



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JOÃO VITOR RODRIGUES QUEIROZ

**CONTROLE DATA-DRIVEN: PROJETO DE CONTROLADOR UTILIZANDO O
MÉTODO VRFT APLICADO AO CONTROLE DE VELOCIDADE EM MOTOR DE
INDUÇÃO**

FORTALEZA

2025

JOÃO VITOR RODRIGUES QUEIROZ

CONTROLE DATA-DRIVEN: PROJETO DE CONTROLADOR UTILIZANDO O MÉTODO
VRFT APLICADO AO CONTROLE DE VELOCIDADE EM MOTOR DE INDUÇÃO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Wilkley Bezerra
Correia.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

Q44c Queiroz, João Vitor Rodrigues.

Controle Data-Driven: Projeto de controlador utilizando o método VRFT aplicado ao controle de velocidade em motor de indução / João Vitor Rodrigues Queiroz. – 2025.

71 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Elétrica, Fortaleza, 2025.

Orientação: Prof. Dr. Wilkley Bezerra Correia.

1. Data-driven. 2. Controle e sistemas. 3. VRFT. 4. Modelos de Referência. 5. Referência Virtual. I. Título.

CDD 621.3

JOÃO VITOR RODRIGUES QUEIROZ

CONTROLE DATA-DRIVEN: PROJETO DE CONTROLADOR UTILIZANDO O MÉTODO
VRFT APLICADO AO CONTROLE DE VELOCIDADE EM MOTOR DE INDUÇÃO

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Elétrica do
Centro de Tecnologia da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Engenharia Elétrica.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Wilkley Bezerra Correia (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Diego de Sousa Madeira
Universidade Federal do Ceará (UFC)

Prof. Dr. Domenico Sgro
Universidade Federal do Ceará (UFC)

Aos meus pais, pelo suporte incondicional dedicado a mim, por meio do esforço, da renúncia silenciosa e do amor inabalável, que moldaram quem sou e me permitiram chegar até aqui.

AGRADECIMENTOS

Primeiramente, agradeço a minha mãe Francisca Viviane Rodrigues e ao meu pai Antônio José Teixeira Queiroz, que nunca mediram esforços para garantir minha felicidade, bem-estar e pavimentaram todo o caminho para que eu pudesse correr atrás dos meus sonhos. Vocês são minha base e sustentação de vida, espero um dia conseguir retribuir um pouco do que fazem por mim.

Aos meus familiares, que são fundamentais em minha vida e minha fonte de força, em especial a minha vó Francisca Lúcia Rodrigues e a minha tia Francisca Daiane Rodrigues, obrigado por todo carinho cuidado e dedicação que têm comigo em todos os momentos.

Aos meus amigos, por toda lealdade, companheirismo e conselhos que me ajudaram em diversos momentos, são essenciais na minha caminhada para que conseguisse superar todos os obstáculos.

Ao meu orientador Professor Dr. Wilkley Bezerra Correia, por toda dedicação a me ensinar e orientar a seguir os melhores passos durante minha carreira acadêmica, sendo uma grante fonte de inspiração.

Ao Laboratório de Sistemas Motrizes (Lamotriz), que permitiu realizar, não só diversos trabalhos, como cativar amigos que foram fundamentais na minha vida universitária que irei levar para a vida, em especial agradeço aos meus amigos Gabriel Costa Leite e José Eduardo Holanda por toda parceria.

Por fim, agradeço a Universidade Federal do Ceará, por toda estrutura disponibilizada que possibilitou meu desenvolvimento profissional, acadêmico e pessoal.

"De tanto querer ser bom, misturei o céu com a terra, e por uma coisa à-toa levei meus anjos à guerra."

(Cecília Meireles, 1939, "Confissão")

RESUMO

Este trabalho apresenta a implementação do método *Virtual Reference Feedback Tuning* (VRFT), uma abordagem data-driven para o ajuste de um controlador Proporcional-Integral (PI) discreto, aplicado a um motor de indução trifásico. O estudo é conduzido por meio de ensaios experimentais realizados em uma bancada de laboratório, permitindo a avaliação prática do desempenho do controlador frente a diferentes modelos de referência de primeira ordem. Os ensaios consideram perturbações em degrau e senoidais, possibilitando uma análise comparativa do erro acumulado (Integral Absolute Error (IAE)) e da variação total do controle (Total Variation (TV)). Os resultados demonstram que a escolha do modelo de referência influencia diretamente a robustez do controle e a rejeição de perturbações, destacando a necessidade de um compromisso entre estabilidade, tempo de resposta e esforço de controle na sintonia do controlador.

Palavras-chave: *Data-driven*; Controle e sistemas; VRFT; Robustez; Modelos de Referência; Perturbação; Controle baseado em dados; Referência Virtual

ABSTRACT

This work presents the implementation of the Virtual Reference Feedback Tuning (VRFT) method, a data-driven approach for tuning a discrete PI controller, applied to a three-phase induction motor. The study is conducted through experimental tests performed in a laboratory bench, allowing a practical evaluation of the controller's performance against different first-order reference models. The tests consider step and sinusoidal disturbances, enabling a comparative analysis of the integral of absolute error (IAE) and total variation of control (TV). The results demonstrate that the choice of the reference model directly influences the control robustness and disturbance rejection, highlighting the need for a trade-off between stability, response time, and control effort in controller tuning.

Keywords: Data-driven; Control and Systems; VRFT; Robustness; Reference Models; Disturbance; Data-Based Control, Virtual Reference;

LISTA DE FIGURAS

Figura 1 – Sistema de Controle	22
Figura 2 – Comparação entre as funções custo (J_y x J_{VR})	24
Figura 3 – Topologia de ensaio VRFT	24
Figura 4 – Esquemático - Disposição dos motores	35
Figura 5 – Foto real da disposição de motores	36
Figura 6 – Inversor Siemens - SINAMICS G120 PM250	37
Figura 7 – Inversor Telemecanique - ATV31HU11N4A	38
Figura 8 – Torquímetro utilizado na bancada	39
Figura 9 – Placa NIDAQ - NI 6221	40
Figura 10 – Esquemático completo da bancada de trabalho	42
Figura 11 – Bancada de trabalho real	42
Figura 12 – Resultado do experimento para modelo de referência m_1 com perturbação em degrau	45
Figura 13 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação em degrau para m_1	46
Figura 14 – Resultado do experimento para modelo de referência m_2 com perturbação em degrau	47
Figura 15 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação para m_2 com perturbação em degrau.	47
Figura 16 – Resultado do experimento para modelo de referência m_3 com perturbação em degrau	48
Figura 17 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação para m_3 com perturbação em degrau	49
Figura 18 – Perturbação de caráter senoidal aplicada	50
Figura 19 – Resultado do experimento para modelo de referência m_1 em perturbação senoidal	51
Figura 20 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_1	51
Figura 21 – Resultado do experimento para modelo de referência m_2 em perturbação senoidal	53

Figura 22 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_2	53
Figura 23 – Resultado do experimento para modelo de referência m_3 em perturbação senoidal	55
Figura 24 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_3	55

LISTA DE TABELAS

Tabela 1 – Especificações elétricas dos motores da bancada	35
Tabela 2 – Especificações elétricas do inversor Siemens SINAMICS G120 PM250 . . .	36
Tabela 3 – Especificações Nominais do Inversor ATV31HU11N4A	37
Tabela 4 – Dados nominais do torquímetro TM Series - Modelo 307	39
Tabela 5 – Características da placa NI PCI/PXI/USB-6221	40
Tabela 6 – Modelos de referência e tempos de acomodação	44
Tabela 7 – Modelos de referência e controladores ajustados	44
Tabela 8 – Métricas de desempenho para Modelo de Referência m_1 com perturbação em degrau	46
Tabela 9 – Métricas de desempenho para Modelo de Referência m_2 com perturbação em degrau	48
Tabela 10 – Métricas de desempenho para Modelo de Referência m_3 com perturbação em degrau	49
Tabela 11 – Métricas de desempenho para Modelo de Referência m_1 em perturbação senoidal	52
Tabela 12 – Métricas de desempenho para Modelo de Referência m_2 em perturbação senoidal	54
Tabela 13 – Métricas de desempenho para Modelo de Referência m_3 em perturbação senoidal	56

LISTA DE ABREVIATURAS E SIGLAS

DDC	<i>Data-Driven Control</i>
IAE	Integral Absolute Error
IFT	<i>Iterative Feedback Tuning</i>
LQR	<i>Linear Quadratic Regulator</i>
MBC	<i>Model-Based Control</i>
MFAC	<i>Model-Free Adaptive Control</i>
NI	National Instruments
PD	Proporcional-Derivativo
PI	Proporcional-Integral
PID	Proporcional-Integral-Derivativo
PRBS	Pseudo-Random Binary Sequence
TV	Total Variation
VRFT	<i>Virtual Reference Feedback Tuning</i>

LISTA DE SÍMBOLOS

$G(z)$	Função de transferência da planta no domínio z
$C(z, \rho)$	Função de transferência do controlador parametrizado
$M(z)$	Função de transferência do modelo de referência
$T(z, \rho)$	Função de transferência em malha fechada
$r(k)$	Sinal de referência discreto no instante k
$y(k)$	Saída do sistema no instante k
$u(k)$	Sinal de controle aplicado ao sistema no instante k
$e(k)$	Erro de seguimento no instante k
ρ	Vetor de parâmetros do controlador
$\ H(e^{j\omega})\ _2^2$	Norma H_2 , utilizada para medir a energia da resposta ao impulso do sistema
$\phi(k)$	Vetor de regressores no instante k
$S(e^{j\omega}, \rho)$	Função de sensibilidade do sistema em função da frequência ω e dos parâmetros ρ
$S_d(e^{j\omega})$	Função de sensibilidade desejada do sistema
$\tilde{e}(k)$	Erro virtual no instante k
$\tilde{r}(k)$	Referência virtual no instante k
$\Delta u(k)$	Variação do sinal de controle entre os instantes k e $k + 1$
τ	Variável de tempo contínuo
n	Número total de amostras consideradas na análise discreta
$L(z)$	Filtro utilizado para garantir equivalência entre critérios de minimização
$J_y(\rho)$	Função de custo baseada no erro de seguimento da trajetória
$J_{VR}(\rho)$	Função de custo baseada na minimização do controlador ideal
$C_d(z)$	Controlador ideal para o sistema
$X(e^{j\omega})$	Transformada de Fourier do sinal $x(t)$
$\Phi_r(e^{j\omega})$	Espectro do sinal de referência no domínio da frequência
$\Phi_u(e^{j\omega})$	Espectro do sinal de entrada aplicado ao sistema no domínio da frequência
T_m	Torque medido pelo torquímetro (N·m)

n_m	Velocidade de rotação medida pelo torquímetro (rpm)
P_n	Potência nominal do motor (W ou kW)
V_n	Tensão nominal do motor (V)
I_n	Corrente nominal do motor (A)
f_n	Frequência nominal do motor (Hz)
T_n	Torque (conjugado) nominal do motor (N·m ou kgf·m)
T_p	Torque de partida do motor (N·m ou kgf·m)
T_{\max}	Torque máximo do motor (N·m ou kgf·m)
I_p	Corrente de partida do motor (A)
J	Momento de inércia do rotor (kg·m ²)
η	Rendimento (eficiência) do motor
λ	Fator de potência do motor

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Metodologia	15
2	VIRTUAL REFERENCE FEEDBACK TUNING (VRFT)	18
2.1	Introdução ao Controle Data-Driven	18
2.2	MBC x Data-Driven Control	18
2.3	Principais técnicas <i>Data-driven</i>	20
2.4	Fundamentos do VRFT	21
2.5	Projeto do Controlador com base na referência de virtual	24
2.6	Sintonia do Controlador	26
2.7	Implementação do VRFT	32
3	DESCRIÇÃO DA BANCADA	34
3.1	Motores da Bancada Experimental	34
3.2	Inversores de Frequência	36
3.3	Aquisição e Envio de Dados	38
3.4	Acionamento da Bancada	41
4	RESULTADOS	43
4.1	Cenário com perturbação em degrau	45
4.2	Cenário com perturbação senoidal	50
4.3	Considerações Finais	56
5	CONCLUSÕES E TRABALHOS FUTUROS	58
	REFERÊNCIAS	60
	APÊNDICE A –CÓDIGOS UTILIZADOS PARA IMPLEMENTAÇÃO DO VRFT E EXPERIMENTO EM MALHA FECHADA	62

1 INTRODUÇÃO

A crescente digitalização e automação industrial têm impulsionado o desenvolvimento de técnicas avançadas para controle e otimização de processos. Com a evolução da Indústria 4.0, a integração de sensores inteligentes e sistemas de monitoramento em tempo real tem gerado um volume exponencial de dados, criando novas oportunidades para a aplicação de metodologias baseadas em aprendizado e modelagem orientada a dados (HOU; WANG, 2013). Nesse cenário, as abordagens *data-driven* emergem como alternativas robustas para superar as limitações dos métodos convencionais de controle, que dependem de modelos matemáticos precisos, muitas vezes impraticáveis em sistemas dinâmicos e sujeitos a incertezas.

O *Virtual Reference Feedback Tuning* (VRFT), proposto por Campi *et al.* (2002), destaca-se entre as técnicas *data-driven* como um método eficiente para a sintonia direta de controladores a partir de dados experimentais. Essa abordagem permite o ajuste de controladores sem necessidade de identificação explícita da planta, tornando-se particularmente vantajosa para processos industriais onde os modelos matemáticos podem ser complexos, sujeitos a não linearidades e variações operacionais (GARCIA, 2023).

Na indústria, a aplicação do VRFT é relevante em diversos setores, como automação de linhas de produção, controle de motores elétricos, processos químicos, sistemas de energia e manufatura avançada. Em motores de indução, por exemplo, a variação de carga, fatores ambientais e degradação de componentes dificultam a obtenção de um modelo exato do sistema. O VRFT possibilita o ajuste de controladores eficientes diretamente a partir dos dados de operação, garantindo estabilidade e desempenho sem necessidade de ajustes constantes (BAZANELLA *et al.*, 2012).

Dessa forma, propõe-se um estudo de caso no qual se avalia o comportamento de um motor de indução trifásico com rotor em gaiola sob diferentes condições operacionais. A metodologia será analisada sob diferentes configurações, investigando o impacto da escolha de diferentes modelos de referência no comportamento dinâmico do sistema com perturbações.

1.1 Metodologia

A proposta deste trabalho inicia-se com a fundamentação teórica abordada no Capítulo 2, onde são introduzidos os conceitos fundamentais do controle *data-driven* e o embasamento teórico e matemático para o projeto do controlador pelo método VRFT. Esse método permite a

sintonia direta de controladores sem necessidade de identificação explícita da planta, utilizando apenas dados experimentais de entrada e saída do sistema.

O experimento consiste na aplicação do método VRFT para projetar um controlador de velocidade, garantindo desempenho robusto frente a perturbações em degrau e senoidais e segue as seguintes etapas:

1. **Coleta de Dados:** Primeiramente, realiza-se um ensaio experimental com o motor de indução operando em malha aberta. Um sinal de excitação adequado, como Pseudo-Random Binary Sequence (PRBS), é aplicado ao sistema para garantir a persistência de excitação e a coleta de dados representativos do comportamento dinâmico do motor.
2. **Definição do Modelo de Referência:** Escolhe-se um modelo de referência desejado $M(z)$ que represente o comportamento esperado do sistema em malha fechada. Esse modelo é determinado com base em critérios de desempenho, como tempo de resposta e rejeição a perturbações.
3. **Construção da Referência Virtual:** A partir dos dados experimentais e do modelo de referência, gera-se uma referência virtual que simula o comportamento ideal do sistema sob controle. Esse passo elimina a necessidade de um modelo matemático explícito da planta.
4. **Definição da Estrutura do Controlador:** Escolhe-se uma estrutura para o controlador, como um PI, de modo que seja parametrizável linearmente.
5. **Otimização dos Parâmetros do Controlador:** Os parâmetros ρ do controlador são ajustados minimizando um critério de erro quadrático entre a saída real e a referência virtual, conforme a formulação do VRFT. A minimização é resolvida por métodos de mínimos quadrados ponderados.
6. **Implementação:** O controlador obtido é implementado no sistema em malha fechada. Testa-se a resposta do motor de indução frente a perturbações em degrau e senoidais por meio da utilização de um motor secundário que atua como perturbação de carga.
7. **Avaliação de Desempenho:** A performance do controlador é analisada através de métricas quantitativas que avaliam a qualidade do controle e a suavidade do sinal de entrada aplicado ao sistema.

Para validar e quantificar os resultados obtidos com os diferentes modelos de referência, serão utilizadas as métricas Integral Absolute Error (IAE) e Total Variation (TV). Essas métricas fornecem uma análise detalhada sobre a precisão do controle e a suavidade do sinal de

entrada (SKOGESTAD, 2004).

A métrica IAE mede o erro acumulado ao longo do tempo, sendo definida por:

$$IAE = \sum_{k=0}^N |e(k)|T_s \quad (1.1)$$

onde $e(k)$ representa o erro entre a saída do sistema e a referência desejada. O IAE é sensível a ruídos de alta frequência, pois acumula suas variações ao longo do tempo.

Por fim, a TV é definida como:

$$TV = \sum_{k=1}^n |u_{k+1} - u_k| \quad (1.2)$$

onde $u(k)$ representa o sinal de controle aplicado ao sistema. O TV mede a suavidade do sinal de controle, sendo particularmente relevante para verificar a presença de oscilações e variações abruptas no esforço de controle.

A combinação dessas métricas permite uma análise abrangente do desempenho do controlador VRFT, possibilitando a observação do impacto da escolha de diferentes modelos de referência na resposta do sistema.

2 VIRTUAL REFERENCE FEEDBACK TUNING (VRFT)

Neste capítulo, apresenta-se a teoria introdutória do Controle Data-Driven, abrangendo sua origem, os principais fundamentos e técnicas, além das vantagens de sua aplicação e das diferenças em relação à teoria de controle tradicional. A partir das Seções 2.4 a 2.6, aborda-se de forma mais específica a técnica VRFT, descrevendo desde sua formulação inicial e desenvolvimento matemático até a obtenção do controlador desejado para o sistema.

2.1 Introdução ao Controle Data-Driven

O avanço tecnológico impulsionou significativamente a eficiência e a produtividade na indústria. Contudo, essa evolução também trouxe um aumento na complexidade dos processos industriais, tornando a modelagem e o controle desses sistemas mais desafiadores e, em muitos casos, inviáveis dentro do escopo da teoria tradicional de controle baseada em modelos (*Model-Based Control* (MBC)). Nesse contexto, o controle Data-Driven surge como uma solução eficiente que permite o projeto de controladores e a análise de desempenho dos sistemas com base exclusivamente em dados, sem depender de uma representação matemática explícita do processo.

O termo *data-driven* surgiu na ciência da computação e posteriormente ganhou força nos campos do controle, otimização e identificação de sistemas. De acordo com a definição proposta por Hou e Wang (2013), controle *data-driven* engloba todas as teorias e métodos de controle nos quais o controlador é projetado diretamente a partir de dados de entrada e saída do sistema, obtidos de forma *online* ou *offline*, sem a utilização explícita de modelos matemáticos do processo em que, sob condições razoáveis, possa ser garantida a estabilidade, convergência e robustez.

2.2 MBC x Data-Driven Control

A teoria de controle moderno, também denominada Controle Baseado em Modelos (MBC), teve suas origens com a introdução do modelo de espaço de estados paramétrico (KALMAN, 1960), juntamente com os avanços em técnicas de otimização de controle. Desde então, essa teoria foi amplamente desenvolvida, consolidando-se como uma abordagem essencial para o controle de sistemas em diversas áreas da indústria. No contexto de sistemas lineares, destacam-se técnicas como alocação de polos, controle ótimo por meio do regulador linear-quadrático

(*Linear Quadratic Regulator* (LQR)) e controle robusto. Para sistemas não lineares, métodos como controladores baseados na teoria de *Lyapunov*, *backstepping* e *feedback linearization* são amplamente empregados (HOU; WANG, 2013).

A principal característica do MBC é que o modelo matemático do sistema é o ponto de partida para o projeto do controlador. Esse modelo pode ser obtido tanto pela modelagem analítica dos fenômenos físicos associados ao sistema quanto pela identificação do modelo com base em dados experimentais coletados da planta. No entanto, a modelagem é sempre uma aproximação da realidade, uma vez que dinâmicas não modeladas e erros inerentes ao sistema são inevitáveis. Por consequência, o controlador projetado com base em um modelo estimado pode apresentar desvios ao ser aplicado no sistema real, especialmente devido às incertezas não modeladas (FRANKLIN *et al.*, 2014).

Além disso, sistemas mais complexos frequentemente apresentam maior número de incertezas paramétricas e dinâmicas difíceis de serem capturadas no modelo. Essa limitação é um dos maiores desafios enfrentados pelo MBC, pois as incertezas não modeladas podem comprometer a precisão e a eficácia do controle projetado. Assim, embora a teoria moderna de controle baseada em modelos seja robusta e bem fundamentada, sua aplicação prática pode ser limitada em cenários que envolvem sistemas altamente complexos ou com variabilidades significativas (HOU; WANG, 2013).

Em contraste, o princípio do controle baseado em dados (*Data-Driven Control* (DDC)) não depende de um modelo matemático explícito do sistema para o projeto do controlador. Em vez disso, o DDC utiliza diretamente os dados de entrada e saída coletados do sistema. Essa característica elimina a necessidade de modelagem analítica ou identificação prévia, superando uma das principais limitações do MBC (BAZANELLA *et al.*, 2013).

Outrossim, como é mostrado em Hou e Wang (2013), o DDC apresenta vantagens significativas, como a independência em relação à precisão do modelo matemático e a robustez frente a dinâmicas não modeladas, que são problemas recorrentes no MBC. Outro ponto de destaque é que o DDC é adequado para sistemas onde o modelo é muito complexo, apresenta não linearidades excessivas ou é difícil de ser estabelecido devido a variações rápidas ou desconhecidas na estrutura do sistema.

Dessa forma, o DDC torna-se uma alternativa viável e eficiente para aplicações em que o controle baseado em modelos enfrenta limitações práticas, permitindo a obtenção de controladores que garantem estabilidade, convergência e robustez com base exclusivamente em

dados de entrada e saída coletados do sistema que deseja-se controlar.

2.3 Principais técnicas *Data-driven*

Além do VRFT, proposto por Campi *et al.* (2002) e abordado com mais detalhes na próxima seção, outras técnicas foram fundamentais para o desenvolvimento do controle *Data-Driven*.

Uma das primeiras contribuições foi apresentada em Ziegler e Nichols (1942). Baseada em controle adaptativo, essa abordagem embora não utilizasse dados diretamente como nas metodologias modernas, baseava-se em experimentos práticos para o ajuste de controladores Proporcional-Integral-Derivativo (PID), dispensando a modelagem analítica detalhada.

Posteriormente, surgiram métodos que utilizavam diretamente os dados do sistema controlado. O *Iterative Feedback Tuning* (IFT), proposto por Hjalmarsson *et al.* (1994), introduziu uma abordagem iterativa para otimizar os parâmetros do controlador a partir de dados experimentais, sendo aplicado principalmente em sistemas lineares. Já o *Model-Free Adaptive Control* (MFAC), desenvolvido por Hou (1994), destacou-se no controle de sistemas não lineares ao construir um modelo linearizado equivalente de forma adaptativa e em tempo real, permitindo o controle direto com base nos dados de entrada e saída.

Embora as técnicas descritas anteriormente já demonstrassem resultados promissores e evidenciassem o potencial do controle *Data-Driven*, ainda não havia uma garantia teórica robusta de que os dados utilizados representassem, de forma completa, as dinâmicas do sistema. Essa questão foi abordada por Willems *et al.* (2005), com a formulação do *Lema Fundamental*, no qual foi provado que sinais de entrada persistentemente excitantes e de ordem suficientemente alta são capazes de capturar todo o comportamento de sistemas lineares invariantes no tempo. Essa descoberta não apenas garantiu a representatividade dos dados no projeto de controladores, mas também estabeleceu critérios claros para a qualidade e o tipo de dados necessários, resolvendo um dos principais desafios teóricos e práticos enfrentados pelo controle baseado em dados.

Desse modo, o controle *Data-Driven* passou a se desenvolver com maior segurança, possibilitando o avanço de técnicas mais sofisticadas e o aprofundamento teórico. Um marco importante nesse contexto foi o trabalho de Waarde *et al.* (2020), que apresentou uma série de provas matemáticas relacionadas à controlabilidade e identificabilidade de sistemas a partir de conjuntos de dados. O estudo demonstrou que diferentes sistemas com comportamentos similares nos dados podem ser controlados por uma mesma classe de controladores, estabelecendo

critérios mais gerais para o projeto de controladores *Data-Driven*. Essa abordagem ampliou a compreensão teórica e forneceu garantias mais robustas, consolidando a base matemática para aplicações práticas e para o desenvolvimento contínuo dessa linha de pesquisa.

2.4 Fundamentos do VRFT

A partir desta seção, todo o projeto do controlador será abordado em tempo discreto, considerando que os dados utilizados para o projeto são coletados da planta nesse domínio. Essa escolha é coerente com a maioria das abordagens *Data-Driven*, que se concentram no projeto de controladores em tempo discreto, incluindo a técnica do VRFT proposta por Campi *et al.* (2002).

Considera-se uma planta descrita por uma função de transferência em tempo discreto $G(z)$, a qual é desconhecida, e um conjunto de dados de entrada e saída obtido experimentalmente a partir do sistema a ser controlado. Devido ao fato de o modelo real da planta $G(z)$ ser desconhecido, utiliza-se um modelo de referência $M(z)$, também caracterizado por uma função de transferência em tempo discreto.

O modelo de referência $M(z)$ representa o comportamento dinâmico desejado para o sistema controlado, sendo definido com base em critérios de desempenho pré-estabelecidos, como sobressinal, tempo de acomodação e rejeição a perturbação.

De maneira geral, pode-se afirmar que existe uma classe de controladores $C(z, \rho)$, sendo ρ o vetor parâmetros ajustáveis do controlador, capaz de levar o sistema ao comportamento desejado, desde que satisfaça determinadas condições de projeto. No presente contexto, consideramos exclusivamente controladores que podem ser parametrizados linearmente em relação aos seus parâmetros. Dessa forma, o controlador pode ser representado matematicamente como o produto de dois vetores, sendo um deles composto por funções de transferências conhecidas em tempo discreto, e o outro formado pelos parâmetros ajustáveis. Desse modo, é possível escrever o controlador desejado da seguinte forma:

$$C(z, \rho) = \rho^T C_d(z) \quad (2.1)$$


Onde:

- ρ é o vetor coluna de parâmetros que serão definidos durante o procedimento de ajuste dado por $[a_1, a_2, a_3, \dots, a_n]$
- $C_d(z)$ é um vetor que define a estrutura do controlador desejado. Esse vetor pode incluir termos associados a funções típicas de controladores (por exemplo, proporcional, integral

ou derivativo), que representam a estrutura funcional do controlador a ser ajustado dado por $[B_1(z), B_2(z), B_3(z), \dots, B_n(z)]$:

Com isso, dado seguinte sistema de controle

Figura 1 – Sistema de Controle



Fonte: Próprio Autor.

É definido por Campi *et al.* (2002) que o principal objetivo da técnica do *VRFT* é minimizar o critério de seguimento de trajetória, ou seja, tornar a saída real do sistema o mais próxima possível da saída desejada. Sendo assim, busca-se minimizar a seguinte função custo:

$$J_y(\rho) = \|y(k, \rho) - y_d(k)\|^2 \quad (2.2)$$

Em que a saída real é medida durante o experimento com o sistema em laço fechado e pode ser caracterizada como:

$$y(k, \rho) = T(z, \rho)r(k) \quad (2.3)$$

Em que:

- $T(z, \rho)$ é a função de transferência do sistema em malha fechada obtida a partir da Figura 1 e dada por:

$$T(z, \rho) = \frac{G(z)C(z, \rho)}{1 + G(z)C(z, \rho)} \quad (2.4)$$

com $G(z)$ representando a planta do sistema e $C(z, \rho)$ o controlador parametrizado;

- $r(k)$ é a referência alocada para o sistema em malha fechada.

Dado que o modelo $G(z)$ não é conhecido, busca-se a saída desejada por meio de:

$$y_d(k) = M(z)r(k) \quad (2.5)$$

Onde:

- $M(z)$ é o modelo de referência escolhido.
- $r(k)$ é a referência alocada para o sistema em malha fechada em função do tempo.

A substituição de $y(k, \rho)$ e $y_d(k)$ na função custo $J_y(\rho)$ permite reescrever a equação como:

$$J_y(\rho) = \|T(z, \rho)r(k) - M(z)r(k)\|^2 \quad (2.6)$$

Essa formulação evidencia que a função depende diretamente da dinâmica completa do sistema em malha fechada, uma vez que requer o conhecimento detalhado da função de transferência da planta. Além disso, a minimização de $J_y(\rho)$ demanda o cálculo iterativo da saída em malha fechada, resultando em uma dependência não linear de ρ e, conseqüentemente, em maior complexidade computacional para realizar o cálculo.

Visando abstrair essa complexidade, é proposto por Campi *et al.* (2002) o critério da minimização do controlador ideal. Este critério baseia-se na ideia de que é possível identificar o controlador ideal a partir dos dados de entrada e saída do sistema, sendo estes $e(k)$ e $u(k)$, respectivamente. O controlador ideal é aquele que, ao receber em sua entrada o sinal $e(k)$, gera como saída o sinal $u(k)$. Em outras palavras, quanto melhor o controlador, mais próxima sua saída será do sinal $u(k)$.

Assim, é possível definir o critério da minimização do controlador ideal como:


$$J_{VR}(\rho) = \|u(k) - \rho^T \phi(k)\|^2 \quad (2.7)$$

Onde:

- $u(k)$: representa o sinal de controle na saída do controlador;
- $\phi(k)$: é um vetor de regressores calculado a partir do erro;

Nota-se que a abordagem acima elimina a necessidade de calcular explicitamente $T(z, \rho)$ ou simular o sistema em malha fechada. Em vez disso, utiliza os dados experimentais para projetar diretamente o controlador. Desse modo a solução torna-se mais simples, pois o problema da minimização da função é linear com relação aos parâmetros ρ permitindo a aplicação de métodos de otimização quadrática simples. A Figura 2 mostra um exemplo do comportamento das funções, no eixo horizontal está representado ρ , conjunto de parâmetros do controlador que desejamos ajustar eixo vertical, exibem-se valores ilustrativos de J_y e J_{VR} para cada ρ , de modo a exemplificar a diferença de complexidade entre as duas funções.

Figura 2 – Comparação entre as funções custo ($J_y \times J_{VR}$)




Fonte: GARCIA (2023).

Portanto, devido à maior simplicidade do critério de minimização do controlador $J_{VR}(\rho)$ em relação a $J_y(\rho)$, é vantajoso utilizar $J_{VR}(\rho)$ como base para o projeto do controlador. Contudo, como se tratam de critérios distintos, é fundamental garantir que ambas as funções apresentem o mesmo mínimo global. Em outras palavras, a minimização de $J_{VR}(\rho)$ deve resultar no mesmo conjunto de parâmetros ρ_d que minimiza $J_y(\rho)$. Para assegurar essa equivalência, é necessário compreender detalhadamente as etapas do projeto do controlador, que serão descritas nas próximas seções.

2.5 Projeto do Controlador com base na referência de virtual

Dado o seguinte sistema em malha fechada:

Figura 3 – Topologia de ensaio VRFT



Fonte: Próprio Autor.

A topologia mostrada na Figura 3 representa um experimento com base na referência virtual gerada pelo modelo desejado, as linhas pontilhadas representam a parte virtual do processo, enquanto as linhas contínuas indicam a parte real do sistema. De maneira geral, nos métodos tradicionais de projeto de controle por referência de modelo, busca-se determinar os parâmetros ρ de um controlador $C(z, \rho)$ de forma que a função de transferência do sistema em malha fechada

seja idêntica ao modelo de referência desejado $M(z)$, ou seja,

$$T(z, \rho) = M(z) \quad (2.8)$$

A partir da estrutura do sistema mostrado na Figura 3, deve-se lembrar que a função de transferência em malha fechada é dada por:

$$T(z, \rho) = \frac{G(z)C(z, \rho)}{1 + G(z)C(z, \rho)} \quad (2.9)$$

Dessa forma, ao alimentar o sistema com um sinal de referência $r(k)$, espera-se que a saída do sistema siga a relação:

$$y(k) = M(z)r(k) \quad (2.10)$$

Entretanto, no contexto do projeto de controladores *data-driven*, tem-se acesso apenas a dados experimentais, ou seja, às medições dos sinais de entrada e saída da planta. Isso torna inviável a aplicação direta dos métodos tradicionais de projeto baseados na referência, uma vez que o modelo da planta $G(z)$ é desconhecido. Para contornar essa limitação, o método do VRFT propõe a substituição da referência real por uma referência virtual, permitindo a obtenção de um controlador que leve o sistema à resposta desejada sem a necessidade de um modelo explícito da planta.

A ideia central do método da referência virtual é definir um sinal de referência $\tilde{r}(k)$ tal que a saída do sistema em malha fechada seja a desejada $y_d(k)$, sem exigir conhecimento prévio da planta $G(z)$. Para isso, assume-se que foram coletadas medições do sinal de entrada $u(k)$, aplicado à planta, e da correspondente saída $y(k)$. Dado um modelo de referência $M(z)$, escolhido com base nos critérios de desempenho desejados, a referência virtual $\tilde{r}(k)$ é definida como:

$$\tilde{r}(k) = M^{-1}(z)y(k). \quad (2.11)$$

Essa referência é denominada virtual pois não foi aplicada efetivamente ao sistema, mas sim reconstruída a partir da saída desejada $y(k)$ e do modelo de referência $M(z)$. A partir dessa referência virtual, define-se o erro virtual $\tilde{e}(k)$ como:

$$\tilde{e}(k) = \tilde{r}(k) - y(k) \quad (2.12)$$

Com base na estrutura do sistema em malha fechada mostrada na Figura 3, pode-se definir o vetor de regressores $\phi(k)$ em função do erro virtual $\tilde{e}(k)$ e da estrutura do controlador

desejado, sendo expresso como:

$$\phi(k) = C_d(z)\tilde{e}(k) \quad (2.13)$$

Onde $C_d(z)$ representa a estrutura do controlador desejado. Dessa forma, a lei de controle que gera o sinal de entrada aplicado à planta pode ser escrita como:

$$u(k) = \rho_d^T C_d(z)\tilde{e}(k) = \rho_d^T \phi(k), \quad (2.14)$$

em que ρ_d é o vetor de parâmetros do controlador desejado, responsável por ajustar cada termo em $C_d(z)$ para atender às especificações de desempenho

Observa-se, portanto, que para encontrar o controlador desejado, o problema consiste em encontrar o vetor de parâmetros do controlador desejado ρ_d , uma vez que todas as demais variáveis podem ser calculadas diretamente a partir dos dados experimentais. Dessa forma, torna-se necessário analisar os critérios de minimização $J_y(\rho)$ e $J_{VR}(\rho)$, para que seja possível garantir que o ρ_d levará as duas funções para o mínimo global e assim encontrar o seu valor por meio da solução de $J_{VR}(\rho_d)$.

2.6 Sintonia do Controlador

Para garantir que o sistema em malha fechada tenha o comportamento estabelecido pelo modelo de referência, o controlador desejado C_d deve ser tal que os seus parâmetros dados pelo vetor coluna ρ_d levem as funções $J_y(\rho)$ e $J_{VR}(\rho)$ para o mínimo global em ρ_d .

Neste caso, existem duas abordagens para garantir que ρ_d leve as funções para o mínimo global, sendo a primeira uma abordagem ideal e a segunda uma abordagem prática em que se considera o caso do controlador desejado descasado.

No caso ideal em que $C_d(z)$ pertence à classe de controladores parametrizáveis $C(z, \rho)$, é possível garantir que os mínimos globais das funções custo $J_y(\rho)$ e $J_{VR}(\rho)$ coincidam.

Para formalizar essa equivalência, considerando o critério de seguimento de trajetória definido na expressão (2.6) e substituindo $T(z, \rho)$ a partir do que foi mostrado na equação (2.9), temos:

$$J_y(\rho) = \left\| \frac{G(z)C(z, \rho)}{1 + G(z)C(z, \rho)} r(k) - M(z)r(k) \right\|^2 \quad (2.15)$$

Para garantir que $J_y(\rho)$ seja minimizado, é necessário que a função de transferência em malha fechada seja igual ao modelo de referência $M(z)$, ou seja:

$$\frac{G(z)C_d(z)}{1 + G(z)C_d(z)} = M(z) \quad (2.16)$$

Rearranjando essa expressão, obtemos a relação que define o controlador ideal:

$$C_d(z) = \frac{M(z)}{G(z)(1-M(z))} \quad (2.17)$$

Caso o controlador ideal $C_d(z)$ pertença à classe de controladores parametrizados $C(z, \rho)$, existe um vetor ρ_d tal que $C(z, \rho_d) = C_d(z)$. Assim, a minimização de $J_y(\rho)$ conduz à escolha de ρ_d como solução ótima.

Por outro lado, considerando o critério de minimização do controlador ideal $J_{VR}(\rho)$ que foi definido em (2.6) e assumindo que o controlador desejado C_d não pertence a classe de controladores $C(z, \rho)$, temos que a função custo pode ser reescrita da seguinte forma:

$$J_{VR}(\rho) = \|u(k) - \rho_d^T C_d(z) \tilde{e}(k)\|^2 \quad (2.18)$$

Sabendo que, $J_{VR}(\rho)$ mede o erro entre o sinal de controle real $u(k)$ e a saída estimada do controlador parametrizado $\rho^T \phi(k)$. No caso ideal, onde $C(z) = C_d(z)$, temos:

$$u(k) = \rho_d^T C_d(z) \tilde{e}(k) \quad (2.19)$$

Assim, avaliando $J_{VR}(\rho)$ no ponto ρ_d :

$$J_{VR}(\rho_d) = \|u(k) - u(k)\|^2 = 0 \quad (2.20)$$

Isso implica que ρ_d é o mínimo global de $J_{VR}(\rho)$. Além disso, ao substituir $\rho = \rho_d$ em $J_y(\rho)$, utilizando a propriedade de que o controlador ideal garante $T(z, \rho_d) = M(z)$, também se obtém:

$$J_y(\rho_d) = 0 \quad (2.21)$$

Portanto, quando o controlador ideal pertence à classe de controladores parametrizáveis, as funções custo $J_y(\rho)$ e $J_{VR}(\rho)$ compartilham o mesmo mínimo global em $\rho = \rho_d$. Isso significa que a minimização de $J_{VR}(\rho)$ conduz ao mesmo conjunto de parâmetros ρ_d que minimiza $J_y(\rho)$, garantindo que a resposta do sistema seja equivalente àquela especificada pelo modelo de referência.

Contudo, na prática, nem sempre é possível garantir que o controlador ideal pertença exatamente à classe parametrizável $C(z, \rho)$. Quando essa condição não é satisfeita, não há garantia de que ρ_d levará $J_{VR}(\rho)$ e $J_y(\rho)$ ao mínimo global, resultando em um controlador que apenas aproxima o desempenho desejado (BAZANELLA *et al.*, 2012).

Para lidar com essa limitação, propõe-se a utilização de um filtro $L(z)$ nos sinais $u(k)$ e $\tilde{e}(k)$ presentes $J_{VR}(\rho)$ com o objetivo de igualar os argumentos deste critério com os argumentos de $J_y(\rho)$, assim garantindo que as duas funções convergirão para o mínimo global no ponto desejado, minimizando a discrepância entre os dois critérios (CAMPI *et al.*, 2002).

No caso em que o controlador ideal não pertence à classe de controladores, torna-se vantajoso conduzir uma análise dos sinais no domínio da frequência. Dessa forma, verifica-se com maior clareza como a energia desses sinais se distribui ao longo das diferentes faixas de frequência, o que facilita tanto a avaliação do erro de aproximação entre os dois critérios quanto o projeto de compensação mediante o uso do filtro proposto

Logo para essa demonstração faz-se necessário passar os critérios no domínio do tempo discreto para o domínio da frequência, para isso utiliza-se o teorema de Parseval (LJUNG, 1999), que estabelece que a energia total de um sinal pode ser calculada tanto no domínio do tempo quanto no domínio da frequência. Matematicamente, para um sinal contínuo $x(t)$, o teorema é expresso como:

$$\int_{-\infty}^{\infty} |x(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |X(\omega)|^2 d\omega \quad (2.22)$$

onde $X(\omega)$ é a transformada de Fourier de $x(t)$. Isso significa que a integral do quadrado do módulo de um sinal no tempo é equivalente à integral do quadrado do módulo de sua representação no domínio da frequência.

No caso discreto, a formulação equivalente do Teorema de Parseval para um sinal $x[k]$ com sua Transformada Discreta de Fourier (DTFT), $X(e^{j\omega})$, é dada por:

$$\sum_{k=-\infty}^{\infty} |x[k]|^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} |X(e^{j\omega})|^2 d\omega \quad (2.23)$$

Além disso, vale ressaltar que a norma H_2 , representada ao longo do trabalho pela notação $\|\cdot\|_2^2$, é utilizada para medir a energia da resposta ao impulso de um sistema (Doyle *et al.* (1996)), sendo particularmente útil para avaliar sistemas lineares invariante no tempo (LTI) no domínio da frequência. Desse modo, no domínio da frequência, para sistemas discretos, a norma H_2 ao quadrado é definida como:

$$\|H(e^{j\omega})\|_2^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} |H(e^{j\omega})|^2 d\omega, \quad (2.24)$$

onde $H(e^{j\omega})$ representa a função de transferência do critério a ser analisado.

A partir disso, tomando como base a metodologia proposta em Bazanella *et al.* (2012), é possível analisar as equações de modo que a equivalência entre os critérios de minimização $J_y(\rho)$ e $J_{VR}(\rho)$ seja estabelecida sob certas condições. À vista disso, analisando o critério de seguimento de trajetória dado pela equação (2.25) e pela definição do modelo desejado dado pela equação (2.16), temos que $J_y(\rho)$ pode ser reescrito como:

$$J_y(\rho) = \left\| \frac{G(z)C(z, \rho)}{1 + G(z)C(z, \rho)} r(k) - \frac{G(z)C_d(z)}{1 + G(z)C_d(z)} r(k) \right\|^2 \quad (2.25)$$

Aplicando o teorema de Parseval para tempo discreto, mostrado em (2.23), e a partir da definição da norma H2 em (2.24), obtemos:

$$J_y(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left| \frac{G(e^{j\omega})C(e^{j\omega}, \rho)}{1 + G(e^{j\omega})C(e^{j\omega}, \rho)} - \frac{G(e^{j\omega})C_d(e^{j\omega})}{1 + G(e^{j\omega})C_d(e^{j\omega})} \right|^2 \Phi_r(e^{j\omega}) d\omega. \quad (2.26)$$

Desenvolvendo essa equação usando um denominador comum:

$$J_y(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \frac{|G(e^{j\omega})|^2 |C(e^{j\omega}, \rho)(1 + G(e^{j\omega})C_d(e^{j\omega})) - C_d(e^{j\omega})(1 + G(e^{j\omega})C(e^{j\omega}, \rho))|^2}{|(1 + G(e^{j\omega})C(e^{j\omega}, \rho))(1 + G(e^{j\omega})C_d(e^{j\omega}))|^2} \Phi_r(e^{j\omega}) d\omega. \quad (2.27)$$

Agora, identificamos que os termos no denominador correspondem às funções de sensibilidade do sistema, definidas como:

$$S(e^{j\omega}, \rho) = \frac{1}{1 + G(e^{j\omega})C(e^{j\omega}, \rho)} \quad (2.28)$$

$$S_d(e^{j\omega}) = \frac{1}{1 + G(e^{j\omega})C_d(e^{j\omega})}. \quad (2.29)$$

Essas funções representam como perturbações e variações nos parâmetros da planta afetam a saída do sistema em malha fechada ao longo das frequências (DOYLE *et al.*, 1995). Sendo $S(e^{j\omega}, \rho)$ a função de sensibilidade do sistema real e $(S_d(e^{j\omega}))$ a função de sensibilidade desejada com base no controlador desejado e modelo de referência. Com isso, reescrevemos $J_y(\rho)$ como:

$$J_y(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} |G(e^{j\omega})|^2 |C(e^{j\omega}, \rho) - C_d(e^{j\omega})|^2 |S(e^{j\omega}, \rho)|^2 |S_d(e^{j\omega})|^2 \Phi_r(e^{j\omega}) d\omega. \quad (2.30)$$

Por outro lado, analisando o critério do controlador ideal, com base na demonstração matemática mostrada em Bazanella *et al.* (2012) a partir do filtro $L(z)$ proposto, o critério J_{VR} pode ser reescrito como:

$$J_{VR}(\rho) = \left\| L(z)u(k) - L(z)\tilde{e}(k)\rho^T C(z) \right\|^2, \quad (2.31)$$

Substituindo a equação (2.12) e lembrando que a referência virtual é definida em (2.11), obtemos:

$$J_{VR}(\rho) = \left\| \left\| L(z)y(k) \left(u(k) - C(z, \rho) \frac{1 - M(z)}{M(z)} \right) \right\| \right\|^2, \quad (2.32)$$

A partir do que foi definido em (2.23) e (2.24), deduzindo mais diretamente o critério filtrado mostrado acima, temos:

$$J_{VR}(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left| L(e^{j\omega}) \left(1 - \left[C(e^{j\omega}, \rho) \frac{1 - M(e^{j\omega})}{M(e^{j\omega})} \right] G(e^{j\omega}) \right) \right|^2 \Phi_u(e^{j\omega}) d\omega. \quad (2.33)$$

Reescrevendo a equação, obtemos:

$$J_{VR}(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} |L(e^{j\omega})|^2 |G(e^{j\omega})|^2 |M(e^{j\omega})|^2 \left| \frac{M(e^{j\omega})}{G(e^{j\omega})} - C(e^{j\omega}, \rho)(1 - M(e^{j\omega})) \right|^2 \Phi_u(e^{j\omega}) d\omega. \quad (2.34)$$

A partir das definições (2.16) e (2.29), nota-se que:

$$1 - M(e^{j\omega}) = S_d(e^{j\omega}) \quad \text{e} \quad \frac{M(e^{j\omega})}{G(e^{j\omega})} = C_d(e^{j\omega}) S_d(e^{j\omega}). \quad (2.35)$$

Assim, podemos finalmente escrever a expressão de $J_{VR}(\rho)$ como

$$J_{VR}(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} |L(e^{j\omega})|^2 \frac{|G(e^{j\omega})|^2}{|M(e^{j\omega})|^2} |S_d(e^{j\omega})|^2 |C_d(e^{j\omega}) - C(e^{j\omega}, \rho)|^2 \Phi_u(e^{j\omega}) d\omega. \quad (2.36)$$

Ainda de acordo com Bazanella *et al.* (2012), observando as Equações (2.30) e (2.36), nota-se que ambas as funções de custo compartilham o mesmo termo de diferença entre o controlador desejado e o projetado, $|C_d(e^{j\omega}) - C(e^{j\omega}, \rho)|^2$. Entretanto, cada critério é ponderado por fatores distintos, de modo que cada integral enfatiza regiões de frequência diferentes. Assim, não há razão para esperar que seus mínimos coincidam. Todavia, a presença do filtro $L(z)$ como parâmetro livre permite alinhar os pesos no critério VR aos do critério baseado em erro na saída, resultando no mesmo controlador que minimizaria $J_y(\rho)$.

Sendo assim, ao igualar os integrandos de $J_y(\rho)$ e $J_{VR}(\rho)$, obtêm-se o filtro a ser utilizado:

$$|L(e^{j\omega})|^2 = \frac{|M(e^{j\omega})|^2 |S(e^{j\omega}, \rho)|^2 \Phi_r(e^{j\omega})}{\Phi_u(e^{j\omega})}. \quad (2.37)$$

Observa-se que $\Phi_r(e^{j\omega})$, presente no critério $J_y(\rho)$, corresponde ao espectro do sinal de referência real $r(t)$ que será aplicado ao sistema durante a operação, enquanto $\Phi_u(e^{j\omega})$, no

critério $J_{VR}(\rho)$, representa o espectro da entrada $u(t)$ medida no experimento de VRFT. Em outras palavras, $\Phi_r(e^{j\omega})$ ajusta o peso do sinal de referência real na faixa de frequências relevante para a operação do sistema, enquanto $\Phi_u(e^{j\omega})$ reflete o espectro efetivamente medido no experimento de VRFT. Ao escolher $L(z)$ de modo que esses dois espectros sejam compatibilizados, faz-se com que ambos os critérios atribuam o mesmo peso às mesmas faixas de frequência, resultando em mínimos idênticos para $J_y(\rho)$ e $J_{VR}(\rho)$.

No entanto, o cálculo exato de $L(z)$ de acordo com a equação (2.37) exige conhecer a função de sensibilidade $S(z, \rho)$, a qual depende do controlador $C(z, \rho)$ — algo que ainda não se conhece *a priori*. Com isso, é mostrado em Campi *et al.* (2002) que, no caso do projeto VRFT, é esperado que controlador $C(e^{j\omega}, \rho)$ esteja relativamente próximo do controlador desejado $C_d(e^{j\omega})$, logo, é razoável fazer a seguinte aproximação:

$$|S(e^{j\omega}, \rho)|^2 \approx |S_d(e^{j\omega})|^2 = |1 - M(e^{j\omega})|^2. \quad (2.38)$$

Substituindo essa aproximação, a equação do filtro se reduz a:

$$|L(e^{j\omega})|^2 = \frac{|M(e^{j\omega})|^2 |1 - M(e^{j\omega})|^2 \Phi_r(e^{j\omega})}{\Phi_u(e^{j\omega})}. \quad (2.39)$$

Essa formulação assegura que $J_y(\rho)$ e $J_{VR}(\rho)$ compartilhem o mesmo mínimo global, fazendo com que a minimização de $J_{VR}(\rho)$ forneça um controlador $C(z, \rho_d)$ capaz de reproduzir o comportamento desejado em malha fechada, aproximando-se do controlador $C_d(z)$. Nesse contexto, o filtro $L(z)$ exerce um papel fundamental ao compatibilizar os pesos de frequência observados no experimento de VRFT com aqueles do sistema em operação real, dispensando a necessidade de conhecer parâmetros intrínsecos da planta e viabilizando, na prática, o projeto de controle diretamente a partir dos dados experimentais.

Agora, aplicando o filtro $L(z)$ às medições de $e(k)$ e $u(k)$ no critério $J_{VR}(\rho)$, garantimos que os dois critérios serão levados ao mínimo global quando analisados no mesmo ponto desejado. Com essa filtragem, obtemos:

$$J_{VR}(\rho) = \frac{1}{2\pi} \int_{-\pi}^{\pi} |G(e^{j\omega})|^2 |S_d(e^{j\omega})|^2 |C_d(e^{j\omega}) - C(e^{j\omega}, \rho)|^2 \Phi_u(e^{j\omega}) d\omega. \quad (2.40)$$

Portanto, para obter o valor de ρ_d que minimiza $J_{VR}(\rho)$, diferenciamos o critério em relação a ρ_d e igualamos a zero:

$$\frac{dJ_{VR}(\rho_d)}{d\rho} = 0. \quad (2.41)$$

Resolvendo essa equação, obtemos:

$$\rho_d = \left(\sum_k \phi(k) \phi^T(k) \right)^{-1} \sum_k \phi(k) u(k). \quad (2.42)$$

Portanto, é notável que ρ_d é justamente o valor que minimiza os critérios de projeto considerados, tornando possível o projeto do controlador desejado. Além disso, o cálculo de ρ_d assume a forma de uma estimação por mínimos quadrados, simplificando a etapa de ajuste. Com isso, a determinação dos parâmetros ρ_d ocorre diretamente a partir dos dados experimentais, sem a necessidade de uma modelagem explícita da planta, o que reforça a eficiência do método *VRFT* para a sintonia de controladores.

2.7 Implementação do VRFT

A partir da fundamentação teórica apresentada nas seções anteriores, podemos agora arquitetar de forma sucinta o fluxo de projeto do controlador. A seguir, descreve-se um passo a passo que mostra como aplicar, na prática, o método VRFT em conformidade com as premissas teóricas apresentadas.

1. Realizar um experimento na planta real para coletar dados de entrada $u(t)$ e saída $y(t)$ (por exemplo, ensaio utilizando um sinal do tipo PRBS).
2. Definir um modelo de referência $M(z)$ com base nas especificações desejadas em malha fechada (por exemplo, tempo de acomodação e rejeição de perturbações).
3. Escolher a estrutura do controlador $C(z, \rho)$ a ser ajustado, como PID, Proporcional-Derivativo (PD) ou PI, dentre outras opções.
4. Projetar (ou selecionar) o filtro $L(z)$ de modo que o critério de ajuste do VRFT ($J_{VR}(\rho)$) se alinhe ao critério real ($J_y(\rho)$), normalmente fazendo uso dos espectros de entrada e de referência ($\Phi_u(\omega)$ e $\Phi_r(\omega)$).
5. Construir, de forma iterativa, as variáveis de regressão $\phi(k)$, empregando as medidas $u(t)$, $y(t)$ e o modelo de referência $M(z)$. Cada $\phi(k)$ reflete a forma paramétrica do controlador escolhido.
6. Aplicar o filtro $L(z)$ aos dados experimentais, tipicamente sobre o sinal de entrada, para que o problema de mínimos quadrados represente adequadamente o critério de projeto.
7. Determinar os parâmetros ρ via resolução de um problema de mínimos quadrados, do tipo:

$$\rho = (\Phi \Phi^T)^{-1} \Phi u_{\text{filtered}},$$

onde Φ é a matriz formada pelos vetores $\phi(k)$, e u_{filtered} é o sinal de entrada após a filtragem por $L(z)$.

8. Implementar o controlador $C(z, \rho)$ na planta em malha fechada e verificar se o desempenho atende ao critério de projeto. Se necessário, ajustar o filtro $L(z)$ ou o modelo de referência $M(z)$.

3 DESCRIÇÃO DA BANCADA

Neste capítulo, apresenta-se a bancada experimental utilizada para a aplicação do estudo em questão. A bancada é composta por dois motores de indução trifásicos, acionados por inversores de frequência, um torquímetro para a medição de torque e velocidade, e uma placa de aquisição de dados da Nidaq, responsável pela comunicação entre o computador e os demais componentes. A placa de aquisição desempenha um papel central no sistema, convertendo os sinais analógicos enviados pelo computador para o acionamento dos motores e registrando os dados provenientes do torquímetro.

As seções 3.1 a 3.3 apresentam a descrição detalhada de cada elemento que compõe a bancada, incluindo suas características técnicas e funcionamento. Na seção 3.4, são descritos o procedimento de acionamento da bancada e o seu esquemático completo.

3.1 Motores da Bancada Experimental

O sistema de ensaio é composto por dois motores trifásicos de indução com rotor de gaiola, ambos da linha W22 IR2 da fabricante WEG. O motor principal é o motor mais potente e será o alvo do controle de velocidade no projeto. Já o motor de secundário é utilizado para impor variações na carga mecânica, simulando condições reais de operação.

De acordo com o catálogo online disponibilizado pela WEG em seu *website* WEG S/A (2025), ambos os motores operam em redes trifásicas com tensão nominal de 220/380V e frequência de 60Hz. O motor principal possui potência de 3,7kW (5cv) e rotação nominal de 3505rpm, enquanto o motor secundário possui potência de 1,1kW (1,5cv) e rotação nominal de 3440rpm. Os motores são projetados para operação contínua (regime S1) e possuem classe de isolamento F, garantindo confiabilidade em aplicações industriais.


Tabela 1 – Especificações elétricas dos motores da bancada

Parâmetro	Motor Principal	Motor Secundário
Potência Nominal	3,7 kW (5 cv)	1,1 kW (1,5 cv)
Tensão Nominal	220/380 V	220/380 V
Corrente Nominal	12,7/7,38 A	4,16/2,41 A
Frequência	60 Hz	60 Hz
Número de Polos	2	2
Rotação Nominal	3505 rpm	3440 rpm
Conjugado Nominal	1,03 kgfm	0,311 kgfm
Corrente de Partida (Ip/In)	9,2	7,6
Conjugado de Partida	330%	340%
Conjugado Máximo	409%	330%
Momento de Inércia (J)	0,0063 kgm ²	0,0009 kgm ²
Classe de Isolamento	F	F
Fator de Serviço	1,15	1,15
Grau de Proteção	IP55	IP55
Fator de Serviço	15%	15%

Fonte: Adaptado de WEG S/A (2025)


Os motores estão mecanicamente acoplados por meio de um torquímetro, permitindo a medição simultânea do torque e da velocidade de rotação do sistema. O motor principal é o responsável pelo acionamento da bancada, sendo controlado pelo inversor para ajuste da velocidade, enquanto o motor secundário atua como uma perturbação e introduz variações de carga no eixo, simulando diferentes condições operacionais, conforme será visto na seção 4. Essa configuração possibilita uma análise detalhada do comportamento dinâmico do motor principal sob diversas condições de carga.

Figura 4 – Esquemático - Disposição dos motores



Fonte: Próprio Autor

Figura 5 – Foto real da disposição de motores



Fonte: Próprio Autor

3.2 Inversores de Frequência

O acionamento do motor principal é realizado por meio do inversor de frequência Siemens SINAMICS G120, equipado com o módulo de potência PM250. Conforme Siemens (2021), Esse modelo opera em redes trifásicas com tensão de alimentação entre 380V e 480V, variando em até 10%. A frequência da rede suportada pelo equipamento está na faixa de 47Hz a 63Hz, garantindo compatibilidade com sistemas industriais padrão. Com um fator de potência de 0,95, o inversor proporciona alta eficiência energética, atingindo um rendimento de 95%, classificado na categoria IE2 de eficiência.

Tabela 2 – Especificações elétricas do inversor Siemens SINAMICS G120 PM250

Parâmetro	Valor
Potência Nominal (LO)	7,5 kW (IEC 400V) / 10 hp (NEC 480V)
Potência Nominal (HO)	5,5 kW (IEC 400V) / 7,5 hp (NEC 480V)
Frequência de Rede	47 Hz - 63 Hz
Frequência de Saída (V/f)	0 Hz - 200 Hz
Frequência de Saída (Controle Vetorial)	0 Hz - 550 Hz
Corrente Nominal (LO)	18,00 A
Corrente Nominal (HO)	13,20 A
Corrente Máxima de Saída	26,40 A
Fator de Potência (λ)	0,95
Eficiência (η)	95%
Classe de Eficiência	IE2

Fonte: Adaptado de Siemens (2018)

Figura 6 – Inversor Siemens - SINAMICS G120 PM250



Fonte: Próprio Autor

O controle de velocidade do motor secundário é realizado por meio do inversor Telemecanique Altivar 31 (ATV31HU11N4A). O catalogo do fabricante Schneider Electric (2004) mostra que esse modelo opera em redes com tensão de alimentação entre 380 V e 500 V, compatível com frequências de 50 Hz e 60 Hz e inversor possui corrente nominal de 3,0 A, com capacidade de sobrecorrente transitória de até 4,5 A por 60 segundos, garantindo estabilidade na operação sob variações de carga.

Tabela 3 – Especificações Nominais do Inversor ATV31HU11N4A

Parâmetro	Valor
Tensão de Alimentação (V)	380 - 500 (Trifásico, 50/60 Hz)
Corrente de Linha Máxima (A)	4,9 (380V) / 3,7 (500V)
Corrente Nominal do Inversor (A)	3,0
Corrente Transitória Máxima (60s) (A)	4,5
Corrente de Chamada Máxima (A)	10
Potência Aparente (kVA)	3,2
Icc Linha Presumida Máxima (kA)	5
Potência Dissipada com Carga Nominal (W)	48
Frequência de Chaveamento (kHz)	2 - 16 (Padrão: 4)

Fonte: Manual do usuário do Altivar 31 (ATV31HU11N4A).

Figura 7 – Inversor Telemecanique - ATV31HU11N4A



Fonte: Próprio Autor

3.3 Aquisição e Envio de Dados

Para a aquisição e envio de dados da bancada, utiliza-se um torquímetro conectado diretamente ao motor principal para a leitura do torque e da velocidade de rotação. Esse torquímetro, por sua vez, está integrado a uma placa de aquisição de dados da National Instruments (NI), modelo NI-6221, a qual é responsável tanto pela leitura dos dados provenientes do sensor quanto pelo envio de informações ao inversor, permitindo o acionamento e controle dos motores.


O torquímetro empregado neste estudo é o modelo TM Series 307, da fabricante Magtrol. Conforme o catalogo do fabricante Magtrol (2024), este modelo trata-se de um sensor de alta precisão cujo princípio de medição baseia-se em um acoplamento transformador variável proporcional ao torque aplicado no eixo. Esse modelo possui um módulo eletrônico de condicionamento, capaz de gerar um sinal de torque na faixa de $0VDC$ a $10VDC$, bem como um sinal de velocidade via coletor aberto. Essa característica garante alta imunidade a ruídos e estabilidade a longo prazo. Além disso, sua tecnologia sem contato evita a rotação de componentes eletrônicos, assegurando maior confiabilidade e precisão nas medições.

Tabela 4 – Dados nominais do torquímetro TM Series - Modelo 307

Parâmetro	Valor
Modelo	TM 307
Torque Nominal (N.m)	10
Precisão (% RT)	<0,1
Sobrecarga Capacidade (% RT)	200
Sobrecarga Limite (% RT)	400
Velocidade Máxima (rpm)	20.000

Fonte: Adaptado de Magtrol (2024)

Figura 8 – Torquímetro utilizado na bancada



Fonte: Próprio Autor


A aquisição dos dados do torquímetro e o envio de comandos para o inversor são realizados por meio da placa de aquisição de dados NI-6221, que oferece funcionalidades avançadas para captura e processamento de sinais analógicos e digitais. De acordo com o catálogo do fabricante National Instruments (2023), esse modelo conta com um conversor analógico-digital (ADC) de 16 bits, garantindo elevada precisão na leitura dos sinais. Além disso, a taxa de amostragem pode atingir $250kS/s$, permitindo a captura rápida e confiável das variações de torque e velocidade do sistema.

Tabela 5 – Características da placa NI PCI/PXI/USB-6221

Entradas Analógicas (AI)	
Canais	8 diferenciais ou 16 single-ended
Resolução	16 bits
Faixas de Entrada	$\pm 0,2$ V, ± 1 V, ± 5 V, ± 10 V
FIFO de Entrada	4.095 amostras
Saídas Analógicas (AO)	
Canais	2
Resolução	16 bits
Faixa de Saída	± 10 V
FIFO de Saída	8.191 amostras
Clocks e Frequências	
Taxa de Amostragem Máxima	250 kS/s
Taxa Máxima de Atualização AO	833 kS/s (1 canal), 740 kS/s (2 canais)
Taxa Máxima de Clock Digital	1 MHz
Número de Contadores	2
Resolução dos Contadores	32 bits
Frequência Máxima do Clock Externo	20 MHz

Fonte: Adaptado de National Instruments (2023)

Figura 9 – Placa NIDAQ - NI 6221



Fonte: Próprio Autor

3.4 Acionamento da Bancada

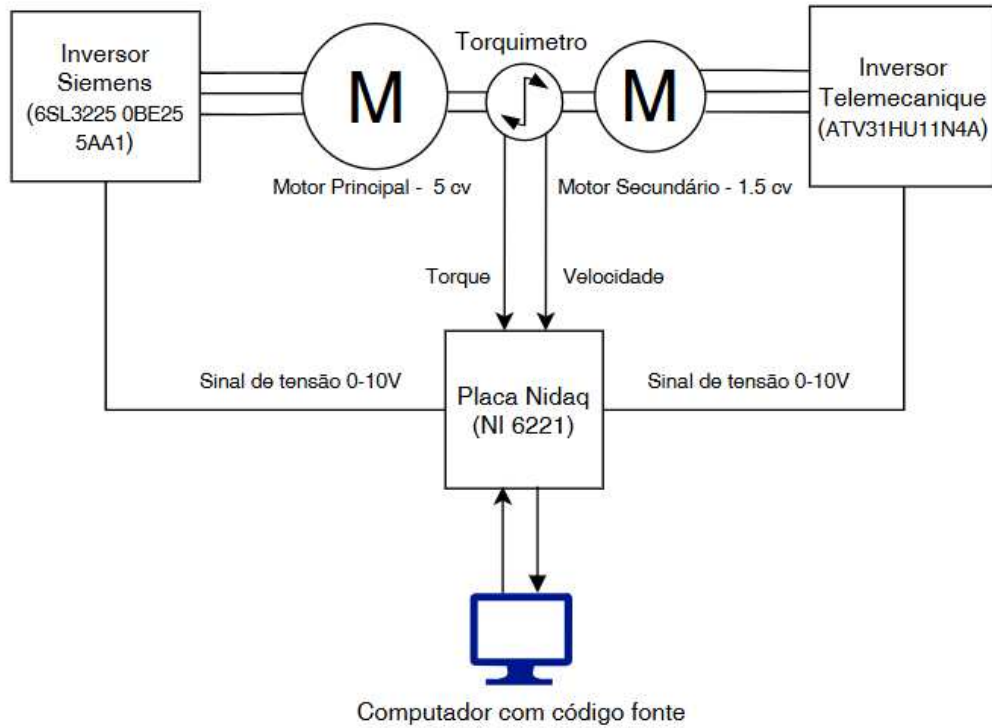
O acionamento da bancada experimental é realizado por um computador central, que controla os inversores de frequência e realiza a aquisição de dados por meio da placa de aquisição de dados NI-6221. A comunicação entre os dispositivos ocorre via sinais analógicos de 0 a 10 V, responsáveis por ajustar a velocidade dos motores e capturar as medições do torquímetro.

Inicialmente, é necessário configurar os inversores. O inversor Siemens SINAMICS G120, que aciona o motor principal de 5 cv, é parametrizado pelo software TIA Portal conforme as especificações do motor. O inversor Telemecanique Altivar 31 (ATV31HU11N4A), responsável pelo motor secundário de 1,5 cv, deve ser ajustado para operar via entrada digital, desativando o controle manual, conforme indicado no manual Schneider Electric (2004).

Após essa configuração, o controle da bancada ocorre por meio de um código em Python executado no computador central (Apêndice A). Esse código converte a velocidade desejada em um sinal analógico entre 0 e 10 V, que é enviado para os inversores via placa NI-6221. Os inversores utilizam esse sinal para ajustar a frequência de saída e controlar a velocidade dos motores.

A aquisição de dados ocorre simultaneamente, com o torquímetro medindo torque e velocidade do motor principal. Esses sinais são enviados para a placa NI-6221, que os converte e transfere ao computador para processamento pelo mesmo código de controle. Dessa forma, a bancada permite a análise do comportamento dinâmico do motor sob diferentes condições de carga.

Figura 10 – Esquemático completo da bancada de trabalho



Fonte: Próprio Autor

Figura 11 – Bancada de trabalho real



Fonte: Próprio Autor

4 RESULTADOS

A proposta deste trabalho é controlar a velocidade do motor principal de 5 cv, descrito na Seção 3.1, e avaliar seu desempenho diante de perturbações de carga emuladas pelo motor secundário de 1.5 cv. O estudo concentra-se na aplicação do método VRFT para o ajuste de um controlador PI e na análise do impacto de diferentes modelos de referência no comportamento dinâmico do sistema, conforme apresentado na Tabela 7.

Além disso, o ponto principal dos resultados obtidos é avaliar o impacto de cada modelo de referência escolhido no desempenho do sistema e do controlador projetado frente a variações de perturbação de carga. Isso porque o modelo é escolhido com base em critérios de desempenho desejados, como tempo de acomodação, sensibilidade a perturbações, entre outros. Para este trabalho, optou-se por utilizar como referência modelos de primeira ordem devido à sua simplicidade prática. Dessa forma, as principais métricas analisadas foram o tempo de acomodação e a rejeição a perturbações, a tabela 6 resume os parâmetros obtidos.

Para determinar o tempo de acomodação no domínio discreto, de acordo com Ogata (1995), considera-se a relação com o polo, onde, para o critério de 5%, tem-se:

$$T_s = \frac{\ln(0.05)}{\ln |p|} \quad (4.1)$$

Onde $|p|$ é o módulo do polo da função de transferência do modelo avaliado.

É válido ressaltar também que, quanto mais próximo o polo está do círculo unitário, mais lenta será a resposta do sistema, pois a dinâmica torna-se mais amortecida, resultando em um maior tempo de acomodação. Por outro lado, polos mais afastados de 1 aceleram a resposta do sistema, reduzindo o tempo de acomodação, mas podem tornar o controlador mais agressivo e sensível a perturbações, amplificando oscilações indesejadas (OGATA, 1995).

Por fim, os ganhos para os modelos foram obtidos foram adotados considerando uma abordagem prática que equilibra a resposta desejada com a simplicidade da implementação. Um ganho menor (0.1) reduz a agressividade do controle, permitindo um comportamento mais estável e menos sensível a perturbações, enquanto um ganho maior (0.2) aumenta a capacidade do sistema de responder mais rapidamente às variações na entrada. Embora não tenha sido realizada uma análise teórica detalhada para essa escolha, a definição empírica dos ganhos foi validada pelos ensaios experimentais, garantindo um desempenho adequado para os objetivos do estudo.

Tabela 6 – Modelos de referência e tempos de acomodação

Modelo	Função de Transferência	Tempo de Acomodação (s)
$m_1(z)$	$\frac{0.1}{1 + 0.9z^{-1}}$	28.43
$m_2(z)$	$\frac{0.2}{1 + 0.6z^{-1}}$	5.86
$m_3(z)$	$\frac{0.2}{1 - 0.8z^{-1}}$	13.43

Fonte: Próprio Autor

Tabela 7 – Modelos de referência e controladores ajustados

Modelo	K_p	K_i	Controlador $C(z)$
$m_1(z)$	0.00020068	0.00020067	$C_1(z) = 0.00020068 + \frac{0.00020067}{1 - z^{-1}}$
$m_2(z)$	0.00114478	0.00114479	$C_2(z) = 0.00114478 + \frac{0.00114479}{1 - z^{-1}}$
$m_3(z)$	0.00157801	-0.00114325	$C_3(z) = 0.00157801 - \frac{0.00114325}{1 - z^{-1}}$

Fonte: Próprio Autor

Os valores de K_p e K_i foram determinados a partir da resolução dos parâmetros ρ_d obtidos para cada modelo de referência a partir do código em Python considerando um tempo de amostragem de 1 segundo, como mostrado no Apêndice A

O experimento inicia-se com o acionamento em rampa dos dois motores em malha aberta, partindo de 0 rpm e adicionando 100 rpm a cada segundo até atingir 2000 rpm. Em seguida, mantém-se o sistema estável por 10 s antes de acionar o controlador VRFT, que permanece controlando o motor principal em 2000 rpm por mais 10 s. Finalmente, o motor menor atua como perturbação de carga, provocando variação de torque no sistema.


Para avaliar o desempenho em cenários distintos, analisaram-se duas estratégias de perturbação. Na primeira, descrita na Seção 4.1, o motor secundário impõe uma perturbação em degrau de curta duração. Já na segunda, apresentada na Seção 4.2, investigou-se a resposta a uma perturbação senoidal. O código utilizado para o acionamento completo em malha fechada com as perturbações está disponível no Apêndice A

4.1 Cenário com perturbação em degrau

Neste cenário, após o acionamento do sistema em malha aberta e a ativação do controlador aos 30 s, ambos os motores atingiram velocidades próximas a 2000 rpm. Em seguida, para impor uma perturbação de carga, a velocidade do motor secundário foi reduzida para 1800 rpm aos 40 s, representando uma queda de aproximadamente 10% e respeitando o fator de serviço do motor (15%). Essa condição perdurou até os 45 s, quando o motor menor retornou à velocidade de 2000 rpm.

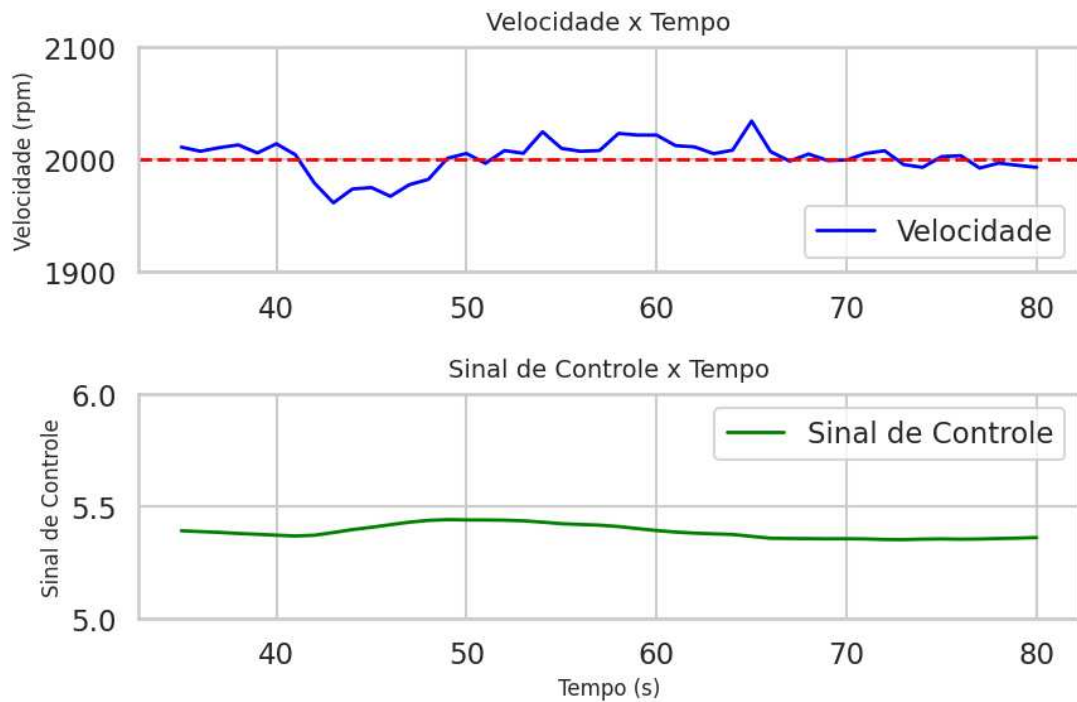
O experimento teve duração total de 80 s, com um passo de aquisição de 1 s para leitura e envio de dados à placa Nidaq. A mesma configuração foi aplicada a cada um dos modelos de referência listados na Tabela 7, cujos resultados são apresentados a seguir:

Figura 12 – Resultado do experimento para modelo de referência m_1 com perturbação em degrau



Fonte: Próprio Autor

Figura 13 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação em degrau para m_1 .



Fonte: Próprio Autor

A partir das figuras apresentadas, nota-se que o sinal de controle varia pouco, conferindo ao sistema uma resposta mais suave. Entretanto, o tempo necessário para corrigir a velocidade após a perturbação é maior. Isso ocorre devido à dinâmica mais lenta do modelo de referência m_1 , cujo polo em -0.9 está próximo do limite do círculo unitário, reduzindo a agressividade do controle. Como consequência, a perturbação demora mais para ser rejeitada, impactando diretamente a métrica de erro acumulado. O tempo de acomodação calculado para esse modelo foi de 28,43 s, o maior entre os modelos analisados, o que confirma a resposta mais lenta do sistema.


Tabela 8 – Métricas de desempenho para Modelo de Referência m_1 com perturbação em degrau

Métrica	Valor
IAE	588.6799
TV	0.2253

Fonte: Próprio Autor


Dessa forma, a suavidade do controle é comprovada pelo baixo valor de TV, enquanto a menor agressividade na correção de perturbações resulta em um alto IAE, indicando maior acúmulo de erro ao longo do tempo.

Figura 14 – Resultado do experimento para modelo de referência m_2 com perturbação em degrau



Fonte: Próprio Autor

Figura 15 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação para m_2 com perturbação em degrau.



Fonte: Próprio Autor

A resposta do sistema ao modelo de referência m_2 evidencia um controle mais agressivo, reduzindo significativamente o tempo de correção da velocidade após a perturbação. Isso ocorre pois o polo em -0.6 confere uma dinâmica mais rápida, exigindo uma atuação mais intensa do controlador. O tempo de acomodação calculado para esse modelo foi de 5.86 s, o menor entre os analisados, o que justifica a rápida rejeição do erro. No entanto, essa agressividade também impacta a variação da entrada de controle, portanto, espera-se observar um aumento significativo do TV com relação ao mostrado para o modelo m_1 .

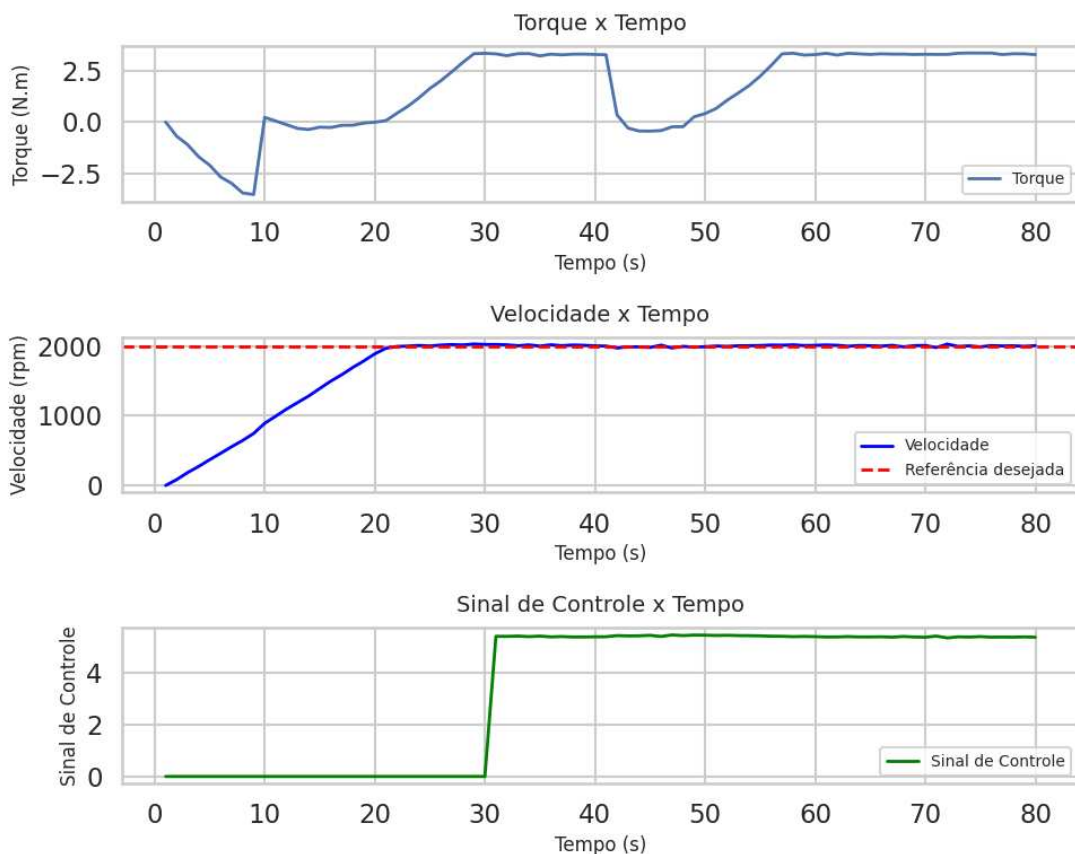
Tabela 9 – Métricas de desempenho para Modelo de Referência m_2 com perturbação em degrau

Métrica	Valor
IAE	378.2000
TV	0.6576

Fonte: Próprio Autor


Assim, observa-se que o controle gerado pelo VRFT para esse modelo minimiza o erro acumulado (IAE), melhorando a rejeição da perturbação. No entanto, o aumento do TV indica que essa melhora é alcançada à custa de um maior esforço de controle.

Figura 16 – Resultado do experimento para modelo de referência m_3 com perturbação em degrau



Fonte: Próprio Autor

Figura 17 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação para m_3 com perturbação em degrau



Fonte: Próprio Autor

Para o modelo m_3 , a resposta apresenta um comportamento distinto devido ao polo positivo em $+0.8$, o que leva a um menor amortecimento. O tempo de acomodação para esse modelo foi calculado em 13.43 s, um valor intermediário entre os demais modelos, refletindo um equilíbrio entre tempo de resposta e suavidade. A ação de controle se torna mais intensa, buscando estabilizar a resposta do sistema. Isso justifica o maior valor de TV entre os modelos analisados, enquanto o IAE se situa em um nível intermediário, pois o controlador responde rapidamente, mas com menor precisão na rejeição de erro.

Tabela 10 – Métricas de desempenho para Modelo de Referência m_3 com perturbação em degrau

Métrica	Valor
IAE	505.5699
TV	0.8253

Fonte: Próprio Autor

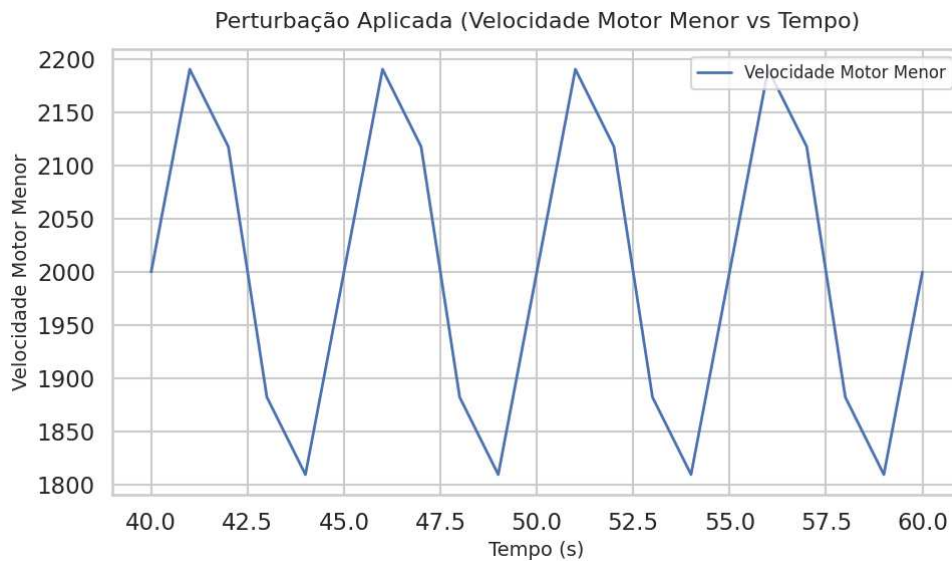
Com isso, verifica-se que o modelo m_3 proporciona uma resposta mais ágil, porém com maior variação no controle, evidenciado pelo alto TV. A falta de amortecimento pode comprometer a estabilidade em algumas condições, tornando esse modelo adequado para aplicações onde velocidade de resposta é prioritária, mas demandando atenção à estabilidade do sistema.

4.2 Cenário com perturbação senoidal

Para este caso, seguiu-se o mesmo princípio de acionamento do caso anterior, em que o controlador foi ativado aos 30 s de ensaio, após os motores atingirem a estabilização em 2000 rpm. No entanto, a perturbação de carga imposta pelo motor secundário teve um comportamento senoidal, variando sua velocidade entre 2200 e 1800 rpm, representando uma queda de aproximadamente 10% e respeitando o fator de serviço do motor (15%), com um período de 5 s. Essa perturbação foi aplicada entre 40 s e 60 s de ensaio, com o objetivo de avaliar a resposta do controle gerado para os diferentes modelos de referência frente a variações periódicas na carga.


O experimento teve duração total de 90 s, com um passo de aquisição de 1 s para leitura e envio de dados à placa Nidaq. A mesma configuração foi aplicada a cada um dos modelos de referência listados na Tabela 7, cujos resultados são apresentados a seguir:

Figura 18 – Perturbação de caráter senoidal aplicada




Fonte: Próprio Autor

Figura 19 – Resultado do experimento para modelo de referência m_1 em perturbação senoidal



Fonte: Próprio Autor

Figura 20 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_1 .



Fonte: Próprio Autor

A resposta do sistema ao modelo de referência m_1 evidencia um controle mais suave, resultando em uma variação menor na entrada de controle. Isso ocorre porque o polo em -0.9 confere uma dinâmica mais lenta ao sistema, o que limita a capacidade do controlador de acompanhar as oscilações impostas pela perturbação senoidal. Como consequência, espera-se observar um maior erro acumulado (IAE) devido à dificuldade do sistema em rastrear as variações de entrada.

Entretanto, diferentemente da perturbação em degrau, onde este modelo apresentou o maior erro acumulado, a resposta à perturbação senoidal mostra um comportamento distinto. Como mostrado na seção anterior, este modelo respondeu de forma mais lenta ao degrau, acumulando um erro significativo. Porém, na presença de uma perturbação senoidal, o sistema demonstrou menor sensibilidade a oscilações periódicas, conforme as figuras acima. Desse modo, nota-se que o tempo de acomodação mais lento desse modelo (28,43 s) contribui para um comportamento mais robusto frente a oscilações frequentes.


Tabela 11 – Métricas de desempenho para Modelo de Referência m_1 em perturbação senoidal

Métrica	Valor
IAE	628.9150
TV	0.2151

Fonte: Próprio Autor


Assim, observa-se que o controle gerado pelo VRFT para esse modelo mantém um esforço de controle reduzido, refletido pelo baixo TV. Neste caso, nota-se a redução do IAE em comparação a perturbação em degrau. Isso indica que a menor agressividade do controle atenua parte dos efeitos da perturbação, evitando amplificação excessiva das oscilações impostas.

Figura 21 – Resultado do experimento para modelo de referência m_2 em perturbação senoidal



Fonte: Próprio Autor

Figura 22 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_2 .



Fonte: Próprio Autor

Como é visto nos resultados acima, observa-se um aumento expressivo na oscilação de velocidade e sinal de controle, indicando que este modelo apresenta maior sensibilidade a oscilações frequentes. Como discutido anteriormente, o modelo m_2 foi eficiente em reduzir o erro acumulado na resposta ao degrau, devido a posição do seu polo mais afastada do valor unitário dentro do ciclo. Entretanto, essa característica resulta em uma maior susceptibilidade a perturbações senoidais, pois o controle busca constantemente corrigir as variações da entrada. O tempo de acomodação de 5.86 s, o menor entre os modelos, demonstra que esse modelo responde rapidamente, mas a falta de amortecimento faz com que ele amplifique oscilações na presença de perturbações senoidais.

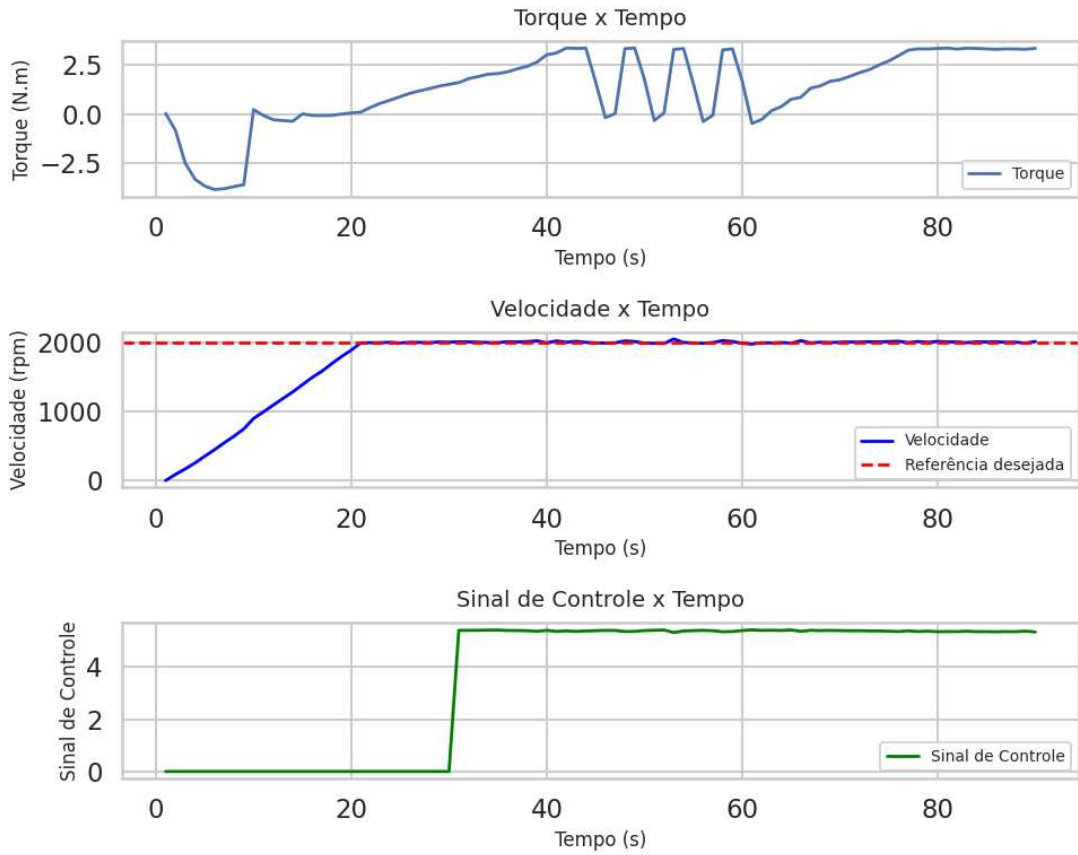
Tabela 12 – Métricas de desempenho para Modelo de Referência m_2 em perturbação senoidal

Métrica	Valor
IAE	810.1700
TV	1.5218

Fonte: Próprio Autor


Desse modo, observa-se que o controle gerado pelo VRFT para esse modelo torna o sistema mais sensível a variações na entrada, reagindo de forma intensa às perturbações senoidais. Esse comportamento leva a uma amplificação da oscilação, resultando em um aumento tanto do IAE quanto do TV.

Figura 23 – Resultado do experimento para modelo de referência m_3 em perturbação senoidal



Fonte: Próprio Autor

Figura 24 – Detalhe da resposta da velocidade e da lei de controle a partir do instante da perturbação senoidal para m_3 .



Fonte: Próprio Autor

A resposta do sistema ao modelo de referência m_3 apresenta um comportamento distinto devido ao polo positivo em $+0.8$, o que confere menor amortecimento à resposta do sistema. Nota-se, pelos gráficos acima que esse modelo permite um rastreamento mais preciso da perturbação senoidal. No entanto, a menor amortecimento pode aumentar a sensibilidade do sistema a oscilações, resultando em um TV intermediário entre os modelos analisados.

Comparando com a perturbação em degrau, o modelo m_3 manteve um desempenho equilibrado. Como discutido na seção anterior, o tempo de acomodação de 13.43 s reforça que este modelo mantém um equilíbrio entre tempo de resposta e suavidade no controle. Na perturbação senoidal, essa característica se mostrou vantajosa, pois o sistema conseguiu acompanhar melhor as oscilações impostas sem amplificar excessivamente a entrada de controle.

Tabela 13 – Métricas de desempenho para Modelo de Referência m_3 em perturbação senoidal

Métrica	Valor
IAE	563.5999
TV	1.010

Fonte: Próprio Autor

Logo, a partir das métricas analisadas, nota-se que o controle gerado pelo VRFT para esse modelo equilibra bem o rastreamento da perturbação senoidal com um esforço de controle moderado. O menor IAE indica que o sistema conseguiu acompanhar a oscilação imposta com menor erro, enquanto o TV intermediário sugere que a ação de controle não foi excessivamente agressiva, tornando esse modelo uma opção viável para perturbações oscilatórias.

4.3 Considerações Finais

Os ensaios realizados permitiram avaliar o impacto da escolha do modelo de referência no desempenho do controlador VRFT, destacando diferenças no erro acumulado (IAE) e na variação do controle (TV) para perturbações em degrau e senoidais.

No ensaio com perturbação em degrau, o modelo m_1 apresentou a maior persistência do erro devido à sua resposta mais lenta, mas com menor esforço de controle. O modelo m_2 , por outro lado, respondeu mais rapidamente, reduzindo o erro acumulado à custa de um maior TV. Já o modelo m_3 apresentou um comportamento intermediário, conciliando velocidade de resposta e controle moderado da variação da entrada.

Na perturbação senoidal, o comportamento dos modelos se diferenciou do observado no degrau. O modelo m_1 mostrou-se mais robusto, apresentando menor erro acumulado do que

m_2 , que se mostrou excessivamente sensível à oscilação, amplificando as variações e elevando o TV. O modelo m_3 manteve um equilíbrio entre rastreamento e suavidade, lidando bem com a perturbação periódica.

Além disso, por se tratar de um sistema físico, é importante considerar a presença de erros inerentes que podem influenciar os resultados obtidos. Fatores como ruídos no sinal, vibrações externas e imprecisões nos sensores e equipamentos utilizados introduzem pequenas variações que impactam nos resultados mostrado anteriormente.

É válido comentar ainda sobre a resposta do torque. Nota-se pelos gráficos que, como o torque não está sofrendo nenhuma ação direta de controle ele varia muito mais com a perturbação e mesmo após o sistema ser perturbado, o torque demora mais tempo para retornar ao estado inicial, mesmo com a estabilização da velocidade. Isso pode estar relacionado à influência do controle de velocidade na corrente do motor. Além disso, em termos de robustez, deve-se considerar que, além do fator principal de escolha dos modelos de referência, a diferença de potência entre o motor principal, alvo do controlador, e o motor secundário, que atua como perturbação de carga, é relevante para que o sistema rejeite as perturbações de maneira mais eficiente.

Dessa forma, os resultados reforçam que a escolha do modelo de referência impacta diretamente o desempenho do controlador, sendo necessário um equilíbrio entre estabilidade, tempo de resposta e esforço de controle para cada tipo de perturbação.

5 CONCLUSÕES E TRABALHOS FUTUROS

Portanto, com base nos resultados obtidos e na fundamentação teórica apresentada no Capítulo 2, conclui-se que a aplicação do método *Virtual Reference Feedback Tuning* (VRFT), embasada nos estudos de (BAZANELLA *et al.*, 2012) e (CAMPI *et al.*, 2002), foi realizada com sucesso. O método foi implementado em tempo discreto para o ajuste de um controlador PI, aplicado a um motor de indução trifásico. Os ensaios experimentais, conduzidos em uma bancada de laboratório, possibilitaram a análise do desempenho do controlador frente a diferentes modelos de referência de primeira ordem, considerando perturbações em degrau e senoidais. As métricas de erro acumulado (IAE) e variação total do controle (TV) foram utilizadas para avaliar o impacto da escolha do modelo de referência na robustez do sistema e na rejeição de perturbações.

Os resultados demonstraram que a escolha do modelo de referência influencia diretamente o desempenho do sistema. Modelos com polos mais próximos de 1 apresentaram maior tempo de acomodação, resultando em uma resposta mais lenta e robusta a oscilações frequentes, como observado no modelo m_1 . Por outro lado, modelos com polos mais afastados, como m_2 , responderam mais rapidamente, reduzindo o erro acumulado na perturbação em degrau, mas tornando-se mais suscetíveis a oscilações na presença de perturbações senoidais. O modelo m_3 , com o polo positivo, apresentou um equilíbrio entre tempo de acomodação e suavidade do controle, sendo uma opção viável para aplicações que demandam rastreamento rápido sem amplificação excessiva das oscilações.

Além disso, a análise das perturbações evidenciou que a interação entre controle de velocidade e rejeição de perturbações desempenha um papel fundamental no comportamento do sistema. A diferença de potência entre os motores influenciou a percepção da perturbação, enquanto a atuação do controlador impactou diretamente a estabilização da velocidade.

Dessa forma, este trabalho contribui para o entendimento do impacto da escolha do modelo de referência no método VRFT, oferecendo uma base sólida para futuras investigações e aprimoramentos no projeto de controladores baseados em dados.

Adiante, são previstos trabalhos propondo a utilização de novas abordagens. Uma das possibilidades é explorar a aplicação de modelos de referência de ordem superior, investigando como a inclusão de dinâmica adicional impacta a performance do controlador. Outra direção relevante consiste na avaliação de diferentes estruturas de controladores, como controle adaptativo ou preditivo, buscando aprimorar a resposta do sistema a diferentes tipos de perturbação.

Por fim, considera-se como possibilidade também avaliar a comparação dos controladores obtidos por métodos clássicos, relacionado ao MBC com o controlador obtido por meio do método VRFT a partir dos dados da planta.

REFERÊNCIAS

- BAZANELLA, A. S.; CAMPESTRINI, L.; ECKHARD, D. **Data-Driven Controller Design: The H2 Approach**. London: Springer, 2012. P. 27–39.
- BAZANELLA, A. S.; CAMPESTRINI, L.; ECKHARD, D. The data-driven approach to classical control theory. **Annual Reviews in Control**, Elsevier, v. 37, n. 1, p. 12–22, 2013.
- CAMPI, M. C.; LECCHINI, A.; SAVARESI, S. M. Virtual reference feedback tuning: a direct method for the design of feedback controllers. **Automatica**, Elsevier, v. 38, n. 8, p. 1337–1346, 2002.
- DOYLE, J. C.; FRANCIS, B. A.; TANNENBAUM, A. R. **Feedback Control Theory**. Englewood Cliffs, NJ: Macmillan Publishing Company, Inc., 1995.
- DOYLE, J. C.; ZHOU, K.; GLOVER, K. **Robust and Optimal Control**. Englewood Cliffs, NJ: Prentice-Hall, 1996.
- FRANKLIN, G. F.; POWELL, J. D.; EMAMI-NAEINI, A. **Feedback Control of Dynamic Systems**. [S. l.]: Prentice Hall, 2014. v. 1993.
- GARCIA, C. S. **Ajuste baseado em dados de controladores: o método VRFT embarcado em um aplicativo móvel**. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2023. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, UFRGS, 2023.
- HJALMARSSON, H.; GUNNARSSON, S.; GEVERS, M. A convergent iterative restricted complexity control design scheme. In: IEEE. **Proceedings of 1994 33rd IEEE conference on decision and control**. [S. l.], 1994. v. 2, p. 1735–1740.
- HOU, Z. S. The parameter identification, adaptive control and model free learning adaptive control for nonlinear systems. **Shenyang: North-eastern University**, 1994.
- HOU, Z.-S.; WANG, Z. From model-based control to data-driven control: Survey, classification and perspective. **Information Sciences**, v. 235, p. 3–35, 2013. ISSN 0020-0255. Data-based Control, Decision, Scheduling and Fault Diagnostics. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0020025512004781>.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions ASME, Series D, Journal of Basic Engineering**, v. 82, p. 34–45, 1960.
- LJUNG, L. **System Identification: Theory for the User**. Englewood Cliffs, NJ: Prentice-Hall, 1999.
- Magtrol. **TM Series In-Line Torque Transducers**. [S. l.], 2024. Acesso em: 19 fev. 2025. Disponível em: <https://www.magtrol.com/wp-content/uploads/tm300-series.pdf>.
- National Instruments. **PCI/PXI/USB-6221 68 Pin Specifications**. [S. l.], 2023. Acesso em: 19 fev. 2025. Disponível em: https://mm.digikey.com/Volume0/opasdata/d220001/medias/docus/5343/PCI-PXI-USB-6221_Spec.pdf.
- OGATA, K. **Discrete-Time Control Systems**. 2. ed. Upper Saddle River, NJ: Prentice Hall, 1995. ISBN 978-0130342812.

Schneider Electric. **Altivar 31: Inversores de Freqüência para Motores Assíncronos**. [S. l.], 2004. Acesso em: 21 fev. 2025. Disponível em: <https://docs.rs-online.com/9548/0900766b805721dd.pdf>.

Siemens. **SINAMICS Power Module PM250: Data Sheet**. [S. l.], 2021. Acesso em: 21 fev. 2025. Disponível em: https://support.industry.siemens.com/cs/attachments/109482010/G120_PM250_hw_inst_man_0421_en-US.pdf.

SKOGESTAD, S. Simple analytic rules for model reduction and pid controller tuning. **Journal of Process Control**, v. 13, n. 4, p. 291–309, 2004.

WAARDE, H. J. van; EISING, J.; TRENTELMAN, H. L.; CAMLIBEL, M. K. **Data informativity: a new perspective on data-driven analysis and control**. 2020.

WEG S/A. **Seleção de Motores Elétricos**. [S. l.], 2025. Acesso em: 21 fev. 2025. Disponível em: https://ecatalog.weg.net/tec_cat/tech_motor_sel_web.asp.

WILLEMS, J. C.; RAPISARDA, P.; MARKOVSKY, I.; MOOR, B. L. D. A note on persistency of excitation. **Systems & Control Letters**, Elsevier, v. 54, n. 4, p. 325–329, 2005.

ZIEGLER, J. G.; NICHOLS, N. B. Optimum settings for automatic controllers. **Transactions of the American society of mechanical engineers**, American Society of Mechanical Engineers, v. 64, n. 8, p. 759–765, 1942.

APÊNDICE A – CÓDIGOS UTILIZADOS PARA IMPLEMENTAÇÃO DO VRFT E EXPERIMENTO EM MALHA FECHADA

Código-fonte 1 – Código Python para obter os controlador desejado

```

1 import numpy as np
2 import matplotlib.pyplot as plt
3 from scipy.signal import lfilter
4 from control.matlab import tf
5
6 # Leitura dos dados de entrada e saida do arquivo
7 data = np.loadtxt('ensaio_prbs.txt', delimiter=';')
8
9 T_data = T_data = np.arange(0, 300)
10 U_data = data[:, 0] # Entrada
11 Y_data = data[:, 1] # Saida
12 # Processamento dos dados
13 t = T_data
14 u = U_data
15 y = Y_data
16
17 # Definir os parametros do sistema baseado nos dados coletados
18 Ts = 1 # Passo de amostragem
19
20 numM = 0.2
21 denM = [1, 0.6]
22 # Definicao da func de transferencia M em tempo discreto
23 M = tf([numM], denM, Ts)
24 # Definir o filtro L(z)
25 lf = 0.0002
26 # L = tf([lf], [1], Ts)
27 L = (1 - M) * M * lf
28 # Gerar o controlador com VRFT
29 # Aplicar VRFT para obter os parametros rho do controlador
30 N = len(y)
31 phi_1 = []
32 phi_2 = []
33 e_barra = []
34 # Loop para calcular phi_1, phi_2 e e_barra

```

```

35 for k in range(2, N - 1):
36     # Conjunto de regressores
37     reg_y = np.array([y[k], y[k - 1]])
38     r_barra_val = np.dot(denM, reg_y) / numM
39     e_barra_val = r_barra_val - y[k]
40     e_barra.append(e_barra_val)
41     if len(phi_1) == 0:
42         phi_1.append(e_barra_val)
43         phi_2.append(0)
44     else:
45         phi_1.append(e_barra_val + phi_1[-1])
46         phi_2.append(e_barra[-2] * Ts + phi_2[-1])
47
48 # Convers o das listas em arrays numpy
49 phi_1 = np.array(phi_1)
50 phi_2 = np.array(phi_2)
51 phi = np.vstack((phi_1, phi_2)) # Matriz phi de 2 x (N - 3)
52
53 # Aplica o do filtro L em u
54 numerator_L = L.num[0][0]
55 denominator_L = L.den[0][0]
56 u_filtered = lfilter(numerator_L, denominator_L, u)
57
58 # Ajuste do tamanho de u_filtered para corresponder ao de phi
59 u_trimmed = u_filtered[2:N - 1] # Ajuste nos ndices aqui
60
61 # Verificar as dimens es
62 print('phi.shape:', phi.shape)
63 print('u_trimmed.shape:', u_trimmed.shape)
64
65 # Calculo dos parametros rho
66 phi_phi_T = phi @ phi.T
67 phi_u = phi @ u_trimmed
68 rho = np.linalg.inv(phi_phi_T) @ phi_u
69 print(f"rho = {rho}")

```

Código-fonte 2 – Código Python para o ensaio em malha fechada com perturbação

```

1 import datetime
2 import math
3 import nidaqmx # Biblioteca de intera o nidaq
4 import time
5 import matplotlib.pyplot as plt
6 import numpy as np
7 import pandas as pd
8
9 def tensao_acionameto(vel_maior, vel_menor):
10     with nidaqmx.Task() as task:
11         # Cria o de canal anal gico para tens o
12         task.ao_channels.add_ao_voltage_chan("Dev2/ao0:1")
13
14         tensao_me = vel_menor*10/3530
15         tensao_ma = vel_maior*10/3688
16
17         # Escreve os valores de tens o
18         task.write([tensao_me, tensao_ma])
19
20         # Exibe as tens es configuradas
21         #print("Tens o motor menor:", tensao_me, "Volts")
22         #print("Tens o motor maior:", tensao_ma, "Volts")
23
24         return tensao_ma, tensao_me, vel_maior, vel_menor
25
26 freq = 0
27
28 """LEITURA ENTRADA ANALOGICA"""
29 # import nidaqmx # Biblioteca de intera o nidaq
30 from datetime import datetime
31 import datetime as dt #Bibl. datetime como date
32
33 tp_ensaio = 85 # Tempo de ensaio determinado em segundos
34 ciclo = 0 # CONSTANTE N O ALTERAR - quantificador de ciclos
35
36 inicio = time.time() # Tempo de execu o do bloco de ensaio em segundos
37

```

```
38 # Valor do erro e da entrada anterior
39 u_ant = 0
40 e_ant = 0
41
42 # Referencia desejada
43 w_ref = 2000
44
45 # Inicializa o dos arrays que guardar o os dados
46 u_array = []
47 e_array = []
48
49 dados_torque = []
50 dados_velocidade = []
51 dados_tempo = []
52 array_tempo = []
53
54 sleep_time = 1
55
56 # Defini o da Velocidade Inicial
57 init_vel = 0
58
59 tensao_ma, tensao_me , vel_maior, vel_menor = tensao_acionameto(init_vel,
    init_vel)
60
61 # Inicializa o Gr fico tempo real
62 plt.ion()
63 fig, (ax1, ax2, ax3) = plt.subplots(3, 1, figsize=(8, 10))
64 line1, = ax1.plot([], [], color="b", linestyle="-", linewidth=2, label =
    "Torque")
65 line2, = ax2.plot([], [], color="g", linestyle="-", linewidth=2, label =
    "Velocidade")
66 line3, = ax3.plot([], [], color='r', linestyle='-', linewidth=2, label =
    "Lei de Controle")
67
68 ax1.set_title("Torque x Tempo")
69 ax1.set_xlabel("Tempo")
70 ax1.set_ylabel("Torque")
71
72 ax2.set_title("Velocidade x Tempo")
```

```

73 ax2.set_xlabel("Tempo")
74 ax2.set_ylabel("Velocidade")
75
76 ax3.set_title('Lei de controle')
77 ax3.set_xlabel("Tempo")
78 ax3.set_ylabel("u(k) ")
79
80 while ciclo < tp_ensaio : # Bloco de ensaio
81
82     with nidaqmx.Task() as task: #
83
84         task.ai_channels.add_ai_voltage_chan("Dev2/ai8:9") # Cria o
            canal analogico para tensao
85
86         """Coleta de dados"""
87         torque, velocTorquim = task.read() # task.read(n amostras,
            Tempo p/ amostras em segundos?
88
89         torqueARRED=round(torque,5) #arrendodamento na quinta casa
            decimal
90         velocARRED=round(velocTorquim,5) #arrendodamento na quinta casa
            decimal
91
92         dados_torque.append(torqueARRED*(-1))
93         dados_tempo.append(datetime.strftime(dt.datetime.now(), "%Ss "))
94         dados_velocidade.append(velocARRED*1000)
95
96         if ciclo >= 30:
97             # C lculo do erro
98             e = w_ref - (velocARRED*1000)
99             # print('Parametros (Vel), (Erro), (Ref)', velocARRED*1000, e,
                w_ref)
100         if(ciclo == 30):
101             u_ant = tensao_ma
102
103             #u_k = u_ant + 0.00157801 * e - 0.00114325 * e_ant # num = 0.2 e
                den = -0.8 lf = 0.0002
104
105             #u_k = u_ant + 0.00020068 * e + 0.00020067 * e_ant # num = 0.1 e

```

```
den = 0.9 lf = 0.0002
106
107 u_k = u_ant + 0.00114478 * e + 0.00114479 * e_ant # num = 0.2 e
den = 0.6 lf = 0.0002
108
109 u_ant = u_k
110 e_ant = e
111
112 e_array.append(e)
113 u_array.append(u_k)
114
115 # Tratamento para tensao nao exceder os limites durante o ensaio
116 if u_k < 0 or u_k > 10:
117     print('tensao excedeu os limites', u_k)
118     tensao_ma, tensao_me , vel_maior, vel_menor =
119         tensao_acionameto(0, 0)
120     break
121
122 vel_control = (u_k * 3688) / 10 #C lculo da velocidade em RPM a
123 ser enviada a partir do sinal de controle
124
125 tensao_ma, tensao_me , vel_maior, vel_menor = tensao_acionameto(
126     vel_control, 2000)
127
128 if ciclo >= 40 and ciclo <= 60: # Bloco da perturba o
129     periodo = 5
130
131     # Frequncia da oscila o (1 ciclo completo a cada 10
132     segundos)
133     frequencia = 1 / periodo
134
135     # Tens o m xima e m nima
136     vel_max = 2200
137     vel_min = 1800
138
139     # Calcular o tempo do ciclo no intervalo [0, 10]
140     tempo = ciclo % periodo # Isso garante que o ciclo reinicie
141     a cada 10 segundos
142
143
```

```

138     # Varia o senoidal da tens o (corrigido para oscilar
        entre vel_min e vel_max)
139     tensao_variacao = (vel_max - vel_min) / 2 * math.sin(2 * math
        .pi * frequencia * tempo) + (vel_max + vel_min) / 2
140
141     print('senoidal',tensao_variacao, ciclo)
142     tensao_ma, tensao_me , vel_maior, vel_menor =
        tensao_acionameto(vel_control, tensao_variacao)
143     # if ciclo % 2 == 0:
144     #     tensao_ma, tensao_me , vel_maior, vel_menor =
        tensao_acionameto(vel_control, tensao_variacao)
145     # else:
146     #     tensao_ma, tensao_me , vel_maior, vel_menor =
        tensao_acionameto(vel_control, vel_menor)
147
148     else: #Bloco do acionamento em Rampa at os 20 seg
149         e_array.append(0)
150         u_array.append(0)
151         if ciclo >= 20:
152             tensao_ma, tensao_me , vel_maior, vel_menor =
                tensao_acionameto(vel_maior, vel_menor) # Velocidade de
                cruzeiro
153         else:
154             tensao_ma, tensao_me , vel_maior, vel_menor =
                tensao_acionameto(vel_maior + 100, vel_menor + 100) #
                Aumento da velocidade antes dos 20 seg
155
156     # Mudan a de refer ncia em t=30s
157     # if ciclo >= 40:
158     #     w_ref = 1500
159
160     array_tempo.append(sleep_time+ciclo)
161
162     line1.set_xdata(array_tempo)
163     line1.set_ydata(dados_torque)
164     line2.set_xdata(array_tempo)
165     line2.set_ydata(dados_velocidade)
166     line3.set_xdata(array_tempo)
167     line3.set_ydata(u_array)

```

```
168
169     ax1.relim()
170     ax1.autoscale_view()
171     ax2.relim()
172     ax2.autoscale_view()
173     ax3.relim()
174     ax3.autoscale_view()
175
176     plt.tight_layout()
177     plt.draw()
178     plt.pause(0.01)
179
180
181     time.sleep(sleep_time) # tempo entre amostras
182     ciclo+=1
183
184
185     print('FIM DE ENSAIO -----')
186     tensao_ma, tensao_me , vel_maior, vel_menor = tensao_acionameto(0, 0)
187     print(tensao_ma, tensao_me)
188
189     df = pd.DataFrame({
190         'Tempo': array_tempo,
191         'Torque': dados_torque,
192         'Velocidade': dados_velocidade,
193         'Lei de Controle': u_array
194     })
195
196     # Nome do arquivo CSV
197     filename = 'dados_ensaio.csv'
198
199     # Salvar o DataFrame como CSV
200     df.to_csv(filename, index=False)
201
202     # ""PLOTAGEM GR FICA""
203     plt.ioff()
204     plt.tight_layout()
205     plt.show()
```