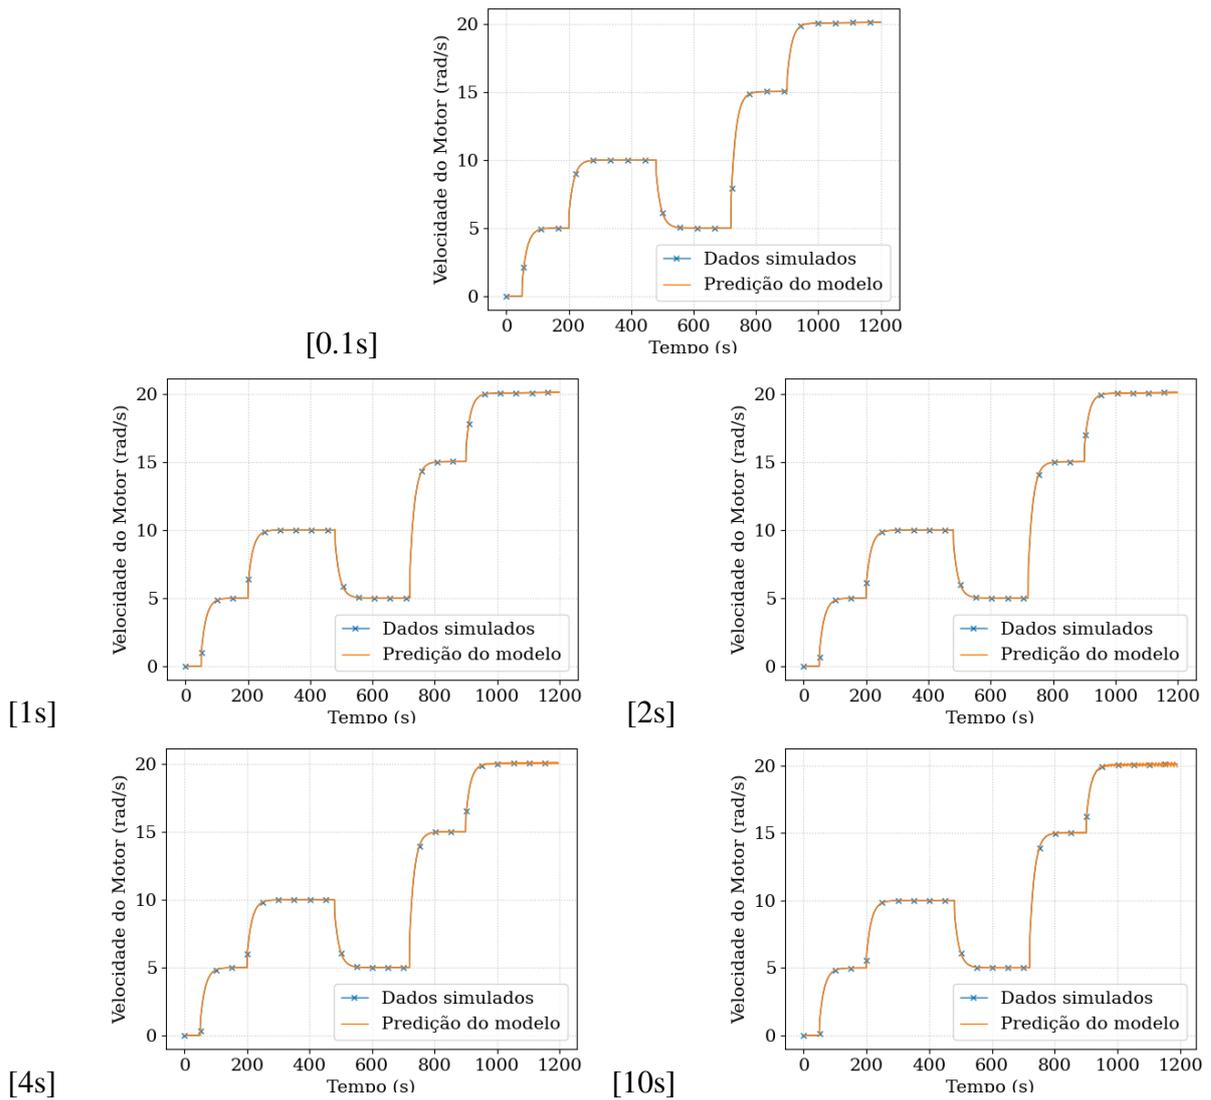


Figura 39 – Comparação entre a velocidade de saída predita pelo modelo e simulada.

uma investigação cuidadosa em cada caso para determinar o tempo de aquisição mais adequado que equilibre a precisão da estimativa de parâmetros e a eficácia da previsão do comportamento do motor.

## Capítulo 6

### Conclusão

Em conclusão, a pesquisa apresentada nesta dissertação enfatiza o grande potencial e a importância de combinar gêmeos digitais e métodos baseados em algoritmos PSO para melhorar a eficiência e o desempenho de diversas aplicações industriais. Este trabalho contribui para o campo emergente das máquinas autoconscientes, que, através do aprendizado e adaptação em tempo real, prometem aprimorar significativamente o desempenho das máquinas industriais. Em especial, a principal contribuição deste trabalho é a proposta e o desenvolvimento de uma metodologia robusta para a criação e implementação de gêmeos digitais interpretáveis e adaptáveis.

A metodologia proposta provou ser efetiva para desenvolver gêmeos digitais interpretáveis e adaptáveis em cenários controlados. Com essa metodologia, os gêmeos digitais demonstraram sua capacidade de acompanhar e ajustar-se dinamicamente às mudanças no sistema físico correspondente, evidenciando uma adaptabilidade de grande importância para uma variedade de aplicações industriais. A eficácia da metodologia foi validada em um ambiente de simulação, por meio de dois estudos de caso – um motor DC industrial e um atuador hidráulico – e mostrou-se capaz de funcionar eficazmente sob uma ampla variedade de condições. É importante salientar que, embora os estudos de caso sejam específicos, a metodologia tem o potencial de ser aplicada em uma gama mais ampla de sistemas e cenários, atendendo assim aos objetivos estabelecidos no início deste trabalho.

Outro ponto notável deste trabalho é a ênfase na interpretabilidade dos gêmeos digitais. A interpretabilidade é uma característica vital para garantir que os gêmeos digitais possam ser usados de maneira eficaz por engenheiros, técnicos e operadores de máquinas. Os gêmeos digitais desenvolvidos neste trabalho não apenas se adaptam e aprendem em tempo real, mas também fornecem *insights* valiosos e compreensíveis sobre o estado e o comportamento do sistema físico.

Os gêmeos digitais interpretáveis permitem que os operadores compreendam melhor o sistema físico, suas mudanças dinâmicas e os impactos potenciais de diferentes cenários de operação. Isso pode levar a melhores decisões de operação e manutenção, reduzindo potencialmente o tempo de inatividade e aumentando a eficiência operacional. Além disso, os gêmeos digitais

interpretáveis podem ser usados para treinamento, permitindo que os operadores compreendam melhor o sistema e respondam de forma mais eficaz em situações de emergência. Isso responde a uma necessidade crucial no campo por ferramentas que não só melhoram o desempenho das máquinas, mas também auxiliam na compreensão humana de sistemas complexos.

Os resultados deste trabalho destacam o grande potencial dos Gêmeos Digitais interpretáveis e adaptáveis, proporcionando uma base sólida para sua implementação em uma ampla gama de aplicações industriais. No âmbito da Manutenção Preditiva, eles oferecem capacidades sem precedentes para monitorar a saúde das máquinas em tempo real e prever possíveis falhas, abordando proativamente problemas potenciais antes que causem interrupções significativas. Isso reduz o tempo de inatividade, maximizando a eficiência operacional.

Além disso, os gêmeos digitais desempenham um papel crucial na Otimização de Design, permitindo que engenheiros testem diferentes modificações de design e avaliem o seu impacto no desempenho em um ambiente simulado. Essa capacidade facilita a experimentação e a inovação, sem arriscar a integridade ou a operação das máquinas reais. E, graças à sua habilidade de adaptar-se em tempo real, os gêmeos digitais também têm um papel importante nas Operações Autônomas. Eles podem ser usados para automatizar processos de tomada de decisão em aplicações industriais, oferecendo soluções em tempo real para questões emergentes, melhorando a eficiência operacional e a segurança.

A implementação dessas aplicações realça a versatilidade da metodologia proposta, bem como o seu potencial para transformar práticas industriais existentes. Assim, a continuidade dessa linha de pesquisa é promissora e pode trazer benefícios significativos em termos de eficiência, desempenho e segurança nas indústrias. Entretanto, a pesquisa tem suas limitações. A implementação dos gêmeos digitais requer dados de alta qualidade e a validação rigorosa dos modelos usados. Além disso, o desenvolvimento de máquinas autoconscientes exige uma cooperação interdisciplinar, combinando conhecimentos em campos diversos como aprendizado de máquina, teoria de controle, engenharia industrial, e mesmo psicologia cognitiva.

Um outro desafio observado nesta pesquisa é a alta demanda computacional dos algoritmos de otimização PSO. Embora isso possa tornar desafiadora a implementação em tempo real, a pesquisa demonstrou que, apesar dessa demanda computacional, a aplicação dos algoritmos PSO no Gêmeo Digital proposto trouxe uma melhoria considerável no desempenho das máquinas industriais nos cenários simulados. Portanto, os benefícios potenciais da implementação desta metodologia podem superar os desafios computacionais. E em aplicações de grande complexidade se pode considerar a paralelização do PSO.

Finalmente, argui-se que a junção de interpretabilidade, adaptabilidade e aprendizado em tempo real compõe uma base sólida para a implementação dos gêmeos digitais em uma vasta gama de aplicações industriais. Este é um campo promissor que pode trazer benefícios consideráveis em termos de eficiência, desempenho e segurança. Além disso, é importante ressaltar que este trabalho reforça a importância da colaboração interdisciplinar. A combinação

de conhecimentos em áreas como aprendizado de máquina, teoria de controle e engenharia industrial é essencial para o desenvolvimento de máquinas autoconscientes. Ao integrar essas disciplinas, a pesquisa contribui para a expansão e maturação deste campo interdisciplinar emergente, adensando o caminho para futuras inovações e aplicações industriais avançadas.

## 6.1 Trabalhos Futuros

Os resultados desta pesquisa abrem várias direções para trabalhos futuros:

1. A validação e aprimoramento da metodologia em aplicações físicas em tempo real é a principal linha de pesquisa a ser explorada. Embora os resultados obtidos por meio das simulações sejam promissores, a necessidade de avaliação desta metodologia em sistemas físicos, isto é, em condições não simuladas, é premente. As condições do mundo real podem apresentar complexidades e nuances que não são plenamente capturadas em um ambiente simulado. A verificação da metodologia em condições reais pode fornecer *insights* adicionais sobre como aprimorar e ajustar a metodologia visando um melhor desempenho e eficácia.
2. A extensão da funcionalidade dos gêmeos digitais para além da otimização de parâmetros e identificação de componentes. Em particular, a detecção de falhas usando gêmeos digitais é um campo promissor. Relacionar a variação dos parâmetros e a identificação de novos componentes com falhas específicas pode potencializar a capacidade de diagnosticar e prevenir falhas do sistema.
3. A integração dos gêmeos digitais ao processo de tomada de decisão, onde eles podem fornecer informações cruciais para otimizar decisões operacionais. A interpretabilidade dos gêmeos digitais, especialmente na descoberta de novos componentes, é um aspecto que merece maior investigação.
4. À medida que a disponibilidade de dados em tempo real e as capacidades computacionais avançam, surge uma significativa oportunidade para aprimorar a funcionalidade e eficácia dos gêmeos digitais adaptativos. Experimentar outras soluções analíticas e algoritmos heurísticos pode potencializar esses sistemas. Com esses avanços, os gêmeos digitais, conforme descritos, podem tornar-se uma abordagem valiosa para aplicações industriais reais.

Adicionalmente, ao longo das correções, algumas necessidades foram percebidas que podem ser incorporadas como trabalhos subsequentes:

- **Paralelização:** O aproveitamento de múltiplos processadores ou núcleos pode levar a um aumento considerável na eficiência dos gêmeos digitais, explorando em conjunto a paralelização dos algoritmos de enxames.
- **Redes de Controladores:** No contexto de ambientes industriais, o processamento distribuído é uma realidade crescente. Explorar como os gêmeos digitais podem ser incorporados nesse cenário é essencial.
- **Janelas adaptativas:** Considerando a dinâmica e a mudança constante dos sistemas, adaptar automaticamente a janela de aquisição para estimação dos parâmetros para melhor se ajustar às mudanças do sistema é uma abordagem que pode aumentar a eficiência dos gêmeos digitais, considerando os resultados apresentados sobre a variação no tempo de aquisição.

## Referências

- [1] BAHRIN, M.; OTHMAN, F.; AZLI, N.; TALIB, M. Industry 4.0: A review on industrial automation and robotic. *Jurnal Teknologi*, v. 78, 06 2016.
- [2] BROWN, R. J. *A Modern Introduction to Dynamical Systems*. [S.l.]: Oxford University Press, 2018.
- [3] KUHNLE, A.; KAISER, J.-P.; THEIß, F.; STRICKER, N.; LANZA, G. Designing an adaptive production control system using reinforcement learning. *Journal of Intelligent Manufacturing*, v. 32, 03 2021.
- [4] OGATA, K. *Modern Control Engineering*. Prentice Hall, 2010. (Instrumentation and controls series). ISBN 9780136156734. Disponível em: <<https://books.google.se/books?id=Wu5GpNAelzkC>>.
- [5] FULLER, A.; FAN, Z.; DAY, C.; BARLOW, C. Digital twin: Enabling technologies, challenges and open research. *IEEE Access*, v. 8, p. 108952–108971, 2020.
- [6] JAFARI, M.; KAVOUSI-FARD, A.; CHEN, T.; KARIMI, M. A review on digital twin technology in smart grid, transportation system and smart city: Challenges and future. *IEEE Access*, v. 11, p. 17471–17484, 2023.
- [7] van Dinter, R.; TEKINERDOGAN, B.; CATAL, C. Predictive maintenance using digital twins: A systematic literature review. *Information and Software Technology*, v. 151, p. 107008, 2022. ISSN 0950-5849. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950584922001331>>.
- [8] BARRICELLI, B. R.; CASIRAGHI, E.; FOGLI, D. A survey on digital twin: Definitions, characteristics, applications, and design implications. *IEEE Access*, v. 7, p. 167653–167671, 2019.
- [9] ZHUANG, J.; CHEN, Y.; CHEN, X. A new simplified modeling method for model predictive control in a medium-sized commercial building: A case study. *Building and Environment*, v. 127, p. 1–12, 2018. ISSN 0360-1323. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360132317304808>>.
- [10] LEWIS, P.; PLATZNER, M.; RINNER, B.; TORRESEN, J.; YAO, X. *Self-aware Computing Systems: An Engineering Approach*. [S.l.: s.n.], 2016. ISBN 978-3-319-39674-3.
- [11] KOZAK, S. State-of-the-art in control engineering. *Journal of Electrical Systems and Information Technology*, v. 1, p. 1–9, 05 2014.
- [12] RUGH, W.; SHAMMA, J. Research on gain scheduling. *Automatica*, v. 36, p. 1401–1425, 10 2000.

- [13] NORAMBUENA, M.; RODRIGUEZ, J.; ZHANG, Z.; WANG, F.; GARCIA, C.; KENNEL, R. A very simple strategy for high-quality performance of ac machines using model predictive control. *IEEE Transactions on Power Electronics*, v. 34, n. 1, p. 794–800, 2019.
- [14] CHEN, G.; PHAM, T. T. *Introduction to Fuzzy Sets, Fuzzy Logic, and Fuzzy Control Systems*. 1st. ed. [S.l.]: CRC Press, 2000.
- [15] SARANGAPANI, J. *Neural Network Control of Nonlinear Discrete-Time Systems*. CRC Press, 2018. (Automation and Control Engineering). ISBN 9781420015454. Disponível em: <<https://books.google.se/books?id=-WjLBQAAQBAJ>>.
- [16] PHANDEN, R. K.; SHARMA, P.; DUBEY, A. A review on simulation in digital twin for aerospace, manufacturing and robotics. *Materials Today: Proceedings*, v. 38, p. 174–178, 2021. ISSN 2214-7853. 2nd International Conference on Future Learning Aspects of Mechanical Engineering. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785320349245>>.
- [17] LI, L.; ASLAM, S.; WILEMAN, A.; PERINPANAYAGAM, S. Digital twin in aerospace industry: A gentle introduction. *IEEE Access*, v. 10, p. 9543–9562, 2022.
- [18] TAO, F.; ZHANG, H.; LIU, A.; NEE, A. Y. C. Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, v. 15, n. 4, p. 2405–2415, 2019.
- [19] GRIEVES, M. Digital twin: Manufacturing excellence through virtual factory replication. 03 2015.
- [20] GLAESSGEN, E.; STARGEL, D. The digital twin paradigm for future nasa and u.s. air force vehicles. In: . [S.l.: s.n.], 2012. ISBN 978-1-60086-937-2.
- [21] WEYER, S.; MEYER, T.; OHMER, M.; GORECKY, D.; ZÜHLKE, D. Future modeling and simulation of cps-based factories: an example from the automotive industry. *IFAC-PapersOnLine*, v. 49, n. 31, p. 97–102, 2016. ISSN 2405-8963. 12th IFAC Workshop on Intelligent Manufacturing Systems IMS 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896316328397>>.
- [22] GABOR, T.; BELZNER, L.; KIERMEIER, M.; BECK, M. T.; NEITZ, A. A simulation-based architecture for smart cyber-physical systems. In: *2016 IEEE International Conference on Autonomic Computing (ICAC)*. [S.l.: s.n.], 2016. p. 374–379.
- [23] ROSEN, R.; von Wichert, G.; LO, G.; BETTENHAUSEN, K. D. About the importance of autonomy and digital twins for the future of manufacturing. *IFAC-PapersOnLine*, v. 48, n. 3, p. 567–572, 2015. ISSN 2405-8963. 15th IFAC Symposium on Information Control Problems in Manufacturing. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896315003808>>.
- [24] RUSSELL, S.; NORVIG, P.; DAVIS, E. *Artificial Intelligence: A Modern Approach*. Prentice Hall, 2010. (Prentice Hall series in artificial intelligence). ISBN 9780136042594. Disponível em: <<https://books.google.se/books?id=8jZBksh-bUMC>>.
- [25] LJUNG, L. *System Identification: Theory for the User*. Prentice Hall PTR, 1999. (Prentice Hall information and system sciences series). ISBN 9780136566953. Disponível em: <<https://books.google.se/books?id=nHFoQgAACAAJ>>.

- [26] CLERC, M.; KENNEDY, J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 1, p. 58–73, 2002.
- [27] DENG, X. System identification based on particle swarm optimization algorithm. In: *2009 International Conference on Computational Intelligence and Security*. [S.l.: s.n.], 2009. v. 1, p. 259–263.
- [28] HOLZINGER, A.; BIEMANN, C.; PATTICHIS, C.; KELL, D. What do we need to build explainable ai systems for the medical domain? 12 2017.
- [29] GUIDOTTI, R.; MONREALE, A.; RUGGIERI, S.; TURINI, F.; GIANNOTTI, F.; PEDRESCHI, D. A survey of methods for explaining black box models. *ACM Comput. Surv.*, Association for Computing Machinery, New York, NY, USA, v. 51, n. 5, aug 2018. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/3236009>>.
- [30] TUEGEL, E. The airframe digital twin: Some challenges to realization. In: . [S.l.: s.n.], 2012. ISBN 978-1-60086-937-2.
- [31] SCHLUSE, M.; ROSSMANN, J. From simulation to experimentable digital twins: Simulation-based development and operation of complex technical systems. In: *2016 IEEE International Symposium on Systems Engineering (ISSE)*. [S.l.: s.n.], 2016. p. 1–6.
- [32] TAO, F.; ZHANG, M. Digital twin shop-floor: A new shop-floor paradigm towards smart manufacturing. *IEEE Access*, v. 5, p. 20418–20427, 2017.
- [33] JOHANSSON, R. *System Modeling and Identification*. Prentice Hall, 1993. (Information and system sciences series). ISBN 9780134823089. Disponível em: <<https://books.google.se/books?id=FZ7gAAAAMAAJ>>.
- [34] @MATLAB. *What is a Digital Twin?* 2019. <<https://www.youtube.com/watch?v=cfbKR48nSyQ>>. Accessed: 2023-07-10.
- [35] KARNOPP, D.; MARGOLIS, D.; ROSENBERG, R. *System Dynamics: Modeling, Simulation, and Control of Mechatronic Systems*. Wiley, 2012. (EngineeringPro collection). ISBN 9781118160077. Disponível em: <<https://books.google.se/books?id=rSVHAAAQBAJ>>.
- [36] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>.
- [37] CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, v. 20, n. 3, p. 273–297, 1995. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/BF00994018>>.
- [38] BREIMAN, L. Random forests. *Machine Learning*, v. 45, p. 5–32, 10 2001.
- [39] BREIMAN, L. *Classification and Regression Trees*. CRC Press, 2017. ISBN 9781351460491. Disponível em: <<https://books.google.se/books?id=MGIQDwAAQBAJ>>.
- [40] MURPHY, K. P. *Machine learning: a probabilistic perspective*. Cambridge, MA: [s.n.], 2012.
- [41] MOLNAR, C. *Interprtable machine learning: A guide for making black box models explainable*. 2018. Disponível em: <<https://christophm.github.io/interpretable-ml-book/>>.

- [42] DUDA, R.; HART, P.; STORK, D. *Pattern Classification*. Wiley, 2000. (11/04 16:50:48 GMT, pt. 1). ISBN 9780471056690. Disponível em: <[https://books.google.se/books?id=\\\_sO4DwAAQBAJ](https://books.google.se/books?id=\_sO4DwAAQBAJ)>.
- [43] ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3, n. 1, p. 28–44, 1973.
- [44] TAN, K.; LI, Y. Grey-box model identification via evolutionary computing. *Control Engineering Practice*, v. 10, n. 7, p. 673–684, 2002. ISSN 0967-0661. Developments in High Precision Servo Systems. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S096706610200031X>>.
- [45] SPONG, M.; HUTCHINSON, S.; VIDYASAGAR, M. *Robot Modeling and Control*. Wiley, 2005. (Wiley select coursepack). ISBN 9780471765790. Disponível em: <<https://books.google.se/books?id=muCMAAAACAAJ>>.
- [46] KHALIL, H. *Nonlinear Systems*. Prentice Hall, 2002. (Pearson Education). ISBN 9780130673893. Disponível em: <[https://books.google.se/books?id=t\\\_d1QgAACAAJ](https://books.google.se/books?id=t\_d1QgAACAAJ)>.
- [47] GOLNARAGHI, F.; KUO, B. *Automatic Control Systems, Tenth Edition*. McGraw Hill LLC, 2017. ISBN 9781259643842. Disponível em: <<https://books.google.se/books?id=RzsVDgAAQBAJ>>.
- [48] HESPANHA, J. *Linear Systems Theory: Second Edition*. Princeton University Press, 2018. ISBN 9781400890088. Disponível em: <<https://books.google.se/books?id=eDpDDwAAQBAJ>>.
- [49] HOUPIS, C.; SHELDON, S. *Linear Control System Analysis and Design with MATLAB®*. CRC Press, 2013. (Automation and Control Engineering). ISBN 9781466504271. Disponível em: <<https://books.google.se/books?id=R07OBQAAQBAJ>>.
- [50] BROCKWELL, P.; DAVIS, R. *Introduction to Time Series and Forecasting*. Springer, 2002. (Introduction to Time Series and Forecasting, v. 1-2). ISBN 9780387953519. Disponível em: <<https://books.google.se/books?id=VHB4OSAmwcUC>>.
- [51] MATHWORKS. *Nonlinear ARX and Hammerstein-Wiener Models*. 2023. Accessed: 2023-07-10. Disponível em: <<https://se.mathworks.com/help/ident/ref/idnlrx.html>>.
- [52] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. ISSN 1476-4687. Disponível em: <<https://doi.org/10.1038/nature14539>>.
- [53] CARUANA, R.; LOU, Y.; GEHRKE, J.; KOCH, P.; STURM, M.; ELHADAD, N. Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission. In: *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2015. (KDD '15), p. 1721–1730. ISBN 9781450336642. Disponível em: <<https://doi.org/10.1145/2783258.2788613>>.
- [54] BRUNTON, S. L.; PROCTOR, J. L.; KUTZ, J. N. Discovering governing equations from data by sparse identification of nonlinear dynamical systems. *Proceedings of the National Academy of Sciences*, v. 113, n. 15, p. 3932–3937, 2016. Disponível em: <<https://www.pnas.org/doi/abs/10.1073/pnas.1517384113>>.

- [55] KAISER, E.; KUTZ, J. N.; BRUNTON, S. L. Sparse identification of nonlinear dynamics for model predictive control in the low-data limit. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 474, n. 2219, p. 20180335, 2018. Disponível em: <<https://royalsocietypublishing.org/doi/abs/10.1098/rspa.2018.0335>>.
- [56] SILVA, B. M. de; HIGDON, D. M.; BRUNTON, S. L.; KUTZ, J. N. Discovery of physics from data: Universal laws and discrepancies. *Frontiers in Artificial Intelligence*, v. 3, 2020. ISSN 2624-8212. Disponível em: <<https://www.frontiersin.org/articles/10.3389/frai.2020.00025>>.
- [57] ANTONIOU, A.; LU, W. *Practical Optimization: Algorithms and Engineering Applications*. Springer US, 2007. ISBN 9780387711065. Disponível em: <<https://books.google.se/books?id=6\2RhaMFPLcC>>.
- [58] BERTSEKAS, D. *Nonlinear Programming*. Athena Scientific, 1999. (Athena scientific optimization and computation series). ISBN 9781886529007. Disponível em: <<https://books.google.se/books?id=TgMpAQAAMAAJ>>.
- [59] BOYD, S.; VANDENBERGHE, L. *Convex Optimization*. [S.l.]: Cambridge University Press, 2004.
- [60] BJÖRCK, A. *Numerical Methods for Least Squares Problems*. Society for Industrial and Applied Mathematics, 1996. (Handbook of Numerical Analysis). ISBN 9780898713602. Disponível em: <<https://books.google.se/books?id=ZecsDBMz5-IC>>.
- [61] RUDER, S. An overview of gradient descent optimization algorithms. 09 2016.
- [62] NOCEDAL, J.; WRIGHT, S. *Numerical Optimization*. Springer New York, 2006. (Springer Series in Operations Research and Financial Engineering). ISBN 9780387400655. Disponível em: <<https://books.google.se/books?id=VbHYoSyelFcC>>.
- [63] BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Comput. Surv.*, Association for Computing Machinery, New York, NY, USA, v. 35, n. 3, p. 268–308, sep 2003. ISSN 0360-0300. Disponível em: <<https://doi.org/10.1145/937503.937505>>.
- [64] YANG, X. *Nature-Inspired Optimization Algorithms*. Elsevier Science, 2014. (Elsevier insights). ISBN 9780124167452. Disponível em: <<https://books.google.se/books?id=BbHVAQAAQBAJ>>.
- [65] BONABEAU, E.; DORIGO, M.; THERAULAZ, G. *Swarm Intelligence: From Natural to Artificial Systems*. Oxford University Press, 1999. (Santa Fe Institute Studies on the Sciences of Complexity). ISBN 9780198030157. Disponível em: <<https://books.google.se/books?id=fcTcHvSsRMYC>>.
- [66] LIU, Y.; PASSINO, K.; POLYCARPOU, M. Stability analysis of m-dimensional asynchronous swarms with a fixed communication topology. *IEEE Transactions on Automatic Control*, v. 48, n. 1, p. 76–95, 2003.
- [67] YANG, X.-S.; DEB, S.; ZHAO, Y.; FONG, S.; XINGSHI, H. Swarm intelligence: Past, present & future. *Soft Computing*, v. 22, 09 2018.
- [68] DORIGO, M.; STÜTZLE, T. *Ant Colony Optimization*. The MIT Press, 2004. ISBN 9780262256032. Disponível em: <<https://doi.org/10.7551/mitpress/1290.001.0001>>.

- [69] KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*. [S.l.: s.n.], 1995. v. 4, p. 1942–1948 vol.4.
- [70] KARABOGA, D.; BASTURK, B. On the performance of artificial bee colony (abc) algorithm. *Applied Soft Computing*, v. 8, p. 687–697, 01 2008.
- [71] FILHO, C. J. A. B.; NETO, F. B. de L.; LINS, A. J. C. C.; NASCIMENTO, A. I. S.; LIMA, M. P. A novel search algorithm based on fish school behavior. In: *2008 IEEE International Conference on Systems, Man and Cybernetics*. [S.l.: s.n.], 2008. p. 2646–2651.
- [72] SCHWAAB, M.; Biscaia, Jr., E. C.; MONTEIRO, J. L.; PINTO, J. C. Nonlinear parameter estimation through particle swarm optimization. *Chemical Engineering Science*, v. 63, n. 6, p. 1542–1552, 2008. ISSN 0009-2509. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0009250907008755>>.
- [73] ZHA, F.; SHENG, W.; GUO, W.; QIU, S.; DENG, J.; WANG, X. Dynamic parameter identification of a lower extremity exoskeleton using rls-pso. *Applied Sciences*, v. 9, n. 2, 2019. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/9/2/324>>.
- [74] POLSENA, A.; KONGJEEN, Y.; WATCHARAKHUP, S. Identifying parameter and pi tuning of dc motor for predict behavior based on pso. In: *2021 9th International Electrical Engineering Congress (iEECON)*. [S.l.: s.n.], 2021. p. 97–100.
- [75] TAO, F.; CHENG, J.; QI, Q.; ZHANG, M.; ZHANG, H.; SUI, F. Digital twin-driven product design, manufacturing and service with big data. *The International Journal of Advanced Manufacturing Technology*, v. 94, n. 9, p. 3563–3576, 2018. ISSN 1433-3015. Disponível em: <<https://doi.org/10.1007/s00170-017-0233-1>>.
- [76] BRYLINA, O. G.; KUZMINA, N. N.; OSINTSEV, K. V. Modeling as the foundation of digital twins. In: *2020 Global Smart Industry Conference (GloSIC)*. [S.l.: s.n.], 2020. p. 276–280.
- [77] BOSCHERT, S.; ROSEN, R. Digital twin—the simulation aspect. In: \_\_\_\_\_. *Mechatronic Futures: Challenges and Solutions for Mechatronic Systems and their Designers*. Cham: Springer International Publishing, 2016. p. 59–74. ISBN 978-3-319-32156-1. Disponível em: <[https://doi.org/10.1007/978-3-319-32156-1\\_5](https://doi.org/10.1007/978-3-319-32156-1_5)>.
- [78] FAZDI, M. F.; HSUEH, P.-W. Parameters identification of a permanent magnet dc motor: A review. *Electronics*, v. 12, n. 12, 2023. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/12/12/2559>>.
- [79] WONOHADIDJOJO, D.; KOTHAPALLI, G.; HASSAN, M. Position control of electro-hydraulic actuator system using fuzzy logic controller optimized by particle swarm optimization. *International Journal of Automation and Computing*, v. 10, 06 2013.
- [80] WARGANTIWAR, N.; RAMBHAD, K.; BALLAMWAR, P. Hydraulic systems and hydraulic leakages - a review. *International Journal of Analytical, Experimental and Finite Element Analysis (IJAEFEA)*, v. 4, 01 2018.
- [81] JetBrains. *PyCharm: The Python IDE for Professional Developers*. 2023. Disponível em: <<https://www.jetbrains.com/pycharm/>>.
- [82] Python Software Foundation. *Python Programming Language*. 2023. Disponível em: <<https://www.python.org/>>.

- [83] HUNTER, J. D. Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, p. 90–95, 2007.
- [84] BLANK, J.; DEB, K. Pymoo: Multi-objective optimization in python. *IEEE Access*, v. 8, p. 89497–89509, 2020.
- [85] Python Software Foundation. *CSV File Reading and Writing*. 2023. Disponível em: <https://docs.python.org/3/library/csv.html>.
- [86] MELLOR, P. H. DC Motors for Electric Vehicle Propulsion. In: \_\_\_\_\_. *Electrical Machines and their Applications*. [S.l.]: Pergamon, 1990. p. 313–320.
- [87] KRISHNAN, R. *Electric Motor Drives: Modeling, Analysis, and Control*. Prentice Hall, 2001. ISBN 9780130910141. Disponível em: <https://books.google.se/books?id=1lgtAQAAMAAJ>.
- [88] PATRASCOIU, N. Modeling and simulation of the dc motor using matlab and labview. *International Journal of Engineering Education*, v. 21, p. 49–54, 01 2005.
- [89] KUTZ, J. *Data-Driven Modeling & Scientific Computation: Methods for Complex Systems & Big Data*. OUP Oxford, 2013. (Data-driven Modeling & Scientific Computation: Methods for Complex Systems & Big Data). ISBN 9780199660339. Disponível em: <https://books.google.se/books?id=WZMeAAAAQBAJ>.
- [90] MANRING, N. *Hydraulic Control Systems*. Wiley, 2005. ISBN 9780471693116. Disponível em: <https://books.google.se/books?id=yNQeAQAAIAAJ>.
- [91] JOKINEN, A.; CALONIUS, O.; PIETOLA, M.; GORLE, J. Effects of oil contamination level, flow rate and viscosity on pressure drop development and dirt holding capacity of hydraulic filter. In: AMERICAN SOCIETY OF MECHANICAL ENGINEERS. *Fluid Power Systems Technology*. [S.l.], 2019. v. 59339, p. V001T01A012.

# ANEXO A

## Publicação produzida

### A.1 Título

An Interpretable Digital Twin for Self-Aware Industrial Machines

### A.2 Autores

Adelson Santos da Silva Junior

João Luiz Vilar Dias

Prof. Fernando Buarque de Lima Neto

### A.3 *Abstract*

*This paper presents a proposed three-step methodology designed to enhance the performance and efficiency of industrial systems by integrating Digital Twins with particle swarm optimization (PSO) algorithms, while prioritizing interpretability. Digital Twins are becoming increasingly prevalent due to their capability to offer a comprehensive virtual representation of physical systems, thus facilitating detailed simulations and optimizations. Concurrently, PSO has demonstrated its effectiveness for real-time parameter estimation, especially in identifying both standard and unknown components that influence the dynamics of a system. Our methodology, as exemplified through a DC motor simulation, underscores the potential of Digital Twins to augment the self-awareness of industrial machines. The results indicate that our approach can proficiently optimize system parameters in real-time and unveil previously unknown components, thereby enhancing the adaptive capacities of the digital twin. While the reliance on accurate data to develop Digital Twin models is a notable consideration, the proposed methodology serves as a promising framework for advancing the efficiency of industrial applications. It further extends its relevance to fault detection and system control. Central to our approach is the emphasis*

*on interpretability, ensuring a more transparent understanding and effective usability of such systems.*

*Key Words: Digital Twin, Self-awareness, Industrial*

## **A.4 Evento**

*SSCI 2023 - IEEE Symposium Series on Computational Intelligence.*

## **A.5 Status**

SUBMETIDO