Universidade de São Paulo–USP
Escola de Engenharia de São Carlos
Departamento de Engenharia Elétrica e de Computação
Programa de Pós-Graduação em Engenharia Elétrica

Paulo Roberto Ubaldo Guazzelli

Controle Preditivo de Torque do Motor de Indução com Otimização dos Fatores de Ponderação por Algoritmo Genético Multiobjetivo

São Carlos
2017

Paulo Roberto Ubaldo Guazzelli

Controle Preditivo de Torque do Motor de Indução com Otimização dos Fatores de Ponderação por Algoritmo Genético Multiobjetivo

Dissertação de mestrado apresentada ao Programa de Engenharia Elétrica da Escola de Engenharia de São Carlos como parte dos requisitos para a obtenção do título de Mestre em Ciências.

Área de concentração: Sistemas Dinâmicos

Orientador: Manoel Luís de Aguiar

São Carlos

2017

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

G919c

Guazzelli, Paulo Roberto Ubaldo
Controle Preditivo de Torque do Motor de Indução com Otimização dos Fatores de Ponderação por Algoritmo Genético Multiobjetivo / Paulo Roberto Ubaldo Guazzelli; orientador Manoel Luís de Aguiar. São Carlos, 2017.

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Dinâmicos -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2017.

1. Controle preditivo de torque. 2. Motor de indução. 3. Algoritmo genético multiobjetivo. 4. Fatores de ponderação. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **PAULO ROBERTO UBALDO GUAZZELLI.**

Título da dissertação: "Controle preditivo de torque do motor de indução com otimização dos fatores de ponderação por algoritmo genético multiobjetivo".

Data da defesa: 20/02/2017.

Comissão Julgadora:	**Resultado:**
Prof. Dr. **Manoel Luís de Aguiar** **(Orientador)** (Escola de Engenharia de São Carlos/EESC)	Aprovado
Prof. Dr. **Marcelo Favoretto Castoldi** (Universidade Tecnológica Federal do Paraná/UTFPR)	APROVADO
Prof. Dr. **Rodrigo Andreoli de Marchi** (Instituto Federal de São Paulo/IFSP)	APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luís Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luís Fernando Costa Alberto**

Este trabalho é dedicado à minha mãe, Maria Aparecida Ubaldo,
que me amou, educou e ensinou o caminho de Deus.

Agradecimentos

Agradeço primeiramente a Deus, pela vida, pela provisão e por permitir o desenvolvimento deste trabalho. À minha mãe, Maria Aparecida Ubaldo, pelo amor e carinho dedicado.

Ao Prof. Dr. Manoel Luís de Aguiar, pela importante orientação e supervisão durante a execução deste trabalho, ao Prof. Dr. José Roberto Boffino de Almeida Monteiro, pelo auxílio no projeto da bancada experimental, ao Prof. Dr. Ivan Nunes da Silva, por ceder equipamentos necessários ao desenvolvimento do trabalho experimental. Ao Prof. Dr. Marcelo Suetake, pela recomendação de realizar o mestrado na Escola de Engenharia de São Carlos.

Aos amigos do laboratório, William, Carlos, Thales, Allan, Luan, Marcelo, Tati, Edson e Geyverson, pelo auxílio e companhia no desenvolvimento do trabalho.

À Escola de Engenharia de São Carlos e à Universidade de São Paulo, pela estrutura disponibilizada, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, pelo suporte financeiro.

Aos irmãos e amigos em Cristo, pela comunhão, amizade e orações.

"E sabemos que todas as coisas contribuem juntamente
para o bem daqueles que amam a Deus, daqueles
que são chamados segundo o seu propósito."
(Bíblia Sagrada, Romanos 8:28)

Resumo

Guazzelli, Paulo Roberto Ubaldo **Controle Preditivo de Torque do Motor de Indução com Otimização dos Fatores de Ponderação por Algoritmo Genético Multiobjetivo**. 94 p. Dissertação de mestrado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2017.

Neste trabalho investiga-se a aplicação de um algoritmo genético multiobjetivo, ferramenta que se destaca por sua flexibilidade e interpretabilidade, na obtenção de fatores de ponderação para aplicação no controle preditivo de torque do motor de indução, ou *Model Predictive Torque Control* (MPTC). O MPTC busca minimizar a cada instante de atuação uma função custo que representa o sistema, destacando-se pela rápida resposta de torque, facilidade de incorporar restrições e ausência de modulador de tensão. No entanto, essa técnica apresenta fatores de ponderação em sua estrutura de cálculo que não dispõem de métodos analíticos de projeto. Utilizou-se o algoritmo genético de classificação não-dominada, ou *Non-dominated Sorting Genectic Algorithm II* (NSGA-II), projetado de forma a obter soluções que busquem o compromisso entre o desempenho dinâmico do motor, via minimização das oscilações de torque e fluxo, e a eficiência energética do sistema por meio da minimização da frequência média de chaveamento da eletrônica de potência. Resultados simulados e experimentais mostraram que o conjunto de soluções fornecido pelo NSGA-II é factível e contrapõe as oscilações de torque e de fluxo e a frequência média de chaveamento, cabendo à aplicação desejada a escolha da solução. Com isso, tem-se uma ferramenta de projeto dos fatores de peso do MPTC capaz de incorporar restrições e ajustar vários fatores ao mesmo tempo.

Palavras-chave: Algoritmo genético multiobjetivo. Controle preditivo de torque. Fatores de ponderação. Motor de indução.

Abstract

Guazzelli, Paulo Roberto Ubaldo **Multi-Objective Genetic Algorithm Optimization of Predictive Torque Control Weighting Factors for Induction Motor Drives**. 94 p. Master Thesis – São Carlos School of Engineering, University of São Paulo, 2017.

This work investigates the application of a multi-objective genetic algorithm to obtain a set of weighting factors suitable for use in Model Predictive Torque Control (MPTC) of a induction motor variable speed drive. MPTC approach aims at minimizing a cost function at each step, and is highlighted for its fast torque response, facility to incorporate system constraints and the absence of voltage modulators. Nevertheless, MPTC structure presents weighting factors in the cost function which lack of an analytical design procedure. The Non-dominated Sorting Genetic Algorithm II (NSGA-II) was designed for a trade-off between torque and flux ripples minimization and minimization of the average switching frequency of the system. Simulated and experimental results showed NSGA-II offered a Pareto set of feasible solutions, so that torque ripple, flux ripple or average switching frequency can be minimized, depending on the solution chosen according to project demand. Thereby, there is a project tool for MPTC weighting factors able to adjust several factor at the same time, incorporating desired restrictions.

Keywords: Induction motor. Genetic algorithm. Multi-objective optimization. Predictive control.

Lista de ilustrações

Figura 1 Referenciais de representação das variáveis elétricas do motor de indução - trifásico e ortogonal estacionários. 37

Figura 2 Circuito esquemático do inversor de tensão de dois níveis (a) e mapa dos possíveis vetores ativos de tensão aplicados (b). 39

Figura 3 Sistema de controle MPTC de velocidade do motor de indução. 40

Figura 4 Sistema de controle MRMPTC de velocidade do motor de indução. . . 44

Figura 5 Fluxograma de funcionamento do AG, para otimização de sistemas. . . 48

Figura 6 Soluções dispostas no plano de aptidão, para minimização de x_1 e x_2 - divisão em classes não-dominadas 1 (branco), 2 (cinza) e 3 (preto). . . 50

Figura 7 Fluxograma de funcionamento do NSGA-II, para otimização de sistemas. 51

Figura 8 Efeito de diferentes valores de T_{band} no desempenho do MPTC, para κ_2 e λ_3 fixos. 55

Figura 9 Efeito de diferentes valores de κ_2 no desempenho do MPTC, para T_{band} e λ_3 fixos. 56

Figura 10 Efeito de diferentes valores de λ_3 no desempenho do MPTC, para T_{band} e κ_2 fixos. 57

Figura 11 Bancada de ensaios experimentais para acionamento e controle do MIT. 62

Figura 12 Diagrama de blocos da bancada 1 com o esquema de conexão do gerador CC para produção de torque de carga. 63

Figura 13 Gráfico vetorial do fluxo de estator do MIT, a 500 rpm sem carga, para fatores de ponderação da solução A - simulado (a) e experimental (b). . 66

Figura 14 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque, para fatores de ponderação da solução A - simulado (a) e experimental (b). 67

Figura 15 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para fatores de ponderação da solução A - simulado (a) e experimental (b). 67
Figura 16 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para fatores de ponderação da solução A - simulado (a) e experimental (b). 68
Figura 17 Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução B - simulado (a) e experimental (b). . 69
Figura 18 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para solução B - simulado (a) e experimental (b). . . . 69
Figura 19 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para solução B - simulado (a) e experimental (b). 70
Figura 20 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para solução B - simulado (a) e experimental (b). 70
Figura 21 Fronteira de Pareto obtida pelo NSGA-II para otimização de torque e fluxo do MPTC aplicado ao MIT - fenótipo (a) e genótipo (b). 71
Figura 22 Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução C - simulado (a) e experimental (b). . 72
Figura 23 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b). 72
Figura 24 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b). 73
Figura 25 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b). 73
Figura 26 Fronteira de Pareto obtida pelo NSGA-II para otimização de torque, fluxo e frequência do MPTC aplicado ao MIT - fenótipo (a) e genótipo (b). 74
Figura 27 Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D1 - simulado (a) e experimental (b). 75
Figura 28 Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D2 - simulado (a) e experimental (b). 76
Figura 29 Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D3 - simulado (a) e experimental (b). 76
Figura 30 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b). 77

Figura 31 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b). 77
Figura 32 Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b). 77
Figura 33 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b). 79
Figura 34 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b). 79
Figura 35 Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b). 79
Figura 36 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b). 80
Figura 37 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b). 80
Figura 38 Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b). 80
Figura 39 Índices de desempenho experimentais obtidos a 1500 rpm pelas soluções consideradas - sem carga (a) e com carga (b). 81

Lista de tabelas

Tabela 1 Tensões resultantes nos eixos $\alpha\beta$ do motor de indução em função do vetor de tensão aplicado pelo inversor. 39

Tabela 2 Parâmetros do MIT para simulação do modelo e para execução do MPTC. 54

Tabela 3 Limites máximos e mínimos de cada gene dos indivíduos do NSGA-II. . 58

Tabela 4 Parâmetros utilizados no AGM desenvolvido para otimização dos fatores de ponderação. 60

Tabela 5 Indicadores de desempenho experimentais obtidos para o MPTC com solução padrão, em regime de 1500 rpm, para duas condições de carga. 68

Tabela 6 Indicadores de desempenho experimentais obtidos para o MRMPTC, em regime de 1500 rpm, para duas condições de carga. 70

Tabela 7 Solução selecionada para testes de validação do MPTC com torque e fluxo otimizados pelo NSGA-II. 72

Tabela 8 Indicadores de desempenho experimentais obtidos para MPTC com fatores de ponderação da solução C, em regime de 1500 rpm, para duas condições de carga. 74

Tabela 9 Três soluções selecionadas para testes de validação do MPTC com torque, fluxo e frequência otimizados pelo NSGA-II. 75

Tabela 10 Indicadores de desempenho experimentais obtidos para as três soluções da otimização considerando frequência de chaveamento, em regime de 1500 rpm, para duas condições de carga. 78

Tabela 11 Relações de dominância entre as soluções testadas para cada combinação de índices, em regime de 1500 rpm, para duas condições de carga. . 81

Tabela 12 Parâmetros das soluções do NSGA-II obtidos para a otimização de oscilação de torque e de fluxo, e respectivos valores das funções objetivo. 93

Tabela 13 Parâmetros das soluções do NSGA-II para a otimização de oscilação de torque, de fluxo e frequência de chaveamento, e respectivos valores das funções objetivo. 94

Lista de siglas

AG Algoritmo Genético

AGM Algoritmo Genético Multiobjetivo

CC Corrente Contínua

DSP *Digital Signal Processor*

DTC *Direct Torque Control*

DTC-SVM *Direct Torque Control Space Vector Modulation*

FOC *Field Oriented Control*

FS-MPC *Finite State Model Predictive Control*

MIT Motor de Indução de Teste

MPC *Model Predictive Control*

MPCC *Model Predictive Current Control*

MPTC *Model Predictive Torque Control*

MRMPTC *Multi Ranking Model Predictive Torque Control*

NSGA *Non-dominated Sorting Genectic Algorithm*

NSGA-II *Non-dominated Sorting Genectic Algorithm II*

PSO *Particle Swarm Optimization*

PI Proporcional-Integral

SVM *Space Vector Modulation*

SPEA *Strength Pareto Evolutionary Algorithm*

THD *Total Harmonic Distortion*

VIKOR *VlseKriterijuska Optimizacija I Komoromisno Resenje*

VEGA *Vector-Evaluated Genetic Algorithm*

Lista de símbolos

Notações e Operadores

$\dot{}$	Notação para a derivada de uma variável em relação ao tempo
$\hat{}$	Notação para variáveis estimadas
$\|\ \ \|$	Operador módulo de variável vetorial
$\|\ \ \|$	Operador módulo de variável escalar
*	Notação para uma variável de referência
$'$	Operador conjugado de uma variável vetorial
negrito	Notação para variáveis vetoriais - com duas componentes ortogonais

Símbolos Gregos

κ_2	Fator de aumento do fator de ponderação λ_2 em relação à razão inicial de projeto
λ	Fator de ponderação da função custo padrão do MPTC
λ_1	Fator de ponderação do MPTC que atua sobre a dinâmica de torque
λ_2	Fator de ponderação do MPTC que determina a relação de importância entre torque e fluxo
λ_3	Fator de ponderação do MPTC para minimização da frequência de chaveamento
ω_λ	Velocidade angular do referencial adotado
ω_m	Velocidade angular mecânica do motor
Ψ_{nom}	Fluxo de estator nominal do motor de indução

Ψ_{rip}	Oscilação de fluxo do motor de indução
ψ_r	Fluxo de rotor do motor de indução
ψ_s	Fluxo de estator do motor de indução
σ	Relação das indutâncias do motor de indução

Símbolos Romanos

$\overline{f_c}$	Frequência de chaveamento média do inversor
F	Coeficiente de atrito viscoso do motor
h	Ordem de predição do MPTC
i_r	Corrente de rotor do motor de indução
i_s	Corrente de estator do motor de indução
I_{MAX}	Máxima corrente permitida do motor de indução
J	Momento de inércia do motor
k	Instante atual do sistema de controle
L_h	Indutância mútua do motor de indução
L_r	Indutância de rotor do motor de indução
L_s	Indutância de estator do motor de indução
p	Número de pares de polos do motor
P_{frac}	Fração de Pareto
R_r	Resistência de rotor do motor de indução
R_s	Resistência de estator do motor de indução
S_i	Estados das chaves do inversor de tensão
T	Torque eletromagnético do motor
t_D	Tempo de discretização do sistema de controle
T_L	Torque de carga
T_{nom}	Torque nominal do motor de indução
T_{rip}	Oscilação de torque do motor de indução

v_s	Tensão de estator do motor de indução
$v_{\alpha\beta}$	Tensões de fase medidas no referencial ortogonal estacionário $\alpha\beta$
v_{ABC}	Tensões de fase medidas no referencial trifásico ABC
v_{CC}	Tensão do barramento CC do inversor de tensão
x	Indivíduo pertencente à população do NSGA-II
$y(x)$	Função objetivo do problema de otimização

Subscritos

$\alpha\beta$	Referencial ortogonal para variáveis do motor de indução
ABC	Referencial trifásico das variáveis do motor de indução
r	Variáveis relativas ao rotor do motor de indução
s	Variáveis relativas ao estator do motor de indução

Sumário

1 Introdução **29**

1.1 Motivação e Relevância do Trabalho 29

1.1.1 Controle Preditivo Baseado em Modelo 30

1.1.2 Otimização por meio de Sistemas Inteligentes 32

1.2 Objetivos do Trabalho 33

1.3 Organização da Dissertação 34

1.4 Publicações 34

2 Modelagem e Controle do Motor de Indução **37**

2.1 Modelagem Matemática do Sistema 37

2.1.1 Motor de Indução Trifásico 37

2.1.2 Inversor de Tensão Trifásico 39

2.2 Controle Preditivo de Torque 40

2.2.1 Estimação de Torque e Fluxo 40

2.2.2 Predição de Torque e Fluxo 41

2.2.3 Avaliação da Função Custo 42

2.2.4 Adição de Objetivos Secundários 42

2.2.5 Compensação de Atraso 44

2.2.6 Controle Preditivo sem Fatores de Ponderação 44

2.3 Conclusões Parciais 45

3 Algoritmos Genéticos **47**

3.1 Algoritmo Genético Mono-objetivo 47

3.2 Algoritmo Genético Multiobjetivo 48

3.3 Estrutura do NSGA-II 49

3.4 Controle de Elitismo do NSGA-II 50

3.5 Conclusões Parciais 52

4 Otimização Multiobjetivo dos Fatores de Ponderação **53**
4.1 Etapas de Projeto 53
4.2 Especificação do Motor de Indução 54
4.3 Definição dos Indivíduos e Funções Objetivo 54
4.4 Estrutura e Operadores do NSGA-II 58

5 Simulação Computacional e Bancada de Ensaios Experimentais **61**
5.1 Simulação em Ambiente Computacional 61
5.2 Bancada Experimental de Controle e Acionamento 61

6 Resultados e Discussões **65**
6.1 Testes Realizados 65
6.2 Controle Preditivo Convencional 66
6.3 Controle Preditivo de Classificação Multiobjetivo 68
6.4 Otimização de Torque e Fluxo 71
6.5 Otimização da Frequência de Chaveamento 74
6.6 Discussões 81

7 Considerações Finais **83**
7.1 Conclusões Finais 83
7.2 Diretivas de Trabalhos Futuros 84

Referências **85**

Apêndices **91**

APÊNDICE A Soluções Otimizadas do NSGA-II **93**

Capítulo 1

Introdução

1.1 Motivação e Relevância do Trabalho

Os motores elétricos são amplamente utilizados na indústria, em virtude de várias vantagens sobre os demais tipos de motores, tais como baixo custo, limpeza, facilidade de comando e controle, construção simples e alto rendimento (UMANS, 2014). Dentre os motores elétricos, o motor de indução destaca-se em diversas aplicações industriais por requerer pouca manutenção devido ao fato de não possuir escovas e comutador, além do seu baixo custo de aquisição e manutenção quando comparado ao motor de Corrente Contínua (CC) (TRZYNADLOWSKI, 2001). No entanto, para sua operação também em aplicações de velocidade variável requer-se um acionamento com tensão com frequência variável (UMANS, 2014, p. 563). O avanço da eletrônica de potência e o desenvolvimento de técnicas de controle próprias para o motor de indução buscaram preencher essa lacuna.

O controle escalar busca manter o fluxo do motor aproximadamente constante, enquanto varia a amplitude e a frequência da tensão aplicada sobre o motor, para variação da velocidade. No entanto, essa estratégia apresenta baixo desempenho dinâmico (MARTINS et al., 1998). O desenvolvimento dos dispositivos embarcados permitiram o estudo de técnicas mais elaboradas de controle. Duas técnicas de controle do motor de indução devem ser destacadas na literatura (CASADEI; PROFUMO; TANI, 2002): o controle de campo orientado, ou *Field Oriented Control* (FOC) (BLASCHKE, 1971), e o controle de torque direto, ou *Direct Torque Control* (DTC) (TAKAHASHI; OHMORI, 1989). O FOC parte da modelagem vetorial do motor de indução (BLASCHKE, 1971) e busca desacoplar as variáveis que controlam o torque e o fluxo da máquina. Desse modo, essas variáveis podem ser controladas de maneira independente, como ocorre naturalmente, no motor CC (BLASCHKE, 1971). O DTC por sua vez utiliza comparadores de histerese para controlar o torque do motor de indução. Cada técnica apresenta vantagens e desvantagens: O FOC destaca-se por desacoplar o controle de torque e fluxo, além de possuir baixas perdas de chaveamento, porém possui muitas transformações de coordenadas e malhas internas de controle; o DTC também opera desacoplado mas apresenta uma estrutura mais simples,

sem transformações e com menos controladores, a despeito de uma maior oscilação de torque e corrente e uma frequência de chaveamento variável, causando maiores perdas de chaveamento (CASADEI; PROFUMO; TANI, 2002). Para reduzir a oscilação de torque do DTC, foi proposto o *Direct Torque Control Space Vector Modulation* (DTC-SVM) (ZELECHOWSKY, 2005), substituindo a tabela de chaveamento pelo modulador de tensão *Space Vector Modulation* (SVM).

Uma solução alternativa que tem sido usada recentemente no controle do motor de indução é o chamado controle preditivo baseado em modelo, ou *Model Predictive Control* (MPC). A partir do modelo da planta, prediz-se qual a ação de controle que minimizará uma determinada função custo. Como essa estratégia opera a partir do modelo da planta, no caso o motor de indução e sua eletrônica de potência, por natureza o MPC torna-se interessante, já que permite que se incorporem nele as não-linearidades e restrições da planta (RODRIGUEZ; CORTES, 2012). Essa técnica é o ponto de partida de investigação do presente trabalho e será delineada nos tópicos seguintes e explicitada no corpo desta dissertação.

1.1.1 Controle Preditivo Baseado em Modelo

Entendem-se por MPC técnicas que busquem predizer o comportamento da planta com base em seu modelo matemático de forma a minimizar uma função custo que represente os objetivos de controle (KENNEL; LINDER, 2000). O controle preditivo de estados finitos, ou *Finite State Model Predictive Control* (FS-MPC), é adequado para uso em sistemas com possibilidades finitas de atuação na planta, e tem sido aplicado com sucesso em plantas com conversores de potência, como sistemas de controle e acionamento de máquinas elétricas, uma vez que as combinações de chaveamento são limitadas (KOURO et al., 2009; RODRIGUEZ et al., 2013). Nesses sistemas o FS-MPC testa o comportamento do sistema para cada possível combinação de chaveamento e seleciona aquela que minimiza a função custo do problema.

Dentre as estratégias de FS-MPC para o controle do motor de indução podem-se destacar: o controle preditivo de torque, ou *Model Predictive Torque Control* (MPTC), que controla de forma direta o torque e o fluxo de estator do motor, assim como o DTC; e o controle preditivo de corrente, ou *Model Predictive Current Control* (MPCC), que controla duas correntes em quadratura, de forma análoga ao FOC. As técnicas MPTC e MPCC foram comparadas em Wang et al. (2015), onde se mostrou que o MPTC proporciona menor oscilação de torque, enquanto que o MPCC possibilita correntes com melhor qualidade e possui um menor esforço de cálculo. O controle MPTC foi comparado ao FOC em Rodriguez et al. (2012) para uma mesma frequência média de chaveamento e destacou-se que o MPTC possui menor complexidade, ausência de moduladores, assim como de controladores internos em sua estrutura, em oposição ao FOC, que necessita do projeto de controladores internos, usualmente Proporcional-Integrais (PIs). Ainda, os

autores em Davari (2016) desenvolveram o controle preditivo de torque e do ângulo entre corrente de estator e fluxo de rotor, a partir do MPTC e conceitos do FOC, com base na análise do modelo do motor e do impacto desse ângulo no torque eletromagnético.

A técnica MPTC apresenta rápida dinâmica de torque com operação em ampla faixa de velocidade tanto em regime quanto em transiente (WANG et al., 2014). O MPTC efetua uma melhor seleção dos vetores de tensão do que o DTC uma vez que o primeiro tem sua escolha baseada em um processo de otimização, enquanto que o segundo baseia-se em uma tabela heurística (ZHANG; YANG, 2016). Ainda, MPTC apresenta uma menor frequência média de chaveamento (GEYER; PAPAFOTIOU; MORARI, 2009). Técnicas de controle preditivo também se destacam por permitir que se adicionem termos auxiliares no problema de minimização, chamados de objetivos secundários de controle (CORTES et al., 2009). Apesar disso, para o caso do MPTC ainda há avanços a serem feitos. Os principais desafios são: redução da oscilação de torque, limitação da frequência de chaveamento, projeto e ajuste dos fatores de ponderação, sensibilidade paramétrica e redução do seu custo computacional (RODRIGUEZ et al., 2012).

Os fatores de ponderação inerentes ao MPTC, ou fatores de peso, são parâmetros em sua função custo que influenciam o comportamento dinâmico do sistema e seu ajuste depende de um compromisso entre os desempenhos dinâmicos de torque e de fluxo (ZHANG; YANG, 2016). A consideração de outras variáveis de controle como a frequência média de chaveamento e corrente de estator insere outros fatores de ponderação no ajuste do MPTC. A inclusão destes novos fatores aumenta o grau de liberdade do sistema, porém as variáveis minimizadas podem ter seus desempenhos em contradição. Assim, o seu projeto constitui um problema de otimização. De fato, o projeto dos fatores de peso do MPTC é um dos principais desafios à sua implementação na indústria (FORBES et al., 2015). O seu projeto é empírico, de modo que o ajuste tem sido feito na literatura por meio de tentativa e erro, com ajuste manual a partir de simulações (CORTES et al., 2009). Em Habibullah et al. (2017), utilizaram-se fatores de peso para minimizar o erro de torque e de fluxo, a frequência de chaveamento do inversor de 3 níveis e a sua tensão de neutro, e o ajuste dos fatores de ponderação foi feito um a um mediante análise do desempenho do sistema.

Adicionalmente, autores buscam implementar o MPTC sem o uso de fatores de peso. Esses parâmetros foram substituídos em Rojas et al. (2013) por uma abordagem de classificação multiobjetivo, em que os objetivos de torque e fluxo eram calculados e usados para classificar os vetores em ordem de menor erro. No entanto, essa alternativa eleva o custo computacional e aplica-se apenas ao MPTC com o objetivo de minimizar erros de torque e fluxo, sem a adição de objetivos secundários, que redundariam em novos fatores de peso para projeto. Um MPTC com seleção do vetor baseado em um algoritmo de decisão e compromisso chamado de *VlseKriterijuska Optimizacija I Komoromisno Resenje* (VIKOR), do sérvio, ou solução de otimização e compromisso de classificação multi

critério, foi desenvolvido em Muddineni, Bonala e Sandepudi (2016), que também depende de classificar os vetores, elevando custo computacional. Os autores em Zhang e Yang (2015) modificaram a função custo do MPTC, mantendo apenas erros de fluxo, com uma referência variável de fluxo de estator, em função da referência de torque, por meio de uma expressão trigonométrica. Assim, a função custo possui apenas termos de uma grandeza, não requerendo fatores de ponderação. Essa estratégia também é feita ao custo de elevar o esforço computacional do algoritmo de controle, e sem considerar os fatores advindos de outros objetivos. A mesma característica é presente em Rojas et al. (2015) onde um sistema multiobjetivo de decisão *fuzzy* foi utilizado para substituir os fatores de peso por coeficientes de prioridade entre as variáveis de torque, fluxo e tensão de neutro do inversor de tensão de três níveis utilizado.

Também se considera na literatura o ajuste *online* dos fatores de peso. No entanto, normalmente ajusta-se apenas um e fixam-se os restantes, como em Leuer e Bocker (2015), que utilizaram um controlador PI para ajuste em função da oscilação de corrente de um fator de peso do MPCC aplicado ao motor síncrono de ímãs permanentes; e Mahmoudi et al. (2016), que utilizaram um sistema de inferência *fuzzy* para ajuste do fator de peso relacionando as correntes do motor síncrono de ímãs permanentes, em função dos erros das correntes em quadratura. Um fator de ponderação do MPTC aplicado ao motor de indução foi otimizado analiticamente por (DAVARI; KHABURI; KENNEL, 2012), baseando-se no modelo do motor, sem considerar outros fatores de peso ou restrições adicionais.

1.1.2 Otimização por meio de Sistemas Inteligentes

Para o ajuste de mais de um fator de ponderação ao mesmo tempo, as técnicas baseadas em sistemas inteligentes, como Algoritmo Genético (AG) e otimização por enxame de partículas, ou *Particle Swarm Optimization* (PSO), mostram-se como interessantes alternativas, uma vez que podem ajustar vários parâmetros ao mesmo tempo, inclusive permitindo que se considerem as restrições adicionais do MPTC no projeto. Enquanto o PSO é baseado no movimento de enxame de partículas, os AGs têm por ideia fundamental emular o processo de sobrevivência e evolução das espécies, conceitos advindos da biologia.

AGs são grupos de ferramentas que buscam as soluções mais adaptadas (ótimas) para um dado problema (WEATHERFORD; BRICE, 2003). Intuitivos e flexíveis, AGs são mais resistentes a máximos e mínimos locais do que métodos tradicionais de otimização por gradiente (KAMPISIOS et al., 2008). A interpretabilidade do AG, devido ao seu fundo biológico, e à sua ausência de projeto analítico entram em consonância com as vantagens do MPTC. AGs não requerem grande conhecimento do modelo analítico da planta. AGs que busquem otimizar mais de um índice de desempenho são conhecidos como Algoritmo Genético Multiobjetivos (AGMs), e são ferramentas que buscam encontrar um conjunto

de soluções adequadas para o problema de otimização, em lugar de uma única solução, de forma que não se pode dizer que uma é superior à outra.

Zanchetta (2011) usou um AGM para otimizar três parâmetros de um FS-MPC aplicado a um filtro ativo de potência paralelo, buscando minimizar diferentes combinações de índices, como *Total Harmonic Distortion* (THD) da corrente da fonte, frequência média de chaveamento e potência reativa de entrada. Em MC NAMARA et al. (2013), utilizou-se um PSO para ajuste dos pesos de um MPC distribuído de um sistema elétrico de potência. Ainda, um AG foi utilizado em Martínez, Senent e Blasco (1998) para determinação da ação de controle a cada instante de tempo por um algoritmo MPC generalizado distribuído, a fim de minimizar a comunização entre os agentes, mantendo um desempenho dinâmico desejado. No entanto, o processo de otimização do MPTC aplicado ao motor de indução restringe-se atualmente a um parâmetro e índice por vez, como em Su et al. (2016) onde um PSO foi utilizado para decidir a tensão ótima e minimizar a função custo padrão do MPTC de forma online, sem adição de restrições. Este trabalho investiga o uso do AGM para a otimização de mais de um fator de ponderação ao mesmo tempo, a saber três, considerando restrições adicionais na função custo, e otimizando até três índices de desempenho.

1.2 Objetivos do Trabalho

A partir da necessidade de projeto dos fatores de ponderação do MPTC aplicado ao motor de indução, da existência de vários objetivos de desempenho e com base na capacidade de otimização dos AGMs, os objetivos específicos deste trabalho são:

a) Inserir na estrutura do MPTC elementos para minimizar a frequência média de chaveamento do conversor;

b) Analisar a importância dos fatores de ponderação do MPTC nas dinâmicas de torque, fluxo e corrente e na frequência média de chaveamento do conversor;

c) Implementar em ambiente computacional um AGM para otimização de três fatores de ponderação, visando minimizar oscilações de torque e de fluxo, além de buscar minimizar a frequência média de chaveamento do conversor, a partir de simulações da planta;

d) Obter um conjunto de soluções capaz de relacionar a oscilação de torque com a frequência média de chaveamento do sistema, em que seja possível minimizar variáveis como desejado;

e) Validar as soluções fornecidas pelo AGM experimentalmente, por meio da implementação do MPTC em um motor de indução real, analisando o comportamento da planta real e das simulações, em testes de reversão de velocidade, distúrbios de carga e análise de indicadores de desempenho em regime permanente.

A execução dos objetivos delineados mostrará uma alternativa de projeto dos fatores de peso do MPTC que engloba a minimização da frequência de chaveamento na sua estrutura, sem adicionar custo computacional à execução do controle.

1.3 Organização da Dissertação

Após tratar sobre o MPTC aplicado ao motor de indução, dos estudos realizados em favor de ajustar seus fatores de ponderação, bem como dos objetivos e justificativa deste trabalho no Capítulo 1, o Capítulo 2 apresenta os fundamentos teóricos a respeito do motor de indução e de seu modelo matemático, assim como da estrutura e operação do MPTC utilizados na elaboração deste trabalho.

O Capítulo 3 trata a respeito de algoritmos genéticos, discutindo sobre técnicas multiobjetivo e apresentando a topologia utilizada neste trabalho.

No Capítulo 4, apresentam-se as questões referentes à estrutura e implementação do algoritmo de otimização dos fatores de ponderação do MPTC, como os parâmetros a serem otimizados e as variáveis consideradas.

As considerações referentes às simulações computacionais desenvolvidas para validação e aquelas referentes à realização em bancada, como a descrição dos hardwares utilizados em laboratório, são feitas no Capítulo 5.

No Capítulo 6, apresentam-se as soluções fornecidas pelo AGM, e os resultados simulados em MATLAB® e experimentais em laboratório do MPTC com as soluções otimizadas, bem como com uma solução empírica, seguidos das respectivas discussões.

Por fim, o Capítulo 7 traz as conclusões finais do trabalho sobre o uso do AGM na otimização dos fatores de ponderação do MPTC, e apresentam-se diretivas de trabalhos futuros.

1.4 Publicações

Durante o período de mestrado, o candidato a Mestre em Ciências desenvolveu os seguintes artigos:

a) GUAZZELLI, P. R. U.; OLIVEIRA, C. M. R.; CASTRO, A. G.; PEREIRA, W. C. A.; AGUIAR, M. L. Electric Vehicle Hardware-In-the-Loop Simulation with Differentiator Optimised by Genetic Algorithm. In: 2016 12th IEEE International Conference on Industry Applications (INDUSCON), 2016, Curitiba - PR. **Proceedings...** [S.l.] : IEEE, 2016.

b) GUAZZELLI, P. R.; SUETAKE, M.; EVANGELISTA, S. H.; OGASHAWARA, O. Análise de Controladores Fuzzy para Motor de Indução Aplicado na Modelagem e Simulação de Veículo Elétrico. In: DINCON 2015 - Conferência Brasileira de Dinâmica, Controle e Aplicações, 2015, Natal - RN. **Proceeding Series of the**

Brazilian Society of Computational and Applied Mathematics, v. 4, n. 1. [S.l.] : SBMAC, 2016. ISSN: 2359-0793.

c) GUAZZELLI, P. R. U.; SUETAKE, M.; EVANGELISTA, S. H.; FRANCISCO, C. A.; OGASHAWARA, O. Modelagem e simulação de veículo elétrico com motor de indução controlado por sistema fuzzy PD incremental. In: XII SBAI - Simpósio Brasileiro de Automação Inteligente, 2015, Natal - RN. **Anais...** [S.l.] : SBA, 2015.

d) GUAZZELLI, P. R. U.; SUETAKE, M.; EVANGELISTA, S. H.; OGASHAWARA, O. Modelling and Simulation of an Electric Vehicle: Analysis and Solutions for Improving Mechanical Performance. In: 23rd ABCM International Congress of Mechanical Engineering, 2015, Rio de Janeiro - RJ. **Proceedings...** [S.l.] : ABCM, 2016.

Ainda, outras publicações desenvolvidas pelo grupo de pesquisa e das quais o candidato participou são listadas abaixo:

a) CASTRO, A. G., PEREIRA, W. C. A., OLIVEIRA, C. M. R., ALMEIDA, T. E. P., GUAZZELLI, P. R. U., MONTEIRO, J. R. B. A., OLIVEIRA Jr, A. A. Finite Control-Set Predictive Power Control of BLDC Drive for Torque Ripple Reduction. **IEEE Latin America Transactions.** (Aceito para publicação).

b) OLIVEIRA, C. M. R.; GUAZZELLI, P. R. U.; CASTRO, A. G.; AGUIAR, M. L.; MONTEIRO, J. R. B. A. Otimização dos Parâmetros do Motor de Indução Trifásico Utilizando Algoritmo Genético com Minimização do Efeito Pelicular. In: **12th IEEE/IAS International Conference on Industry Applications.** [S.l.]: IEEE, 2016.

c) OLIVEIRA, C. M. R.; AGUIAR, M. L.; PEREIRA, W. C. ; GUAZZELLI, P. R. U.; SANTANA, M. P. ; PAULA, G. T.; ALMEIDA, T. E. P. Controle Vetorial da Máquina de Indução por Modos Deslizantes com Função Suave. In: DINCON 2015 - Conferência Brasileira de Dinâmica, Controle e Aplicações, 2015, Natal - RN. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics, v. 4, n. 1.** [S.l.] : SBMAC, 2016. ISSN: 2359-0793.

Capítulo 2

Modelagem e Controle do Motor de Indução

2.1 Modelagem Matemática do Sistema

A planta é essencialmente composta do motor de indução, acionado por um inversor de tensão trifásico. A correta modelagem dos dois componentes influi diretamente no funcionamento do MPTC, uma vez que por definição a predição baseia-se no conhecimento do modelo da planta, a fim de que o vetor de tensão mais adequado seja selecionado.

2.1.1 Motor de Indução Trifásico

Para simulação do motor de indução, utilizou-se o modelo com referencial $\alpha\beta$ estacionário, isto é, as variáveis trifásicas (tensões defasadas em 120° entre si) são convertidas para um referencial ortogonal $\alpha\beta$ fixo no estator (BARBI, 1985), como na Figura 1 .

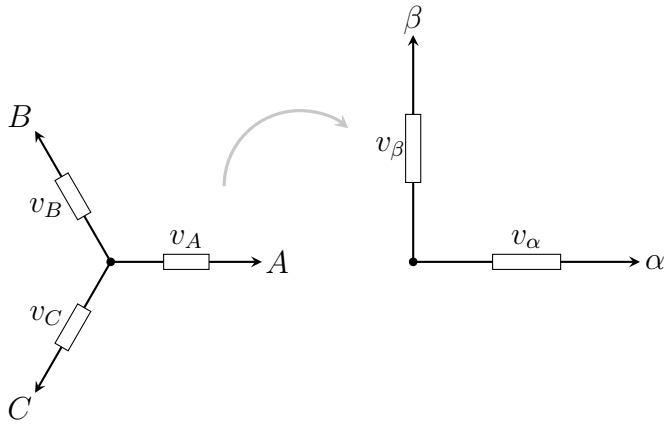

Figura 1: Referenciais de representação das variáveis elétricas do motor de indução - trifásico e ortogonal estacionários.

Para tal, segue-se (1), a partir das tensões de fase de estator v_{ABC} medidas no referencial trifásico ABC, obtêm-se as tensões $v_{\alpha\beta}$. A tensão de estator pode então ser

representada de forma vetorial, em negrito, para simplificação.

$$\boldsymbol{v_s} = \begin{bmatrix} v_\alpha \\ v_\beta \end{bmatrix} = \frac{2}{3} \begin{bmatrix} 1 & -\frac{1}{2} & \frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \cdot \begin{bmatrix} v_A \\ v_B \\ v_C \end{bmatrix} \tag{1}$$

O motor de indução trifásico com rotor em gaiola de esquilo tem seu modelo fundamentado no seu circuito de estator, de rotor, e na equação mecânica (VAS, 1990), como em (2),

$$\boldsymbol{v_s} = R_s \boldsymbol{i_s} + \frac{d\boldsymbol{\psi_s}}{dt} + j\omega_\lambda \boldsymbol{\psi_s} \tag{2a}$$

$$0 = R_r \boldsymbol{i_r} + \frac{d\boldsymbol{\psi_r}}{dt} + j\left(\omega_\lambda - p\omega_m\right)\boldsymbol{\psi_r} \tag{2b}$$

$$\boldsymbol{\psi_s} = L_s \boldsymbol{i_s} + L_h \boldsymbol{i_r} \tag{2c}$$

$$\boldsymbol{\psi_r} = L_h \boldsymbol{i_s} + L_r \boldsymbol{i_r} \tag{2d}$$

$$\frac{d\omega_m}{dt} = \frac{1}{J}\left(T - F\omega_m - T_L\right) \tag{2e}$$

$$T = \frac{3}{2} p \cdot \mathrm{Im}\{\boldsymbol{\psi_s'} \cdot \boldsymbol{i_s}\} \tag{2f}$$

onde $\boldsymbol{v_s}$, $\boldsymbol{i_s}$ e $\boldsymbol{\psi_s}$ denotam as seguintes variáveis: tensão, corrente e fluxo de estator; $\boldsymbol{i_r}$ e $\boldsymbol{\psi_r}$ são corrente e fluxo de rotor; R_s e R_r são as resistências de estator e de rotor, L_s, L_r as indutâncias de estator e de rotor, L_h é a indutância mútua. Quanto aos parâmetros mecânicos, o momento de inércia do motor é representado por J, o coeficiente de atrito viscoso por F, o torque de carga por T_L, e p refere-se ao número de pares de polos do motor. O torque eletromagnético desenvolvido é dado por T e a velocidade angular mecânica por ω_m. A variável ω_λ é a velocidade angular do referencial adotado. A notação "′" indica o conjugado de uma variável.

Definindo σ como uma relação adimensional entre as indutâncias, de modo que $\sigma = 1 - \frac{L_h^2}{L_s L_r}$, e mantendo apenas as variáveis de estator, chega-se ao modelo do motor de indução representado em (3), com quatro estados elétricos e um mecânico, orientado no referencial estacionário, em que $\omega_\lambda = 0$ (VAS, 1990):

$$\frac{d\boldsymbol{\psi_s}}{dt} = -R_s \boldsymbol{i_s} + \boldsymbol{v_s} \tag{3a}$$

$$\frac{d\boldsymbol{i_s}}{dt} = -\left(\frac{R_r}{\sigma L_r} + \frac{R_s}{\sigma L_s} - jp\omega_m\right)\boldsymbol{i_s} + \frac{1}{\sigma L_s}\left(\frac{R_r}{L_r} - jp\omega_m\right)\boldsymbol{\psi_s} + \frac{1}{\sigma L_s}\boldsymbol{v_s} \tag{3b}$$

$$\frac{d\omega_m}{dt} = \frac{1}{J}\left(\frac{3}{2} p \cdot \mathrm{Im}\{\boldsymbol{\psi_s'} \cdot \boldsymbol{i_s}\} - F\omega_m - T_L\right) \tag{3c}$$

2.1.2 Inversor de Tensão Trifásico

Neste trabalho, o atuador do sistema é um inversor de tensão de dois níveis, ilustrado na Figura 2 (a), onde v_{CC} é a tensão do barramento de CC, e S_i são os estados das chaves, em que $S_i = 1$ significa que a chave está ligada. Os três braços delimitam que o sistema de controle pode aplicar oito vetores de tensão, seis ativos e dois não ativos, como mostrado na Figura 2 (b).

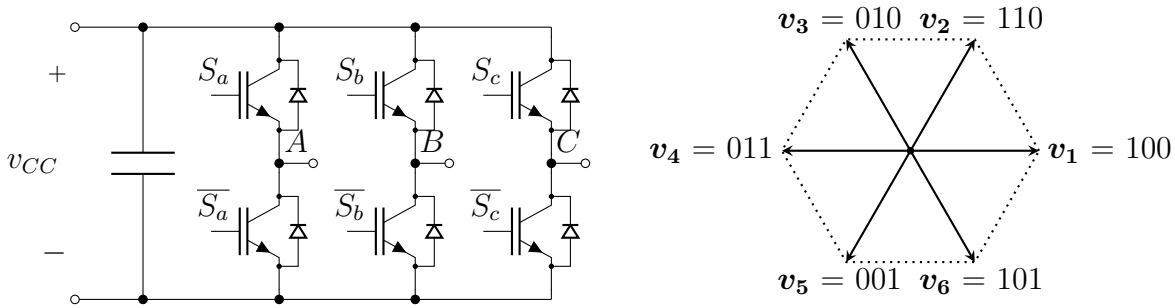

(a) Inversor de tensão de dois níveis. (b) Possíveis vetores ativos de tensão.

Figura 2: Circuito esquemático do inversor de tensão de dois níveis (a) e mapa dos possíveis vetores ativos de tensão aplicados (b).

A tensão de estator $\boldsymbol{v_s}$ aplicada pelo controle passa a ser função do vetor selecionado, como em (4), onde $a = e^{j2\pi/3}$ (WANG et al., 2015). Pode-se relacionar para cada vetor de tensão a tensão correspondente nos eixos $\alpha\beta$, a partir de (4) e (1), chegando à Tabela 1, para o motor conectado em estrela. Essa informação é usada no funcionamento do MPTC.

$$\boldsymbol{v_s} = \frac{2}{3} v_{CC} \left[S_a + a S_b + a^2 S_c \right]. \tag{4}$$

Tabela 1: Tensões resultantes nos eixos $\alpha\beta$ do motor de indução em função do vetor de tensão aplicado pelo inversor.

Vetor	Chaveamento	v_α	v_β
$\boldsymbol{v_0}$	000	0	0
$\boldsymbol{v_1}$	100	$\frac{2}{3}v_{CC}$	0
$\boldsymbol{v_2}$	110	$\frac{1}{3}v_{CC}$	$\frac{\sqrt{3}}{3}v_{CC}$
$\boldsymbol{v_3}$	010	$-\frac{1}{3}v_{CC}$	$\frac{\sqrt{3}}{3}v_{CC}$
$\boldsymbol{v_4}$	011	$-\frac{2}{3}v_{CC}$	0
$\boldsymbol{v_5}$	001	$-\frac{1}{3}v_{CC}$	$-\frac{\sqrt{3}}{3}v_{CC}$
$\boldsymbol{v_6}$	101	$\frac{1}{3}v_{CC}$	$-\frac{\sqrt{3}}{3}v_{CC}$
$\boldsymbol{v_7}$	111	0	0

2.2 Controle Preditivo de Torque

O sistema completo controlado pela técnica MPTC é ilustrado pela Figura 3. O MPTC controla o torque e a amplitude do fluxo de estator do motor, e destacam-se três etapas principais: estimação das variáveis necessárias à operação do MPTC no instante k; predição pelo MPTC das variáveis de controle no instante futuro $k+1$ para cada possível vetor de acionamento; e determinação e escolha de qual vetor de tensão minimizará a função custo em $k+1$, aplicando-o ao inversor.

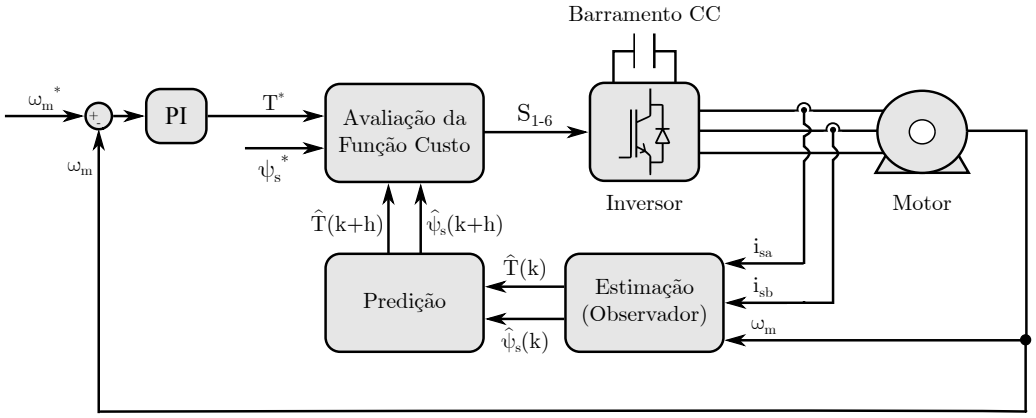

Figura 3: Sistema de controle MPTC de velocidade do motor de indução.

Adicionalmente, um barramento CC alimenta o inversor, que atua sobre o motor de indução. Duas correntes de fase são medidas, assumindo que o sistema seja equilibrado. A velocidade mecânica pode ser medida ou estimada por meio de técnicas *sensorless*. Ainda, há um controlador de velocidade, como um PI, responsável por determinar a referência de torque do sistema. Seguem as descrições das etapas de funcionamento do MPTC, e também considerações a respeito de adição de restrições, questões de implementação e alternativas ao uso dos fatores de peso.

2.2.1 Estimação de Torque e Fluxo

Uma estimação correta do torque e do fluxo do motor de indução é necessária para o correto funcionamento do MPTC, uma vez que não é possível medir fisicamente o fluxo de estator do motor, e sensores de torque aumentam o custo e complexidade mecânica do sistema. O fluxo de estator do motor de indução relaciona-se à tensão e corrente de estator de acordo com (5):

$$\boldsymbol{\psi_s} = \int (\boldsymbol{v_s} - R_s \boldsymbol{i_s})\, dt \tag{5}$$

No entanto, a obtenção do fluxo pela simples integração sofre de problemas de *drift* e *offset*, que degradam a qualidade do sinal integrado, em razão de existirem na prática erros de medição e condições iniciais não-ideais (PEREIRA, 2014, p. 51–54). Desse modo, requer-se o uso de observadores recursivos para estimação das variáveis desejadas e necessárias

ao controle (LASCU; ANDREESCU, 2006). Neste trabalho, a estimação destas variáveis foi feita por um observador de Luenberger de ordem completa, conforme (6), derivado a partir do modelo do motor em (3), que estima as variáveis de corrente e fluxo de estator (ZHANG et al., 2012). Variáveis estimadas são denotadas por "ˆ".

$$\frac{d\hat{\boldsymbol{\psi}}_s}{dt} = \boldsymbol{v}_s - R_s\hat{\boldsymbol{i}}_s + \mathbf{G_1}(\boldsymbol{i}_s - \hat{\boldsymbol{i}}_s) \tag{6a}$$

$$\frac{d\hat{\boldsymbol{i}}_s}{dt} = -\left(\frac{R_r}{\sigma L_r} + \frac{R_s}{\sigma L_s} - jp\omega_m\right)\hat{\boldsymbol{i}}_s + \frac{1}{\sigma L_s}\left(\frac{R_r}{L_r} - jp\omega_m\right)\hat{\boldsymbol{\psi}}_s + \frac{1}{\sigma L_s}\boldsymbol{v}_s + \mathbf{G_2}(\boldsymbol{i}_s - \hat{\boldsymbol{i}}_s) \tag{6b}$$

$$\hat{T} = \frac{3}{2}p \cdot \mathrm{Im}\{\hat{\boldsymbol{\psi}}'_s \cdot \hat{\boldsymbol{i}}_s\} \tag{6c}$$

onde as matrizes G_1 e G_2 são calculadas de acordo com (7), e b é um parâmetro positivo de projeto, ajustado manualmente. Análise acerca da estabilidade do observador encontra-se em Yongchang e Zhengming (2008).

$$\mathbf{G_1} = \begin{bmatrix} \sigma L_s b & 0 \\ 0 & \sigma L_s b \end{bmatrix} \tag{7a}$$

$$\mathbf{G_2} = \begin{bmatrix} 2b & 0 \\ 0 & 2b \end{bmatrix}. \tag{7b}$$

2.2.2 Predição de Torque e Fluxo

Usando o método de discretização de Euler para frente e considerando um tempo t_D de discretização, tem-se (8) para a estimação do fluxo no instante $k+1$, para cada possível vetor v_s aplicado, consultando a Tabela 1.

$$\hat{\boldsymbol{\psi}}_s(k+1) = \hat{\boldsymbol{\psi}}_s(k) + t_D\left(\hat{\boldsymbol{v}}_s(k) - R_s\hat{\boldsymbol{i}}_s(k)\right) \tag{8}$$

A amplitude é então calculada por (9), a partir das componentes ortogonais do fluxo predito. A predição pode ser efetuada de forma subsequente até um instante futuro h, em que diz-se que h é a ordem de predição do MPTC. O aumento da ordem de predição tende a melhorar o desempenho do MPTC, porém ao custo de aumentar consideravelmente o tempo de execução, principalmente da etapa de predição, devido ao aumento do número de combinações possíveis. Assim, neste trabalho, usou-se ordem de predição igual a 1.

$$\|\hat{\boldsymbol{\psi}}_s(k+1)\| = \sqrt{\hat{\psi}_{s\alpha}(k+1)^2 + \hat{\psi}_{s\beta}(k+1)^2} \tag{9}$$

O cálculo do torque também depende da corrente de estator. Logo, a sua predição também é realizada, de acordo com (10):

$$\begin{aligned}\hat{\boldsymbol{i}}_s(k+1) = \hat{\boldsymbol{i}}_s(k) + t_D\Bigg(&\frac{1}{\sigma L_s}\left(\frac{R_r}{L_r} - jp\omega_m(k)\right)\hat{\boldsymbol{\psi}}_s(k) + \frac{1}{\sigma L_s}\hat{\boldsymbol{v}}_s(k) + \\ &- \left(\frac{R_r}{\sigma L_r} + \frac{R_s}{\sigma L_s} - jp\omega_m(k)\right)\hat{\boldsymbol{i}}_s(k)\Bigg).\end{aligned} \tag{10}$$

Assim, pode-se estimar o torque conforme (11):

$$\hat{T}(k+1) = \frac{3}{2}p \cdot \mathrm{Im}\{\hat{\boldsymbol{\psi}}'_s(k+1) \cdot \hat{\boldsymbol{i}}_s(k+1)\}. \tag{11}$$

2.2.3 Avaliação da Função Custo

Para cada vetor de tensão j, o MPTC precisa avaliar qual o valor correspondente da função custo para um horizonte de predição h, para comparação e escolha daquele que a minimizará. A função custo básica do MPTC depende do erro entre a referência de torque e o torque predito do motor, assim como do erro entre a amplitude de fluxo desejada e a amplitude de fluxo predita, esta calculada a partir das componentes $\alpha\beta$ em (9). Assim, diz-se que torque e fluxo de estator são os objetivos primários de controle do MPTC. A função custo é descrita em (12),

$$g_j = \sum_{h=1}^{N}\left(|T^* - \hat{T}(k+h)_j| + \lambda \cdot |\psi_s^* - \|\hat{\boldsymbol{\psi}}_s(k+h)_j\||\right) \tag{12}$$

onde λ determina a relação de importância entre as variáveis de torque e fluxo controladas, e "*" denota as variáveis de referência. Sua presença é necessária porque os erros de torque e amplitude de fluxo possuem unidades diferentes. Sem o fator de ponderação, apenas o erro de torque, em Nm, influenciaria a escolha do vetor, devido à ordem superior ao erro de fluxo, em Wb. Assim, um ponto de partida para o valor de λ é a razão entre o torque nominal T_{nom} do motor e a sua amplitude nominal de fluxo $\|\Psi_{nom}\|$, no entanto o final valor de λ é geralmente maior (ZHANG; YANG, 2014). Para cada vetor possível do inversor, o MPTC calculará a respectiva função custo. A expansão do horizonte de predição aumenta o numero de possibilidades testadas geometricamente. Para o inversor de dois níveis, o cálculo da função custo passaria de 7 para 49 vezes.

2.2.4 Adição de Objetivos Secundários

A estrutura do MPTC permite de forma simples adicionar restrições ao sistema, considerando outros objetivos de controle. Assim, pode-se aprimorar a função custo adicionando mais termos, como em (13), onde se consideram diversos possíveis termos, de acordo com Wang et al. (2014), relativos respectivamente a:

a) Erro entre torque de referência e torque predito do motor;

b) Erro entre as amplitudes do fluxo de referência e fluxo predito;

c) Limitação de corrente de estator máxima;

d) Quantidade de chaveamentos realizados pelo inversor para mudar do vetor atual para o vetor testado.

$$g_j = \sum_{h=1}^{N} \Big(\overbrace{\lambda_1 \cdot |T^* - \hat{T}(k+h)_j|}^{\text{(a)}} + \overbrace{\lambda_2 \cdot |\psi_s^* - \|\hat{\boldsymbol{\psi}}_{\boldsymbol{s}}(k+h)_j\||}^{\text{(b)}} + \\ + \overbrace{I_{max}}^{\text{(c)}} + \overbrace{\lambda_3 \cdot |S(k) - S(k+h)_j|}^{\text{(d)}} \Big). \tag{13}$$

O termo de controle de torque apresenta o fator de ponderação λ_1, definido nulo ou um valor positivo de acordo com uma banda de torque, como em (14).

$$\lambda_1 = \begin{cases} 0, & \text{se } |T^* - \hat{T}(k+h)_j| \leq T_{band} \\ \kappa_1, & \text{se } |T^* - \hat{T}(k+h)_j| > T_{band}. \end{cases} \tag{14}$$

O termo de fluxo depende do fator de ponderação λ_2, equivalente ao fator λ da função custo original (12). Assim, o fator λ_2 pode ser expresso como em (15), sendo função de um parâmetro positivo κ_2 maior do que 1 e da razão do torque e fluxo nominais do motor do sistema.

$$\lambda_2 = \kappa_2 \cdot \frac{T_{nom}}{\|\Psi_{nom}\|}. \tag{15}$$

O funcionamento do sistema, principalmente durante o transiente de velocidade, requer limitação de corrente para proteção do sistema. Essa limitação é atingida pelo termo I_{max}, que assume um valor teoricamente infinito caso o vetor de tensão testado produza uma corrente predita superior à máxima corrente desejada, tal qual (16), onde a amplitude de corrente é dada por (17), e I_{MAX} é a máxima corrente permitida do motor de indução.

$$I_{max} = \begin{cases} 0, & \text{se } \|\hat{\boldsymbol{i}}_{\boldsymbol{s}}\| \leq |I_{MAX}| \\ \infty, & \text{se } \|\hat{\boldsymbol{i}}_{\boldsymbol{s}}\| > |I_{MAX}| \end{cases} \tag{16}$$

$$\|\hat{\boldsymbol{i}}_{\boldsymbol{s}}\| = \sqrt{\hat{i}_{s\alpha}^2(k+1)_j + \hat{i}_{s\beta}^2(k+1)_j}. \tag{17}$$

O último termo de (13) quantifica o número de mudanças de estado que um vetor testado produzirá no inversor. Essa variável relaciona-se diretamente à frequência de chaveamento do sistema, e sua minimização é interessante porque quanto maior for a frequência de chaveamento, menor será a eficiência do inversor. O fator de ponderação λ_3 determina sua influência no sistema de controle.

O uso de (13) aumenta o número de graus de liberdade do MPTC, e por consequência pode-se melhor ajustar os desempenhos de torque e de fluxo, assim como a frequência média de chaveamento do inversor. Por isso, este trabalho utilizou (13) em lugar de (12). Por outro lado, ressalta-se que a nova função custo aumenta a dificuldade de ajuste dos parâmetros, já que contém três fatores de ponderação em lugar de um.

2.2.5 Compensação de Atraso

A simulação computacional e a prática possuem uma diferença a ser ressaltada na implementação do MPTC. Na simulação, a execução do laço de controle para a execução do modelo da planta, de modo que o vetor escolhido pelo MPTC será aplicado no instante k em que o sistema de controle as variáveis de controle foram medidas. Na prática, a planta é contínua, mas o sistema de controle age de maneira discreta, aplicando o vetor escolhido apenas no instante $k+1$ seguinte, gerando uma defasagem entre a predição e o sistema. Uma correção possível consiste na predição de dois horizontes consecutivos para cada vetor, em lugar de um (WANG et al., 2014). Neste trabalho, a correção do atraso não se faz necessária porque a etapa de predição do fluxo e do torque são feitas a partir das correntes também estimadas pelo observador, e não das medidas, o que compensa o atraso.

2.2.6 Controle Preditivo sem Fatores de Ponderação

Pode-se ver que o MPTC baseia-se em minimizar diversos objetivos ao mesmo tempo, que são combinados na função custo. No entanto, outras alternativas são buscadas para evitar a presença dos fatores de pesos.

Os autores de Rojas et al. (2013) trataram cada objetivo separadamente, sem uma função custo global, com base em um método de classificação multiobjetivo, ou *Multi Ranking Model Predictive Torque Control* (MRMPTC). O MRMPTC opera da seguinte maneira: os objetivos de torque e fluxo são calculados separadamente, para cada possível vetor, como no MPTC convencional. Em seguida, cada vetor é classificado em ordem conforme o valor de seu objetivo de torque, e outra classificação é feita para os valores de fluxo. Depois calcula-se a média das posições de cada vetor nas duas classificações, e o vetor com menor média é escolhido. Essa abordagem, mostrada na Figura 4, garante

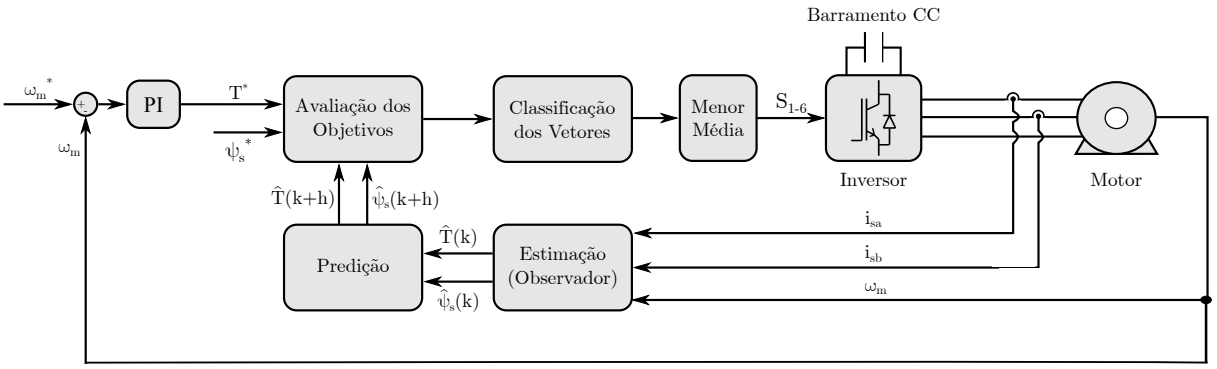

Figura 4: Sistema de controle MRMPTC de velocidade do motor de indução.

que torque e fluxo sejam tratados com a mesma importância, e elimina o uso do fator de ponderação relacionando os dois. Por outro lado, perdem-se graus de liberdade no ajuste do sistema, e dificulta-se a inclusão de restrições e de objetivos secundários de

controle. O objetivo de frequência média de chaveamento, por exemplo, pode ser inserido na técnica, porém não se pode diretamente calcular-se a media das três classificações, pois a sua importância por definição é menor do que torque e fluxo, requerendo um fator que redundaria na mesma necessidade de projeto inicial.

2.3 Conclusões Parciais

Neste Capítulo foram apresentados os fundamentos teóricos referentes ao controle e acionamento do motor de indução, utilizados neste trabalho. Os componentes da planta foram modelados, a saber, o motor de indução e o inversor de tensão trifásicos. Seguiu-se a estrutura e equacionamento do MPTC, derivada dos modelos da planta, destacando-se a facilidade de inclusão de restrições na estrutura do MPTC. Segue no próximo Capítulo a teoria a respeito de algoritmos genéticos utilizada neste trabalho.

Capítulo 3

Algoritmos Genéticos

3.1 Algoritmo Genético Mono-objetivo

Nos AGs, possíveis soluções do problema são chamadas de indivíduos e cada indivíduo é codificado, originando um cromossomo correspondente. O conjunto de cromossomos é submetido a um processo iterativo de adaptação, convergindo para a sobrevivência do código genético mais apto, que corresponde à solução com melhor desempenho para resolver o problema modelado. Neste trabalho, o AG busca otimizar os três fatores de ponderação da função custo mostrada em (13), que definem um espaço de busca contínuo. Devido à característica do problema, usou-se um AG de valores reais, em que cada gene é um valor real (DEB, 2001, p. 106).

A estrutura de um AG mono-objetivo de valores reais é ilustrada na Figura 5. O sistema inicia com a criação de uma população inicial, gerada aleatoriamente dentro de limites desejados, onde cada indivíduo é uma solução do problema no espaço de busca considerado. Para mais de um parâmetro sendo otimizado, cada indivíduo passa a ser um vetor em que cada posição refere-se a um parâmetro, permitindo que todos sejam otimizados ao mesmo tempo.

Enquanto o critério de parada não é atingido, o algoritmo executa um processo iterativo, que começa com o cálculo da aptidão de cada indivíduo, por meio de uma função definida pelo projetista do AG. Essa função deve representar as grandezas do sistema que se deseja otimizar o desempenho. O AG utiliza a informação de aptidão para selecionar os indivíduos mais aptos, isto é, que melhor resolvem o problema. Seguem então os dois operadores genéticos, que modificam a população do AG:

a) Operador de cruzamento, que restaura o tamanho da população original, com indivíduos filhos gerados a partir daqueles que foram anteriormente selecionados (indivíduos pais), garantindo que os novos indivíduos perpetuem as características desejáveis dos indivíduos pais. Dentre os possíveis operadores de cruzamento para AGs com valores reais, citam-se o operador média, média ponderada, e razão (DEB, 2001);

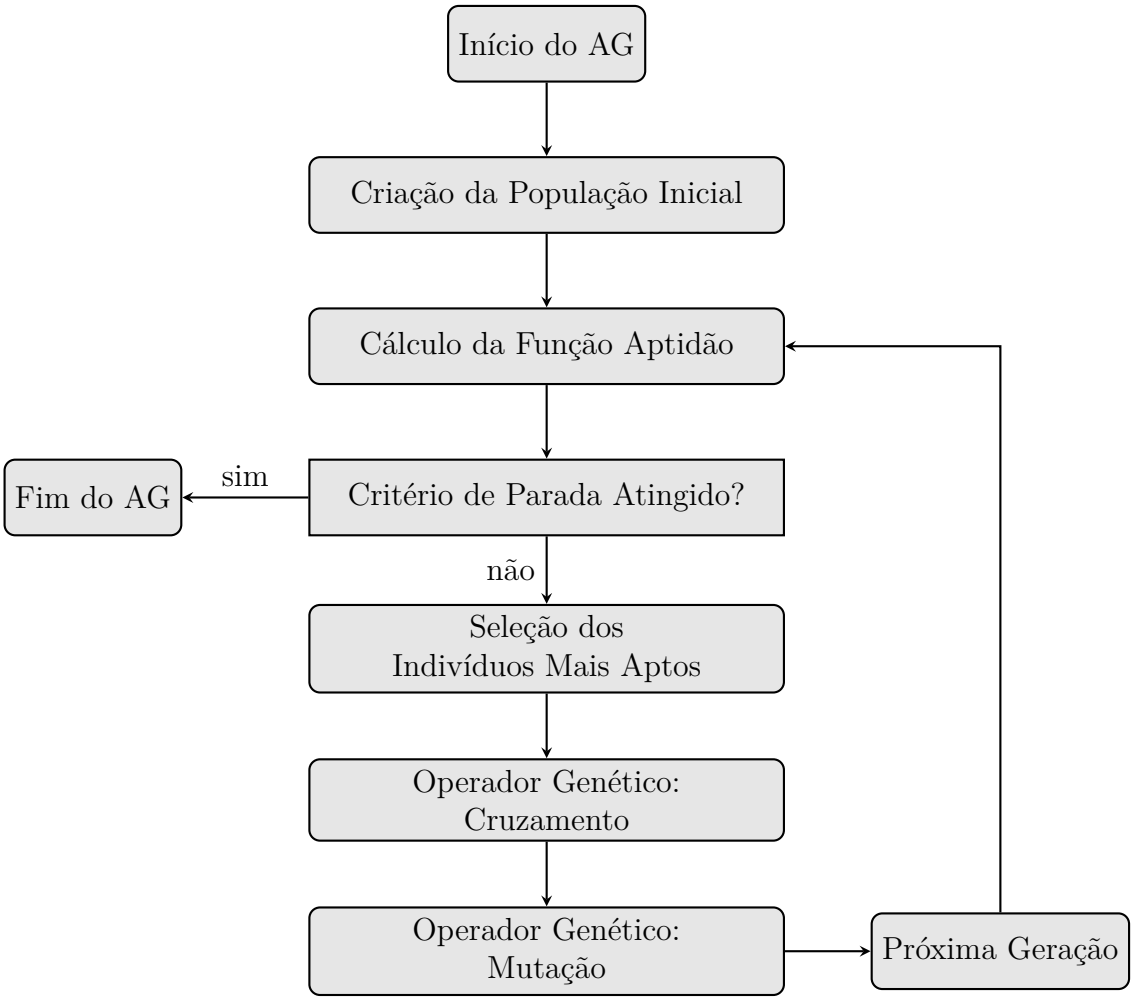

Figura 5: Fluxograma de funcionamento do AG, para otimização de sistemas.

b) Operador de mutação, responsável por inserir diversidade genética na população, a fim de evitar máximos locais. Quanto a possíveis operadores de mutação, citam-se operador randômico uniforme, randômico gaussiano e adaptativo (DEB, 2001).

O AG repete este processo, até que se atinja o critério de parada definido, como número máximo de gerações ou a aptidão desejada, por exemplo. Finalmente, retorna-se o indivíduo mais adaptado ao problema, que corresponde à melhor solução encontrada.

3.2 Algoritmo Genético Multiobjetivo

No projeto e ajuste dos fatores de ponderação há muitos requisitos de desempenho envolvidos que influenciam o comportamento do sistema. Logo, a abordagem multiobjetivo deve ser utilizada, ou seja, um AGM que considera mais de uma função aptidão. Em lugar de buscar um indivíduo mais adaptado o AGM retorna um conjunto de melhores soluções, mostrando os compromissos existentes entre cada variável que se quer otimizar. Esse conjunto é conhecido como fronteira de Pareto ou conjunto de soluções

não-dominadas, uma vez que entre elas não é possível obter nenhuma melhoria de algum requisito sem deteriorar outro (KUMAR; SAXENA; KUMAR, 2014; CENSOR, 1977). Desse modo, o AGM tem duas principais tarefas como objetivo (WANG; NG; DEB, 2011):

a) Encontrar um grupo de soluções que façam parte da fronteira de Pareto do sistema;

b) Escolher o grupo de soluções de forma a representar a gama de possibilidades de soluções da forma mais diversa possível.

Vários AGMs foram desenvolvidos e são usados para problemas de otimização em engenharia, diferindo entre si quanto ao esforço computacional solicitado, à abrangência no espaço de busca e à capacidade de convergência (KUMAR; SAXENA; KUMAR, 2014). Há técnicas baseadas no conceito de fronteira de Pareto, como o *Strength Pareto Evolutionary Algorithm* (SPEA) (ZITZLER; THIELE, 1999), e técnicas que não a utilizam diretamente, como *Vector-Evaluated Genetic Algorithm* (VEGA) (SCHAFFER, 1985), que efetua seleções separadas para cada objetivo, juntando posteriormente as subpopulações. O AG de classificação não-dominada (SRINIVAS; DEB, 1994), ou *Non-dominated Sorting Genectic Algorithm* (NSGA), foi proposto baseado no conceito de classes não-dominadas, no entanto apresentando problemas de custo computacional e ausência de elitismo (DEB et al., 2002). A sua evolução é o *Non-dominated Sorting Genectic Algorithm II* (NSGA-II) (DEB et al., 2002), que buscou resolver os problemas citados ao inserir o operador de seleção de aglomeração. O NSGA-II destaca-se na literatura pelo melhor desempenho nas métricas de convergência, relacionada à distância final das soluções à fronteira de Pareto real, e de divergência, relacionada à diversidade da população final, frente a outras topologias como o SPEA (KUMAR; SAXENA; KUMAR, 2014). Neste trabalho, utilizou-se o NSGA-II.

3.3 Estrutura do NSGA-II

O NSGA-II apresenta em sua estrutura os operadores genéticos de cruzamento e mutação semelhantes a um AG mono-objetivo. No entanto, como a aptidão de um indivíduo não é medida por um valor escalar, mas por várias funções objetivo, o NSGA-II então, em uma dada geração, classifica todas as soluções em subgrupos quanto a sua dominância. Matematicamente, diz-se que uma solução $\boldsymbol{x_A}$ domina uma solução $\boldsymbol{x_B}$ se e somente (GOLDBERG, 1989, p. 198) as condições de (18) são atendidas, ou seja, todos os seus índices são menores ou iguais e pelo menos um deles é menor do que o de $\boldsymbol{x_B}$:

$$\boldsymbol{x_A} < p\boldsymbol{x_B} \Leftrightarrow (\forall_i)\,(y_{A_i} \leq y_{B_i})\, e\, (\exists i)\,(y_{A_i} < y_{B_i}) \tag{18}$$

em que se busca minimizar os índices y_i e $< p$ é o símbolo para dominação. A Figura 6 ilustra um exemplo de soluções para um problema de minimização de duas variáveis, y_1 e y_2 . As três soluções em branco são não-dominadas em relação à todas as soluções do conjunto e por isso são ditas pertencentes a classe 1 ou classe de elite, em razão de não haver pelo menos uma solução do conjunto que tenha os dois índices iguais ou menores

ao delas. De forma análoga, tem-se que as soluções em cinza são ditas de classe 2, por cada uma ser dominada por ao menos uma solução da classe 1, e que por fim as soluções em preto são consideradas de classe 3 (WANG; NG; DEB, 2011).

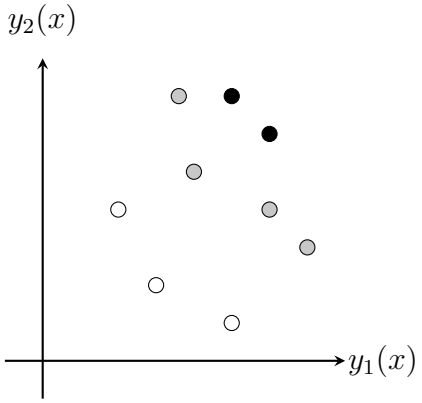

Figura 6: Soluções dispostas no plano de aptidão, para minimização de x_1 e x_2 - divisão em classes não-dominadas 1 (branco), 2 (cinza) e 3 (preto).

Fonte: adaptado de Wang, Ng e Deb (2011).

Com base nesse princípio de funcionamento tem-se na Figura 7 o fluxograma de operação do NSGA-II para obtenção de uma fronteira de Pareto para um dado problema. Em uma dada geração, após os operadores genéticos produzirem os indivíduos filhos a partir dos pais, as funções objetivo são calculadas e as soluções são divididas em classes não-dominadas. A primeira etapa de seleção escolhe os subgrupos com dominância sobre os outros para preencher a população da geração seguinte. Esse processo é feito até que uma classe de soluções não possa ser totalmente escolhida, pois excederia o limite da população. Inicia-se então a segunda etapa de seleção do NSGA-II, que visa outro objetivo: aumentar a diversidade de soluções da população. Nessa etapa escolhem-se os indivíduos desse subgrupo que aumentarão a cobertura no espaço de busca da população, preenchendo as última vagas da população. Assim como no AG mono-objetivo, o processo é repetido iterativamente, ate que se atinja o critério de parada (WANG; NG; DEB, 2011).

3.4 Controle de Elitismo do NSGA-II

Ao entender o funcionamento do NSGA-II percebe-se que a cada geração as melhores soluções são preservadas, de modo que suas características são enfatizadas para transmissão às gerações seguintes. A esse fenômeno dá-se o nome de elitismo (DEB; GOEL, 2001). A sua presença é importante para aumentar a velocidade de convergência dos AGMs (ZITZLER; DEB; THIELE, 2000).

Por outro lado, o elitismo pode afetar a capacidade de convergência do NSGA-II. Após algumas gerações, o método de seleção por classes não-dominadas pode resultar em uma população concentrada em poucas classes não-dominadas, porém ainda longe da fronteira

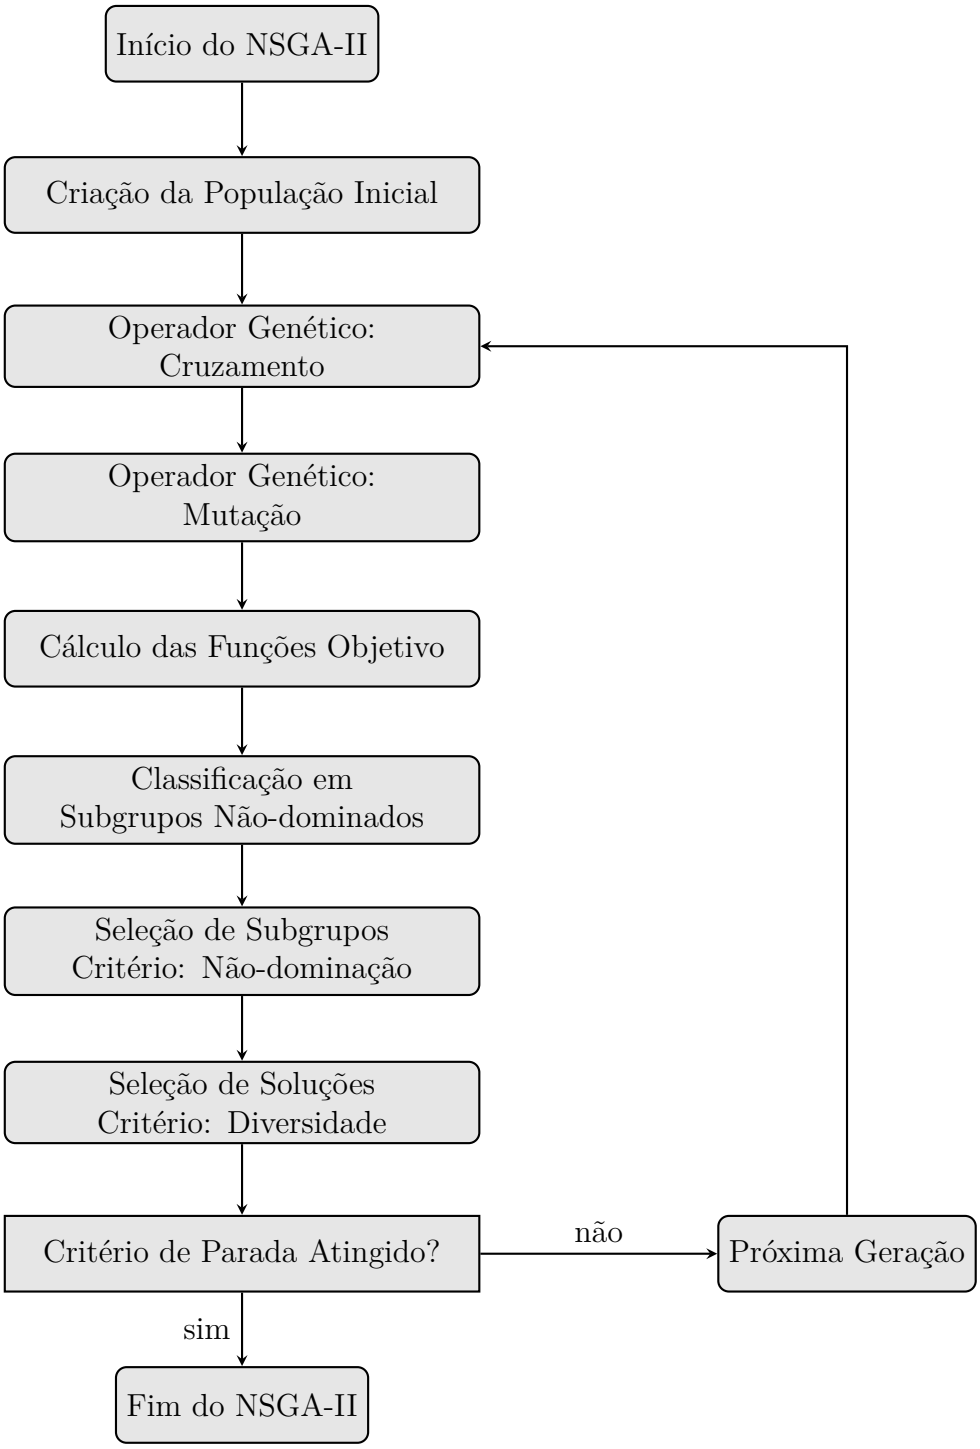

Figura 7: Fluxograma de funcionamento do NSGA-II, para otimização de sistemas.

de Pareto real do problema. Nesse caso, o NSGA-II ficará preso em uma fronteira de Pareto local. A solução proposta por Deb e Goel (2001) baseia-se em limitar o número de indivíduos nas classes não-dominadas, escolhendo outros indivíduos pertencentes a classes inferiores para aumentar a diversidade da população. Assim, consegue-se controlar o elitismo do NSGA-II, para melhoria da sua convergência.

3.5 Conclusões Parciais

Apresentou-se neste Capítulo a teoria a respeito da otimização multiobjetivo utilizando AGs, especificamente o NSGA-II, onde se percebe a interpretabilidade dos AGs e a capacidade do NSGA-II para resolução de problemas com mais de um objetivo.

Com base nas qualidades e ferramentas apresentadas, o próximo Capítulo investiga a relação entre os fatores de ponderação e os índices de desempenho considerados. Ainda, trata de explicar a estrutura do NSGA-II utilizado e como ele foi executado de forma a otimizar os fatores de ponderação do MPTC, utilizando a função custo aprimorada mostrada em (13).

Capítulo 4

Otimização Multiobjetivo dos Fatores de Ponderação

4.1 Etapas de Projeto

A aplicação do NSGA-II para otimizar os fatores de ponderação da função custo escolhida para o MPTC requer os seguintes passos, descritos nas seções deste Capítulo:

a) Especificar o motor de indução a ser modelado e controlado. A correta modelagem afeta o desempenho do MPTC sendo, portanto, necessária para a fase do NSGA-II de cálculo da aptidão;

b) Analisar a relação entre os fatores de otimização e os indicadores de desempenho que se quer minimizar, garantindo que os genes dos indivíduos de fato atuem sobre os indicadores de desempenho;

c) Constituir os indivíduos do NSGA-II a partir dos fatores de ponderação do MPTC que se quer otimizar, assim como os seus limites. Deve-se garantir um espaço de busca das soluções que abranja soluções viáveis;

d) Definir os métodos de seleção e operadores genéticos de mutação e cruzamento que compõem o NSGA-II, para sua implementação.

O desempenho do MPTC pode ser visto por vários aspectos, de acordo com a necessidade do projetista como por exemplo: desempenho de torque e de fluxo, as variáveis com prioridade de controle do MPTC; qualidade das correntes de estator, avaliadas pela análise de seus harmônicos; oscilação do barramento de tensão, que deve ser a mínima possível; e a frequência de chaveamento do inversor, diretamente relacionada à eficiência energética do inversor. Este trabalho foca no desempenho dinâmico bem como energético, por meio da minimização da oscilação de torque e de fluxo e da frequência média de chaveamento. Assim, seguem as análises feitas para estruturar e definir a topologia do NSGA-II.

4.2 Especificação do Motor de Indução

Neste trabalho, efetuou-se a otimização para o MPTC aplicado a um motor de indução trifásico de 1 hp/3420 rpm, 220/380 V, chamado de Motor de Indução de Teste (MIT), para o qual se efetuou o processo de otimização dos fatores de ponderação do MPTC via NSGA-II utilizando a simulação em Simulink, para posterior teste em bancada.

Os parâmetros elétricos e mecânicos do MIT encontram-se na Tabela 2. Esses parâmetros são usados na execução do modelo do motor de indução e nas etapas de estimação e predição do MPTC, na simulação e em ambiente experimental.

Tabela 2: Parâmetros do MIT para simulação do modelo e para execução do MPTC.

Parâmetro	MIT	Unidade
T_{nom}	2	Nm
$\|\Psi_{nom}\|$	$0,7$	Wb
R_s	$7,5022$	Ω
R_r	$4,8319$	Ω
L_s e L_r	$718,5$	mH
L_m	$694,1$	mH
p	1	—
J	$0,0017$	$\mathrm{kg} \cdot \mathrm{m}^2$
F	$0,001$	$\mathrm{N} \cdot \mathrm{m} \cdot \mathrm{s}$

4.3 Definição dos Indivíduos e Funções Objetivo

Cada indivíduo $\boldsymbol{x}$ do problema de otimização do MPTC deve conter parâmetros capazes de influenciar e modificar o desempenho das variáveis de otimização desejada. Analisando a função custo de (13), tem-se quatro graus de liberdade, a partir da análise da função custo que segue

$$g_j = \sum_{h=1}^{N} \left(\boldsymbol{\lambda_1} \cdot |T^* - \hat{T}(k+h)_j| + \boldsymbol{\lambda_2} \cdot |\psi_s^* - \|\hat{\psi}_s(k+h)_j\|| + I_{max} + \boldsymbol{\lambda_3} \cdot |S(k) - S(k+h)_j| \right) \quad (19)$$

em que o parâmetro λ_1 contém dois graus de liberdade: a banda de torque T_{band} e o fator de ponderação κ_1, conforme (14), e λ_2 é função de κ_2 e de parâmetros nominais do motor. No entanto, deve-se ressaltar que os fatores de ponderação da função custo são linearmente dependentes entre si, de modo que um deles pode ser mantido constante não perderá a generalidade do sistema na região linear de operação. Assim, pode-se fixar $\kappa_1 = 1$, por exemplo, e analisar-se o efeito da variação dos outros dois fatores nos indicadores de desempenho.

No Simulink, efetuaram-se simulações do MIT em regime de velocidade de 2000 rpm, em que apenas um dos parâmetros era variado. Como solução base, tomou-se $T_{band} = 0$,

$\kappa_2 = 1$ e $\lambda_3 = 0$. Tem-se na Figura 8 os gráficos de torque, correntes e fluxos de estator no eixo $\alpha\beta$ para simulações com diferentes banda de torque, enquanto os outros dois parâmetros permaneceram fixos.

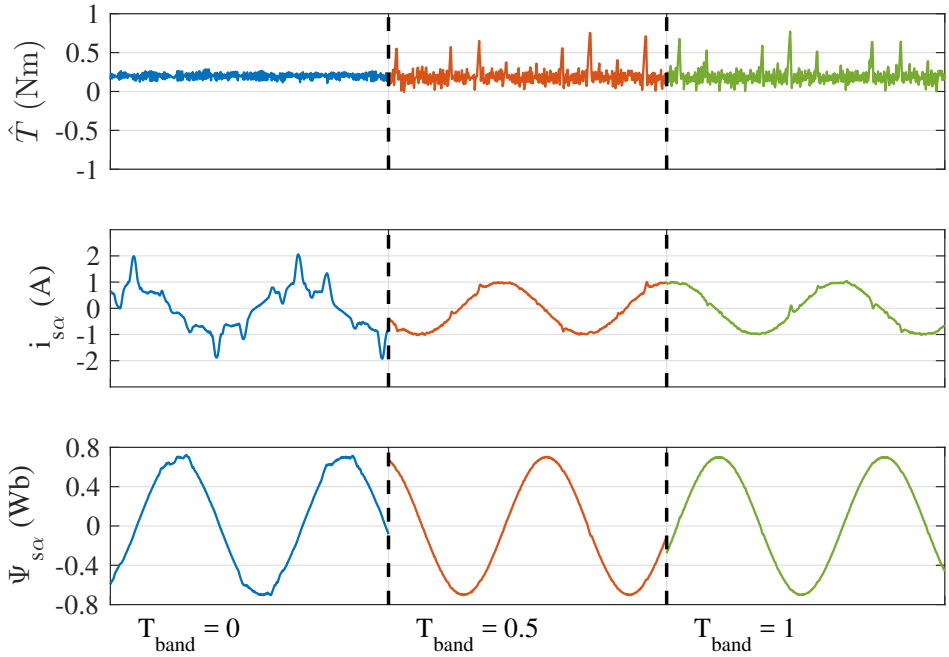

Figura 8: Efeito de diferentes valores de T_{band} no desempenho do MPTC, para κ_2 e λ_3 fixos.

A respeito da solução inicial, tem-se uma oscilação de torque baixa, porém com correntes e fluxo de estator apresentando baixa qualidade. Vê-se que o aumento da banda de torque aumenta a oscilação de torque, mas melhora a qualidade das correntes e fluxos, contrapondo o desempenho mecânico ao elétrico.

O efeito da variação de κ_2, para $T_{band} = 0$ e $\lambda_3 = 0$ originais, é mostrado nas simulações da Figura 9. Percebe-se como o aumento de κ_2 melhorou a forma de onda do fluxo de estator. O aumento de 1 para 10 aumentou a oscilação de torque, porém melhorou consideravelmente a corrente de estator. Importante notar que o aumento demasiado de κ_2 para 20 deteriorou o torque e a corrente. Logo, o ajuste deste fator é fundamental para assegurar a qualidade das correntes e do fluxo de estator.

Por fim, tem-se a variação do fator de ponderação λ_3, para $T_{band} = 0$ e $\kappa_2 = 1$, para a qual a Figura 10 mostra o gráfico da seleção de vetores, além dos gráficos de torque, corrente e fluxo. Nota-se como o seu aumento faz com que a oscilação de torque aumente, e a qualidade das correntes diminua. Pode-se ainda perceber a redução na mudança de vetores ao aumentar-se λ_3 de 0 para 0,025. No entanto, ressalta-se que acima de um determinado valor o fator λ_3 interferiu na operação do motor, selecionando sempre o vetor nulo e impedindo a magnetização e partida do motor. Assim, este fator assume apenas

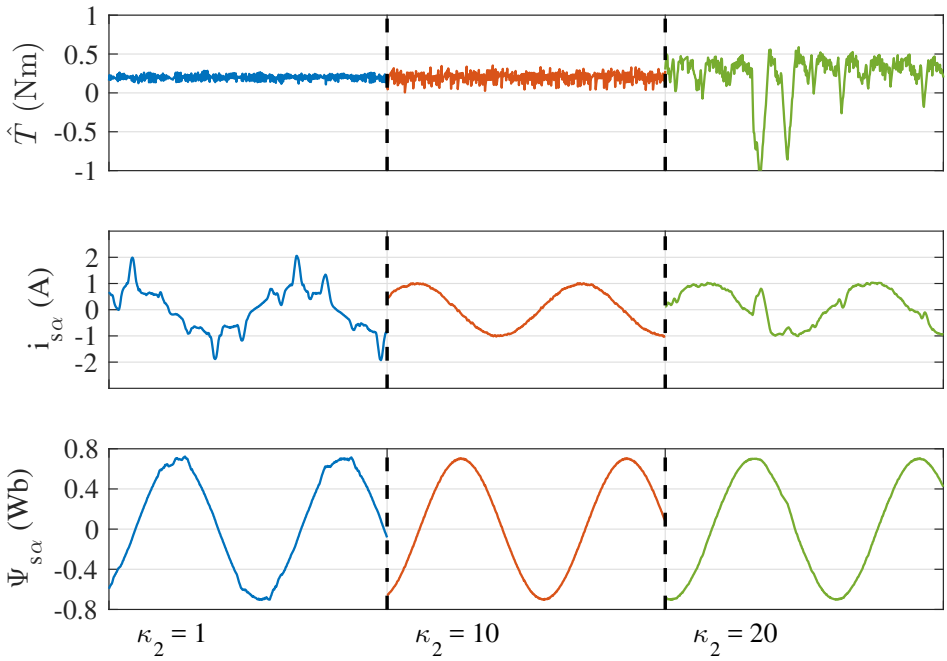

Figura 9: Efeito de diferentes valores de κ_2 no desempenho do MPTC, para T_{band} e λ_3 fixos.

valores pequenos em relação ao fator de peso do fluxo, uma vez que a minimização de chaveamento é um objetivo secundário de controle.

Os três comparativos mostram como os fatores de peso são parâmetros interligados. Apesar de cada fator referir-se a um termo específico da função custo do MPTC, a sua variação influencia todas as demais variáveis, melhorando algumas e deteriorando outras, justificando a necessidade de otimização multiobjetivo. O aumento de κ_2, por exemplo, aumentou a importância do erro de fluxo na escolha do vetor de tensão pelo MPTC, melhorando a dinâmica de fluxo e deteriorando o torque. O aumento de λ_3, por outro lado, aumenta o custo de vetores que impliquem mais mudanças no estados das chaves. Como efeito, tem-se a redução da frequência média de chaveamento, porém maiores oscilações de torque e fluxo.

Neste trabalho decidiu-se atuar sobre três indicadores de desempenho: a redução da oscilação de torque, da oscilação de fluxo e da frequência média de chaveamento, a fim de considerar tanto o desempenho mecânico e elétrico do sistema quanto a sua eficiência energética. As duas oscilações devem ser as menores possíveis, o que implica uma melhor resposta dinâmica do motor. O último indicador, por sua vez, deve ser o valor mais baixo possível, pois menores frequências de chaveamento correspondem a menores perdas de energia nas chaves do inversor. No entanto, a redução de todos os indicadores é conflitante, uma vez que o MPTC melhora a dinâmica de torque e fluxo aumentando o número de chaveamentos ao longo do tempo. Outra otimização também foi considerada, em que apenas as oscilações de torque e fluxo são objetivos, isto é, apenas otimiza-se o

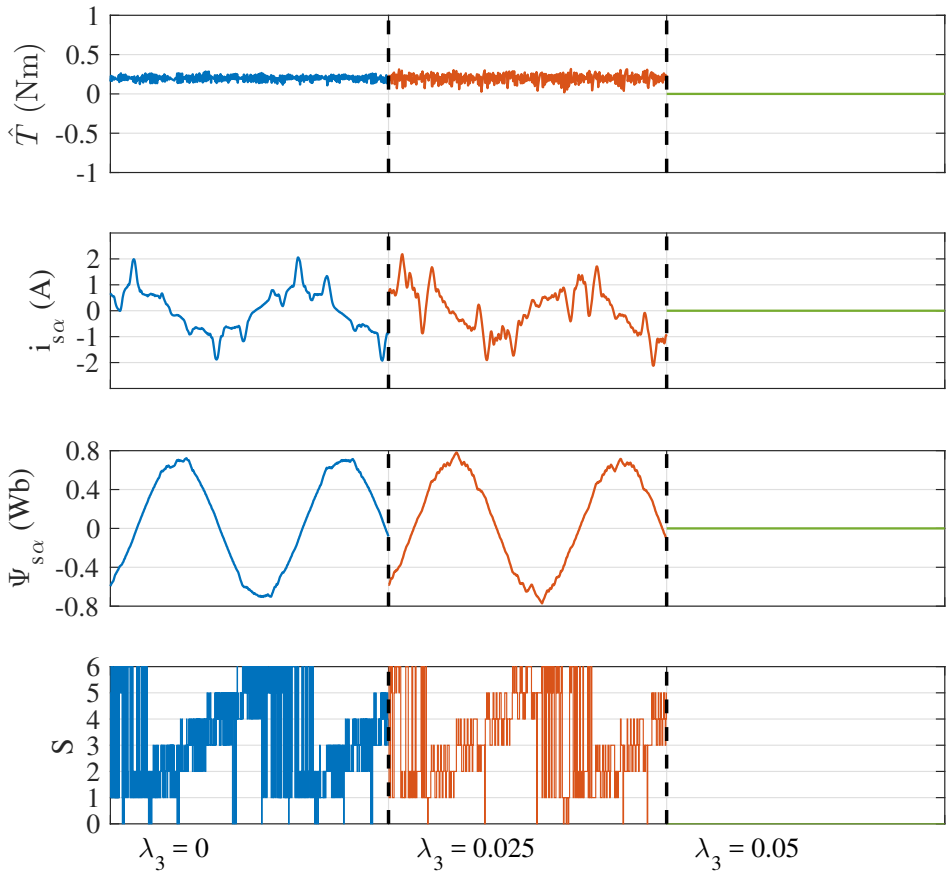

Figura 10: Efeito de diferentes valores de λ_3 no desempenho do MPTC, para T_{band} e κ_2 fixos.

desempenho dinâmico do sistema.

No AGM, a função objetivo é substituída por todos os requisitos de desempenho, ou aptidões, que se queira minimizar. Para avaliar cada solução, efetuou-se uma simulação no Simulink, da MathWorks®, da resposta ao degrau de velocidade de 1000 rpm do motor com MPTC com os fatores de ponderação da solução testada, com 75% da carga nominal. Essa simulação proporciona a extração de variáveis que indicam quão boa uma solução é para a otimização do MPTC. Com isso, pode-se extrair da simulação a frequência média de chaveamento durante o regime permanente de velocidade e as oscilações de torque e fluxo do motor durante o regime permanente de velocidade, para 75% da carga nominal. A frequência média de chaveamento foi calculada a partir da contagem do número de chaveamentos efetuados em regime, durante 1 s. As oscilações são calculadas a partir da diferenças entre os valores máximos e mínimos de cada variável em regime.

Ainda, deve-se considerar a influência da solução considerada na dinâmica de fluxo, uma vez que se viu nas análises a importância desta variável. A flexibilidade do AGM também permite a inclusão de restrições para os requisitos de desempenho. Caso em uma

simulação o motor não parta, não apresente dinâmica de velocidade satisfatória ou uma oscilação do módulo do fluxo acima de um limiar, as duas aptidões são forçadas a um valor muito grande, de forma similar ao algoritmo de limitação de corrente, o que fará com que essas soluções não sejam escolhidas em futuros processos de seleção. Seguindo esta estratégia, as seguintes grandezas foram limitadas em faixas de desempenho desejado: oscilação de torque inferior a 50% do torque nominal, oscilação da amplitude de fluxo de estator inferior a 10% do fluxo nominal e frequência média de chaveamento entre 2 e 7 kHz.

Após as análises efetuadas e com base no exposto, fixou-se $\kappa_1 = 1$ e cada indivíduo x do NSGA-II foi definido possuindo três genes, como mostrado em (20), de modo que cada gene corresponda a um fator de ponderação e influa nos índices de desempenho avaliados:

a) T_{band}: a banda de torque influi no termo de torque da função custo, estando relacionada à oscilação de torque do sistema;

b) κ_2: o parâmetro definido em (15) define o valor do peso λ_2 do termo de fluxo, e influi diretamente no comportamento desta variável;

c) λ_3: o peso do termo de minimização da frequência de chaveamento atua de forma a aumentar a eficiência energética, em detrimento do desempenho de torque.

$$\boldsymbol{x} = [T_{band}, \kappa_2, \lambda_3]. \tag{20}$$

Cada gene teve seu espaço de busca limitado conforme descrito na Tabela 3. A banda de torque foi limitada entre 5 e 15% do torque nominal do motor. Os outros fatores possuem natureza adimensional.

Tabela 3: Limites máximos e mínimos de cada gene dos indivíduos do NSGA-II.

Parâmetro	Mínimo	Máximo	Unidade
T_{band}	$0,1$	$0,3$	Nm
κ_2	$1,1$	20	—
λ_3	0	$0,07$	—

4.4 Estrutura e Operadores do NSGA-II

Para execução do NSGA-II, o programa de otimização global contido no MATLAB®, chamado *Global Optimization Toolbox*. É uma ferramenta capaz de implementar, entre outros algoritmos, um NSGA-II com elitismo controlado (THE MATHWORKS INC., 2016).

Como visto na estrutura do NSGA-II, para que se defina a topologia do NSGA-II devem-se especificar os seguintes componentes:

a) Operador genético de cruzamento;

b) Operador genético de mutação;

c) Método de controle de elitismo;

d) Método de seleção de aglomeração, que avalia a diversidade da população;

Em AGs binários, o operador genético de cruzamento gera indivíduos filhos recombinando os genes dos pais. No entanto, em AGs de valores reais o cruzamento pode gerar os indivíduos filhos por meio de operações matemáticas com os indivíduos pais, podendo também ser chamado de operador de mistura (DEB, 2001, p. 108). Utilizou-se o operador intermediário, no qual um indivíduo filho é obtido a partir da média ponderada entre seus indivíduos pais x_1 e x_2, por meio de um fator randômico entre 0 e 1, como em (21). Como o indivíduo filho está localizado dentro do cubo definido pelos indivíduos pais no espaço de soluções, tem-se que o operador intermediário garante que os indivíduos filhos permaneçam dentro do espaço de busca inicial (DEB, 2001, p. 108).

$$\boldsymbol{x_{filho}} = \boldsymbol{x_1} + rand(.)\left(\boldsymbol{x_2} - \boldsymbol{x_1}\right). \tag{21}$$

O operador genético de mutação para AGs de valores reais consiste em modificar valor de um gene do indivíduo escolhido, dentro do espaço de busca definido. Escolheu-se o operador adaptativo, em que a taxa em que a mutação ocorre varia ao longo das gerações de acordo com o desempenho das gerações anteriores, visando preservar as soluções no espaço de busca (THE MATHWORKS INC., 2016).

O controle de elitismo é feito pelo NSGA-II do MATLAB® limitando-se o número de indivíduos no grupo de soluções não-dominadas da classe de elite. O parâmetro P_{frac} determina qual a fração da população que pode pertencer à classe de elite. Assim, a população não convergirá toda para uma mesma classe não-dominada.

A última parte do NSGA-II é a seleção dos indivíduos que vão completar a geração seguinte, visando a diversidade da população. Utilizou-se o índice conhecido como distância de aglomeração para avaliar os indivíduos. Para um indivíduo de uma população, a sua distância de aglomeração é calculada como perímetro do cubo delimitado em volta da solução pelas soluções mais próximas a ela, no espaço dos objetivos (WANG; NG; DEB, 2011). Assim, uma solução terá esse índice maior quanto mais distante ela estiver de outras soluções, implicando que essa solução oferece diversidade à população.

Esse índice foi utilizado para execução do operador de seleção torneio. No torneio, um número definido de soluções são sorteadas, e postas em comparação. Aquela que exibir o melhor índice desempenho (distância de aglomeração) é escolhida. Esse processo é feito até que se complete a geração. Como resultado, os AGMs foram desenvolvidos com os parâmetros da Tabela 4.

Tabela 4: Parâmetros utilizados no AGM desenvolvido para otimização dos fatores de ponderação.

Parâmetro	Tipo	Valor
Tamanho da População	Iniciada aleatoriamente	50
Seleção	Torneio	2
Cruzamento	Intermediário	0,80
Mutação	Adaptativa	—
Fração de Pareto	—	0,35
Medição de distância	Distância de aglomeração	—
Critério de parada	Número de gerações	100

Capítulo 5

Simulação Computacional e Bancada de Ensaios Experimentais

5.1 Simulação em Ambiente Computacional

Simular é uma parte importante do processo, ajudando a reduzir custos e tempo de projeto (BAZZO; PEREIRA, 2009). As simulações do motor de indução controlado pelo MPTC foram realizadas no software Simulink, da MathWorks®. Integrado ao MATLAB®, podem-se incluir os modelos dinâmicos aqui apresentados para simular os componentes da planta (motor, inversor e retificador), e desenvolver-se o sistema de controle em uma linguagem de programação próxima da implementação em bancada.

Utilizou-se o *solver ode45*, para resolução das equações diferenciais. Destacam-se os seguintes pontos, a respeito da simulação:

a) O sistema de controle MPTC foi executado com base de tempo fixa a 20 kHz;

b) A medição de apenas duas correntes foi realizada, assumindo-se que o sistema é equilibrado;

c) As correntes medidas passaram por um filtro passa-baixa de 600 Hz, dez vezes a frequência nominal de operação do MIT;

d) O controlador de velocidade foi ajustado para $K_P = 0,05375$ e $K_I = 1,082$;

e) Um retificador foi modelado, em lugar de um barramento CC ideal.

Essa mesma configuração foi usada tanto na execução do NSGA-II, para gerar os dados que possibilitam o cálculo dos objetivos, quanto nas simulações de validação e comparação com os resultados experimentais.

5.2 Bancada Experimental de Controle e Acionamento

No Laboratório de Controle e Eletrônica de Potência da Universidade de São Paulo, usou-se a bancada para acionamento e controle do MIT mostrada na Figura 11, na qual

se encontra o MIT acoplado a um gerador CC para aplicação de torque de carga.

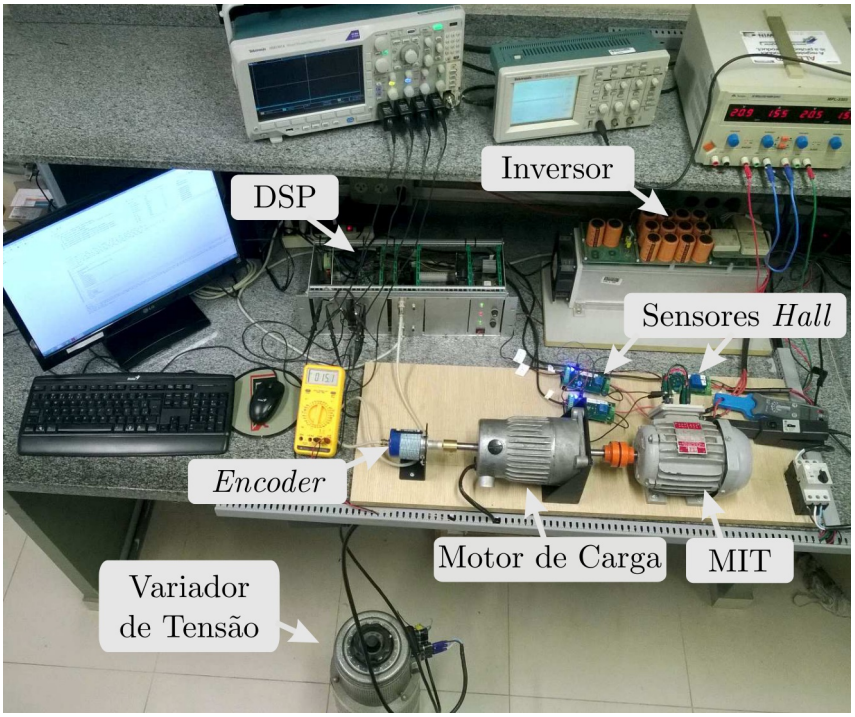

Figura 11: Bancada de ensaios experimentais para acionamento e controle do MIT.

O MIT foi conectado em estrela seguindo o modelo da simulação em Simulink. Os principais componentes de acionamento e controle do MIT são:

a) Inversor trifásico da SEMIKRON® com potência nominal de 2.2 kVA;

b) Retificador trifásico embutido no conjunto inversor, cujo banco de capacitores totaliza 8,16 mF/400 V. Assim, as condições de velocidade e carga nominais do MIT não podem ser obtidas, uma vez que para isso requer-se um barramento de 538 V, para a sua conexão em estrela;

c) Variador de tensão usado para carregar o barramento CC de forma controlada, evitando picos de corrente;

d) Sistema de controle embarcado no kit de desenvolvimento TMDXDOCK28377D, da Texas Instruments®;

e) Medição de velocidade realizada por meio de um *encoder* incremental de 1500 pulsos por revolução, com saída em quadratura;

f) Medição das correntes do MIT efetuadas por sensores *hall*, assim como a tensão do barramento CC, para monitoramento.

Pode-se ver na Figura 12, que ilustra o diagrama de blocos da bancada 1, que o MIT é controlado pelo MPTC embarcado no *Digital Signal Processor* (DSP), a partir das medições de velocidade e correntes. As mesmas considerações da simulação aplicam-se aqui. Ainda, o barramento CC é obtido pelo retificador. Quanto à geração de torque de

carga, esta é feita em malha aberta. O gerador CC de carga tem sua armadura conectada a uma carga resistiva, e seu campo é alimentado por uma fonte de tensão variável para a produção de torque, a fim de que se possa testar o MIT quando operando com carga.

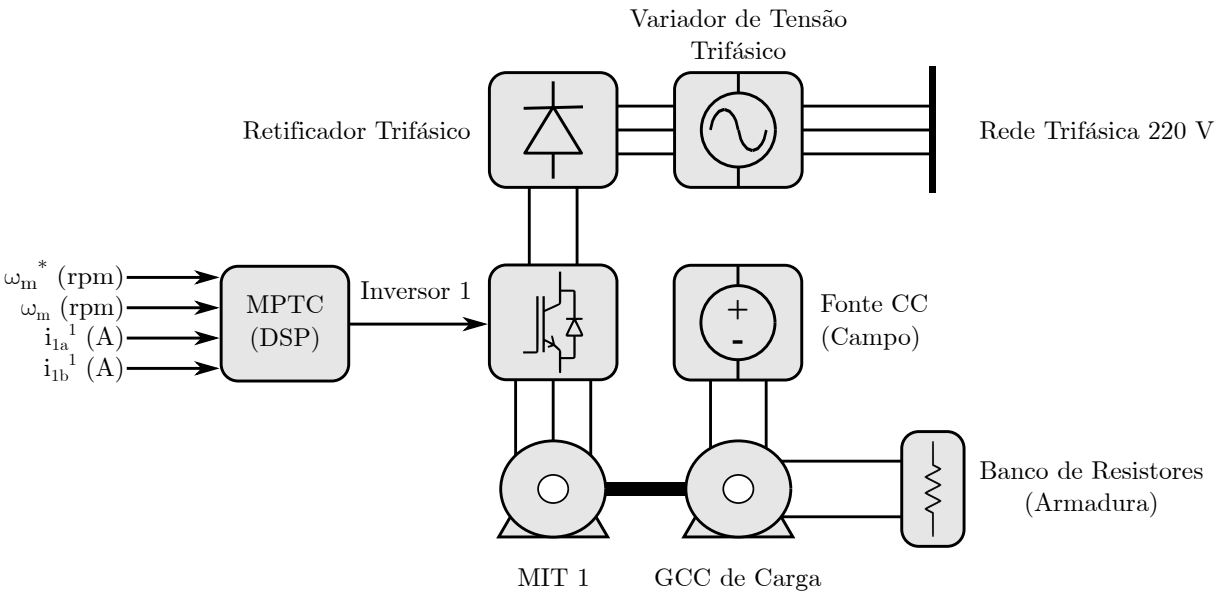

Figura 12: Diagrama de blocos da bancada 1 com o esquema de conexão do gerador CC para produção de torque de carga.

Capítulo 6

Resultados e Discussões

6.1 Testes Realizados

O sistema de controle deve ser capaz de lidar com diferentes situações de operação do motor de indução, quanto à carga e velocidade. Logo, cinco testes foram realizados em simulação e em bancada, para avaliar o desempenho do MPTC com fatores de ponderação otimizados:

a) Análise da dinâmica do fluxo de estator em regime permanente, a velocidade de 500 rpm, sem carga;

b) Resposta do controle a um degrau de torque mediante saturação do controlador PI, verificando os vetores selecionados e a dinâmica de torque;

c) Dinâmica de reversão de velocidade de -1500 a 1500 rpm, sem carga, analisando velocidade, torque e correntes no eixo $\alpha\beta$;

d) Resistência do sistema a um torque de carga de 1,5 Nm, 75% do torque nominal, aplicado em regime permanente do motor a 1500 rpm;

e) Análise em regime permanente da oscilação de torque e fluxo, bem como da frequência média de chaveamento do motor, em 1500 rpm, com e sem carga de 1,5 Nm.

Esses testes possibilitam que se avalie cada solução de controle quanto à qualidade das variáveis elétricas (fluxo e corrente de estator) e também o desempenho mecânico de torque e velocidade, considerando regime transiente e permanente. Os testes propostos foram aplicados a quatro topologias de controle:

a) Uma solução padrão do MPTC, em que $T_{band} = 0$, $\kappa_2 = 1$, $\lambda_3 = 0$. Essa solução equivale ao uso da função custo de (12), com o único fator de ponderação dado pela razão nominal (ZHANG; YANG, 2014);

b) O MRMPTC também foi implementado e testado, utilizando o operador de ordenação dos vetores *selection sort*;

c) MPTC com otimização de torque e fluxo realizada pelo NSGA-II;

d) MPTC com otimização de torque, fluxo e frequência de chaveamento realizada pelo NSGA-II.

6.2 Controle Preditivo Convencional

O MPTC com fator de ponderação convencional é chamado de solução A, servindo de referência. O seu tempo de execução no DSP foi computado em 28 µs. Em relação ao seu desempenho para magnetizar o motor de indução, tem-se na Figura 13 o gráfico das componentes do fluxo de estator para o uso da solução padrão do MPTC, em formato vetorial, para o MIT em regime permanente de 500 rpm, sem torque de carga, durante 0,5 s.

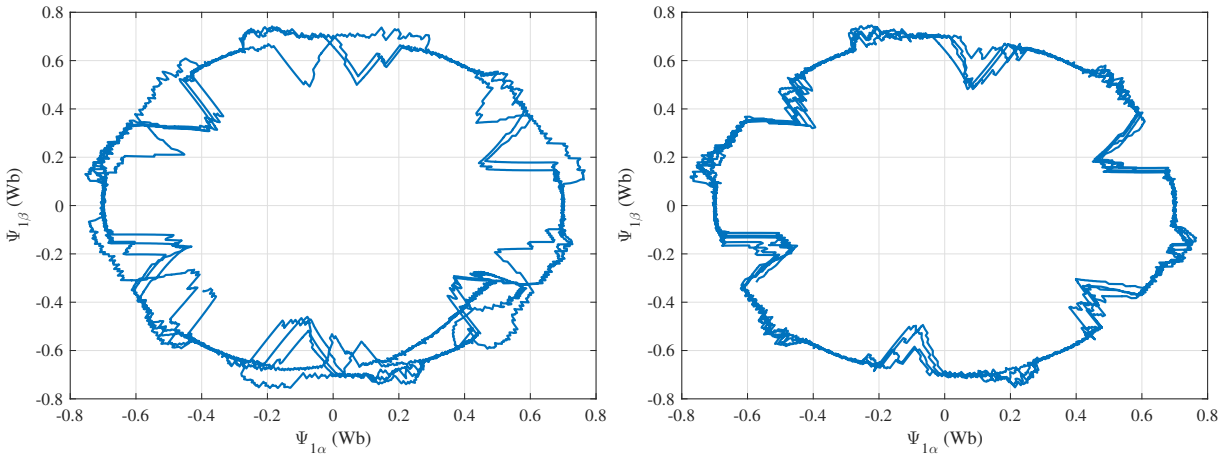

(a) Simulação. (b) Experimental.

Figura 13: Gráfico vetorial do fluxo de estator do MIT, a 500 rpm sem carga, para fatores de ponderação da solução A - simulado (a) e experimental (b).

Da análise do gráfico, tem-se que a solução padrão não é capaz de magnetizar o MIT no valor nominal desejado, de 0.7 Wb. Em regime, o valor desejado não é mantido constante, de modo que o fluxo apresenta uma amplitude intermitente, com oscilação superior a 0,3 Wb, mostrando que a combinação padrão dos fatores de ponderação não é uma solução satisfatória para o MPTC, fazendo-se necessária a otimização dos parâmetros.

O teste de resposta de torque foi realizado mediante uma referência de velocidade que sature o controlador PI. Assim, a Figura 14 apresenta a resposta de torque junto dos vetores selecionados a cada instante, na simulação e em ambiente experimental. Vê-se que, no momento em que o degrau de torque ocorreu, o sistema apresentou uma resposta com sobressinal, aparentando boa dinâmica e baixa oscilação. O aumento no erro de torque, durante o transiente, fez com o MPTC selecionasse vetores ativos. Como a função custo não depende da mudança de estados das chaves, os vetores podem mudar sempre que necessário.

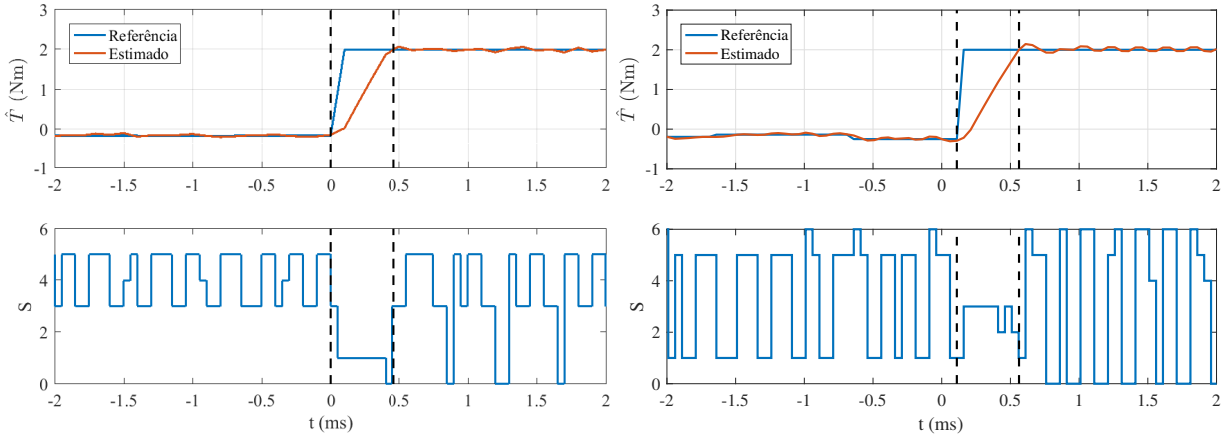

(a) Simulação. (b) Experimental.

Figura 14: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque, para fatores de ponderação da solução A - simulado (a) e experimental (b).

Um outro teste foi realizado, consistindo em uma reversão de velocidade sem torque de carga aplicado, de -1500 a 1500 rpm. Os gráficos simulados e experimentais de velocidade, torque estimado e correntes no eixo $\alpha\beta$ do uso da solução padrão são encontrados na Figura 15. Pode-se observar o baixo desempenho do torque durante a reversão, principalmente na fase final, assim como a má qualidade das correntes, evidenciando a necessidade de ajuste dos valores dos fatores de ponderação do MPTC.

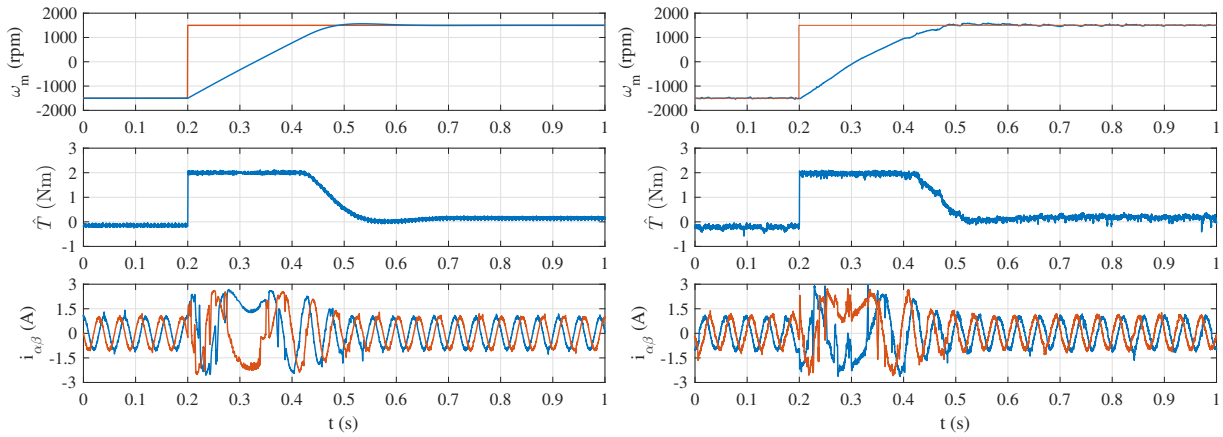

(a) Simulação. (b) Experimental.

Figura 15: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para fatores de ponderação da solução A - simulado (a) e experimental (b).

O último teste realizado refere-se a um distúrbio de carga de 1,5 Nm em regime de velocidade igual a 1500 rpm. A Figura 16 apresenta a resposta ao distúrbio do MPTC com a solução padrão, onde se vê que o sistema respondeu ao distúrbio restaurando a velocidade desejada após cerca de 200 ms. Porém, as correntes permaneceram apresentando picos em regime.

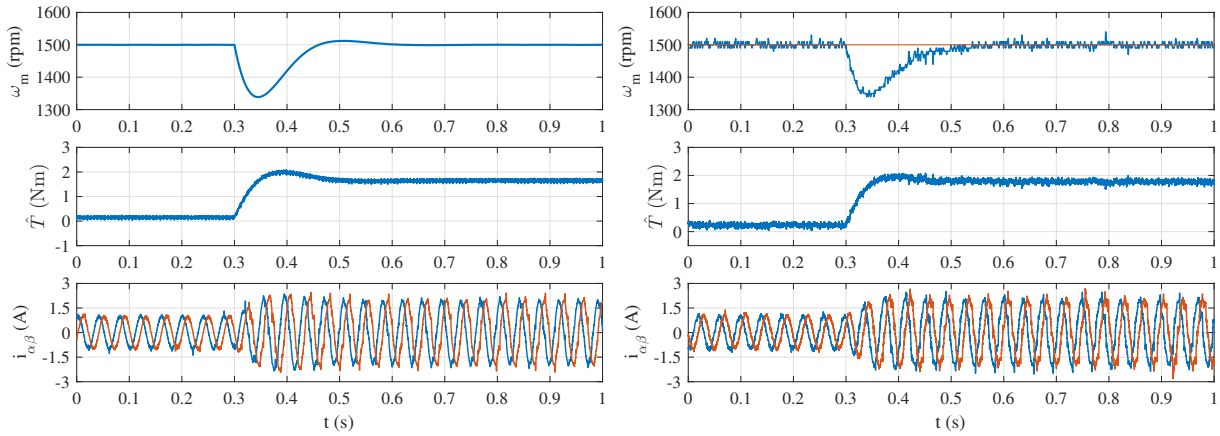

(a) Simulação. (b) Experimental.

Figura 16: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para fatores de ponderação da solução A - simulado (a) e experimental (b).

A oscilação de torque e fluxo do MPTC com função custo padrão, além da frequência média de chaveamento, estão na Tabela 5, junto da distorção harmônica total, ou THD, de corrente. Apesar de a oscilação de fluxo em 1500 rpm ser menor do que em 500 rpm, ainda continua acima de 10% do fluxo nominal, tanto com quanto sem carga, a despeito da alta frequência média de chaveamento empregada. A adição do termo de minimização de frequência deterioraria ainda mais a dinâmica de fluxo, de modo que o ajuste dos outros fatores de ponderação também é necessário. A aplicação de carga reduziu a oscilação de torque e aumentou a frequência de chaveamento.

Tabela 5: Indicadores de desempenho experimentais obtidos para o MPTC com solução padrão, em regime de 1500 rpm, para duas condições de carga.

T_L	Solução	T_{rip} (Nm)	Ψ_{rip} (Wb)	$\overline{f_c}$ (kHz)	THD$_i$ (%)
0	A	0,456	0,0784	6,425	5,14
1,5	A	0,365	0,1087	6,523	6,93

6.3 Controle Preditivo de Classificação Multiobjetivo

A técnica MRMPTC, chamada de solução B, também foi implementada com a mesma estrutura de estimação e predição das variáveis que o MPTC, diferindo apenas na determinação do vetor a ser aplicado. O tempo total de execução foi de 45,9 µs. A Figura 17 mostra a dinâmica de fluxo em regime permanente do MRMPTC, em velocidade de 500 rpm sem carga. Ao contrário da solução A, a amplitude do fluxo de estator é mantida controlada no valor desejado, com uma oscilação menor do que 3% do fluxo nominal.

A resposta ao degrau de torque é vista na Figura 18, onde se vê que controle preditivo respondeu à referência de torque, com um tempo de assentamento similar ao MPTC

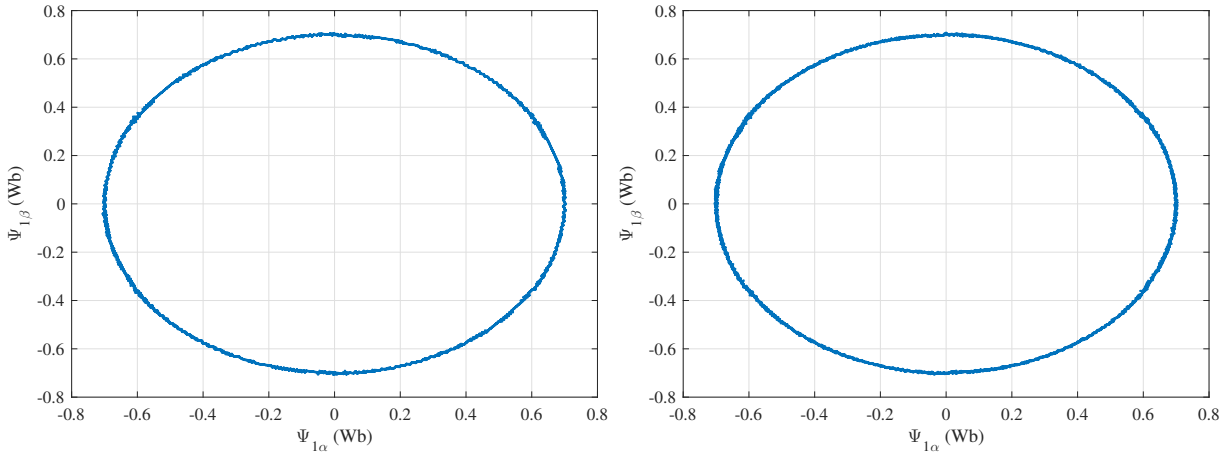

(a) Simulação. (b) Experimental.

Figura 17: Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução B - simulado (a) e experimental (b).

convencional. Como não há estratégia de minimização do chaveamento, mais uma vez as trocas de vetores ocorrem com alta frequência.

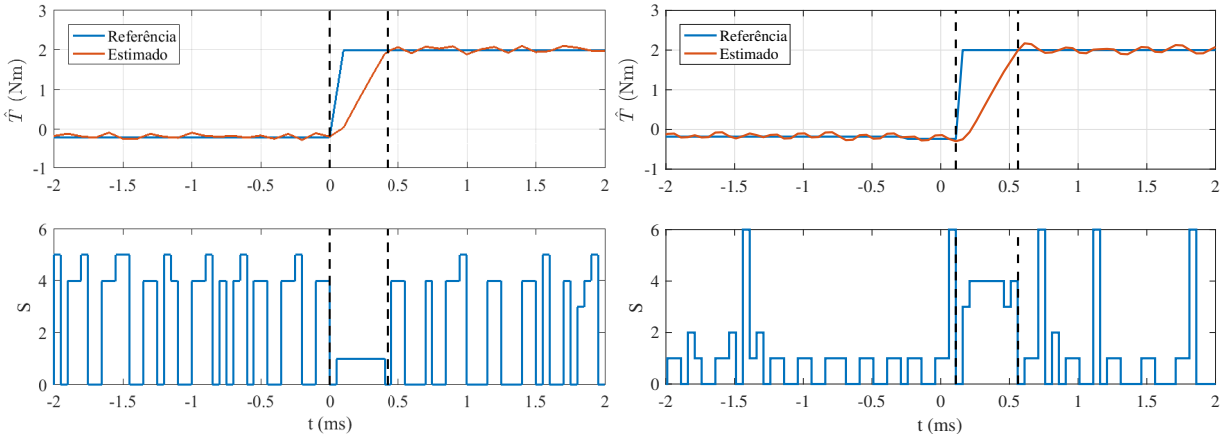

(a) Simulação. (b) Experimental.

Figura 18: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para solução B - simulado (a) e experimental (b).

Os gráficos da Figura 19, relativos à solução B no teste de reversão de velocidade, mostram dinâmica semelhante ao MPTC convencional, porém uma oscilação de torque maior, com picos intermitentes, tanto na simulação quanto na prática. As correntes durante o transiente de velocidade apresentaram melhor qualidade do que o MPTC convencional.

Os gráficos de resistência ao distúrbio estão na Figura 20, onde se percebe que com carga o motor restabelece a velocidade desejada de forma similar ao MPTC convencional, porém continua a apresentar um torque com picos intermitentes.

Na Tabela 6, tem-se os indicadores de desempenho obtidos pelo MRMPTC a 1500 rpm, sem e com carga de 1,5 Nm. A oscilação de torque é alta, porém há maior qualidade do

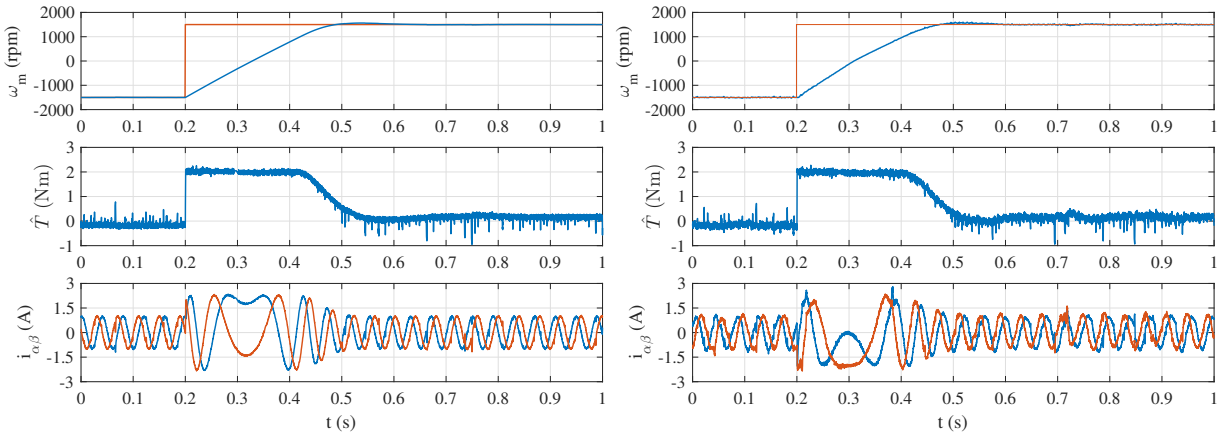

(a) Simulação. (b) Experimental.

Figura 19: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para solução B - simulado (a) e experimental (b).

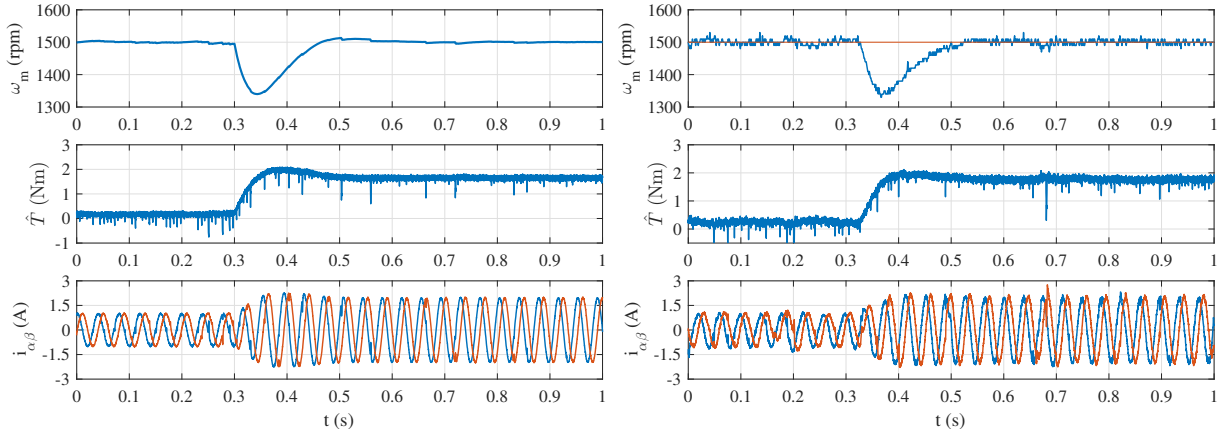

(a) Simulação. (b) Experimental.

Figura 20: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para solução B - simulado (a) e experimental (b).

fluxo de estator, com uma oscilação inferior a 3% do nominal. As frequências de chaveamento permaneceram acima de 5 kHz, devido à ausência do seu termo de minimização. A sua inclusão reduziria a frequência do sistema, porém aumentaria a degradação do torque.

Tabela 6: Indicadores de desempenho experimentais obtidos para o MRMPTC, em regime de 1500 rpm, para duas condições de carga.

T_L	Solução	T_{rip} (Nm)	Ψ_{rip} (Wb)	$\overline{f_c}$ (kHz)	THD$_i$ (%)
0	B	1,232	0,0203	5,924	10,7
1,5	B	1,130	0,0210	5,683	4,13

6.4 Otimização de Torque e Fluxo

A primeira otimização realizada considerou apenas as variáveis primárias de controle, torque e fluxo, por meio das suas oscilações em regime permanente. A execução do NSGA-II, após todas as gerações, resultou na fronteira de Pareto mostrada na Figura 21 (a), onde se vê a relação entre oscilação de torque T_{rip} e a oscilação de fluxo Ψ_{rip} das soluções (o fenótipo da população), onde se vê a relação as variáveis. O genótipo obtido é mostrado na Figura 21 (b), que mostra as soluções no espaço de busca do algoritmo.

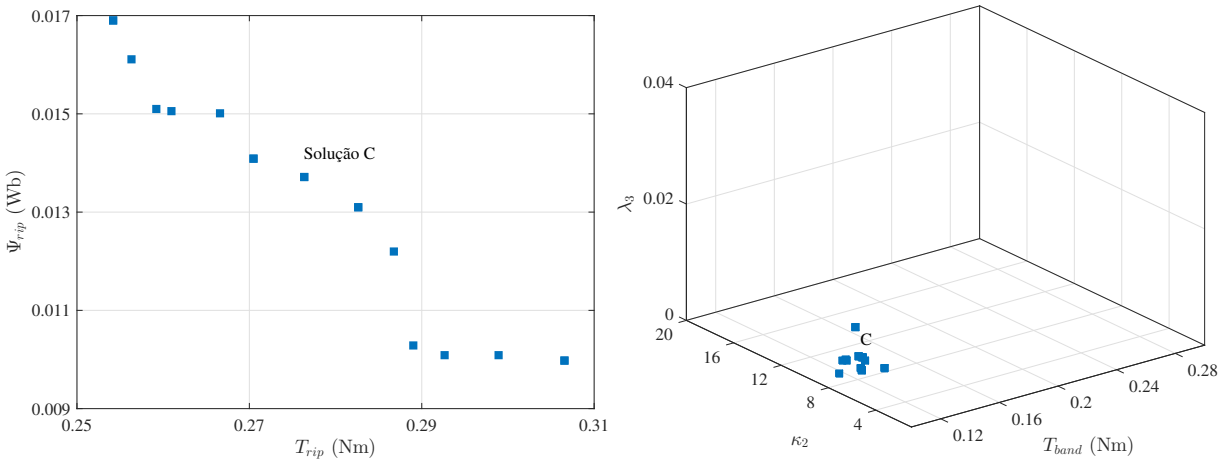

(a) Fenótipo. (b) Genótipo.

Figura 21: Fronteira de Pareto obtida pelo NSGA-II para otimização de torque e fluxo do MPTC aplicado ao MIT - fenótipo (a) e genótipo (b).

A oscilação de torque das soluções finais concentrou-se em uma faixa com variação inferior a 0,1 Nm, e a oscilação de fluxo em uma faixa com variação inferior a 0,01 Wb. Ainda, o gráfico do genótipo mostra como as soluções convergiram para uma mesma região do espaço de busca. Isso mostra que o desempenho de torque e fluxo não são essencialmente variáveis contrastantes, de forma que o NSGA-II foi capaz de otimizar as duas simultaneamente. Ainda, ressalta-se que o parâmetro λ_3 permaneceu com valores baixos uma vez que sua influência maior é na frequência de chaveamento, que não foi considerada na otimização. Assim, considerou-se uma única solução do conjunto, salientada nos gráficos e chamada de solução C, para os teste simulados e experimentais. A Tabela 7 mostra os seus parâmetros. Nota-se que, como não há otimização da frequência de chaveamento, o parâmetro λ_3 permanece em próximo do seu limite inferior. As outras soluções estão na Tabela 12, no Apêndice A.

O gráfico vetorial do fluxo de estator da solução C é visto na Figura 22, mostrando como o MPTC com a solução otimizada magnetizou o MIT com oscilação semelhante à do MRMPTC.

No segundo teste, cujos gráficos encontram-se na Figura 23, vê-se que tanto na simulação quanto na bancada a solução padrão proveu um tempo de resposta similar aos anteriores, entre 0,3 e 0,4 ms. O período transiente é caracterizado pela seleção apenas

Tabela 7: Solução selecionada para testes de validação do MPTC com torque e fluxo otimizados pelo NSGA-II.

Solução	T_{band}	κ_2	λ_3
C	0,1281	8,7750	0,0007

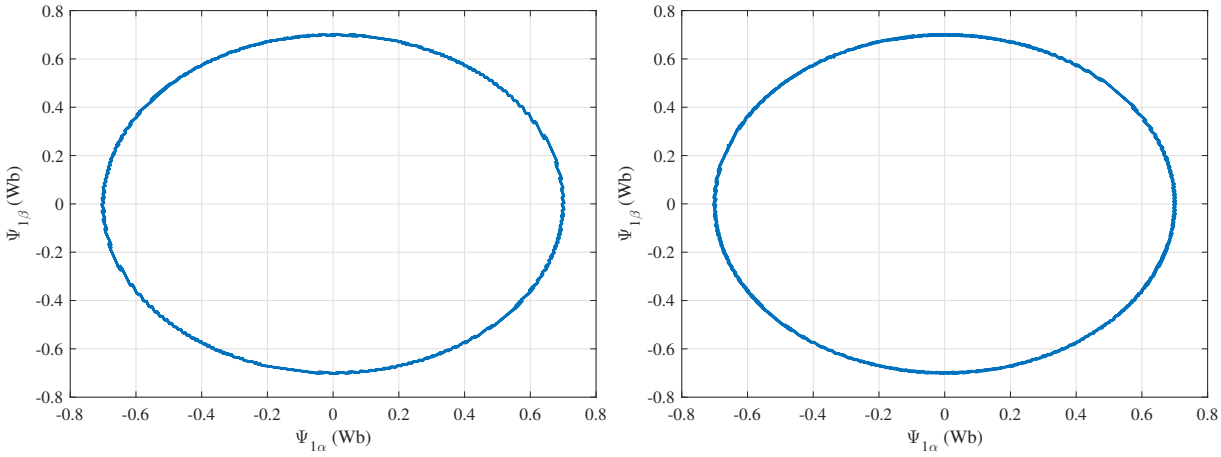

(a) Simulação. (b) Experimental.

Figura 22: Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução C - simulado (a) e experimental (b).

de vetores ativos, buscando minimizar o erro de torque. Não se percebe diferença no

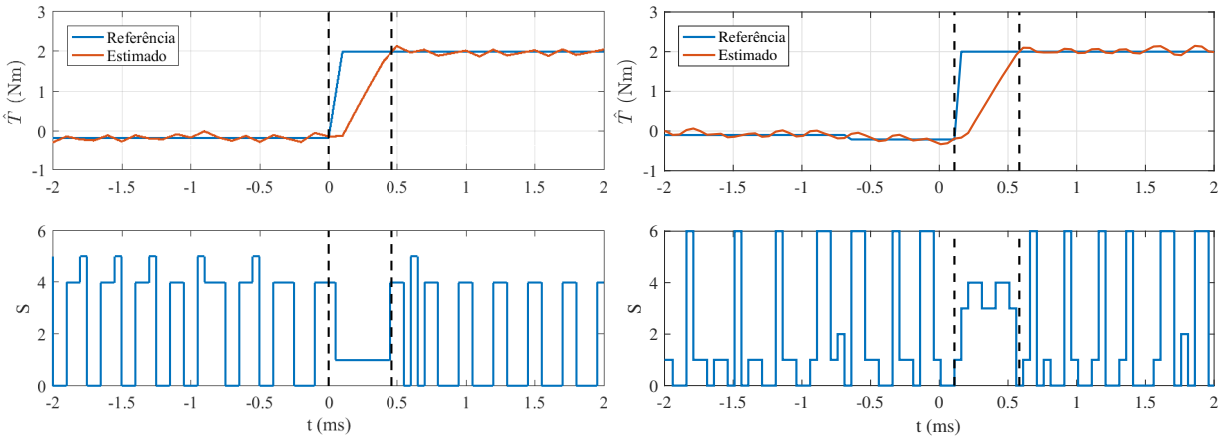

(a) Simulação. (b) Experimental.

Figura 23: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b).

número de chaveamentos desta solução frente às anteriores, uma vez que essa variável não foi considerada na otimização.

Também se realizou para o MIT o teste de reversão de velocidade de -1500 a 1500 rpm, sem torque de carga aplicado. Os gráficos simulados e experimentais de velocidade, torque

estimado e correntes no eixo $\alpha\beta$ são encontrados na Figura 24. Tanto na simulação quanto no teste experimental, o uso da solução otimizada possibilitou uma dinâmica de torque sem os picos intermitentes do MRMPTC, ao mesmo tempo com boa qualidade das correntes durante a reversão, o que não acontecia no uso da solução convencional.

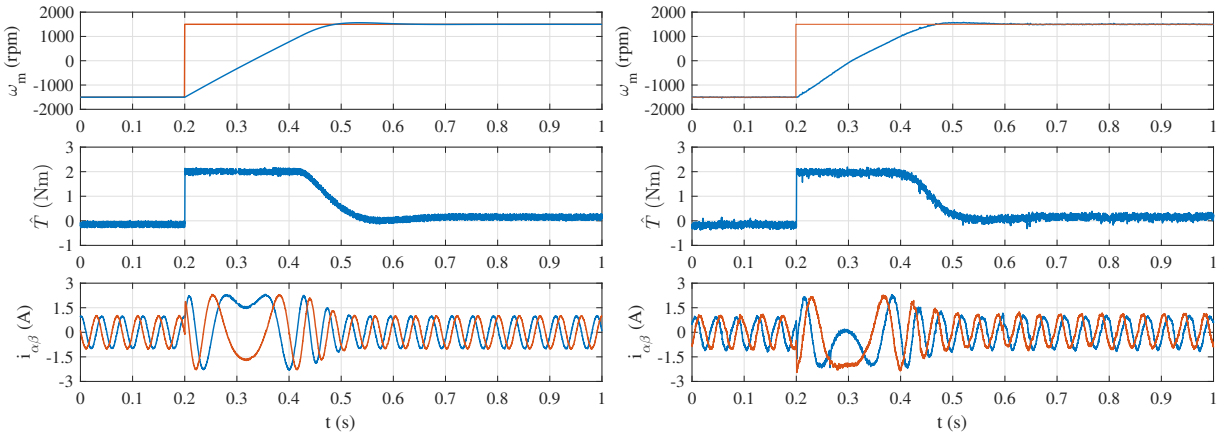

(a) Simulação. (b) Experimental.

Figura 24: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b).

A Figura 25 apresenta a resposta ao distúrbio do MPTC com a solução otimizada, onde se vê que o sistema respondeu ao distúrbio restaurando a velocidade desejada após cerca de 200 ms, como visto nas outras soluções. Novamente, percebe-se o torque com melhor qualidade do que o MRMPTC.

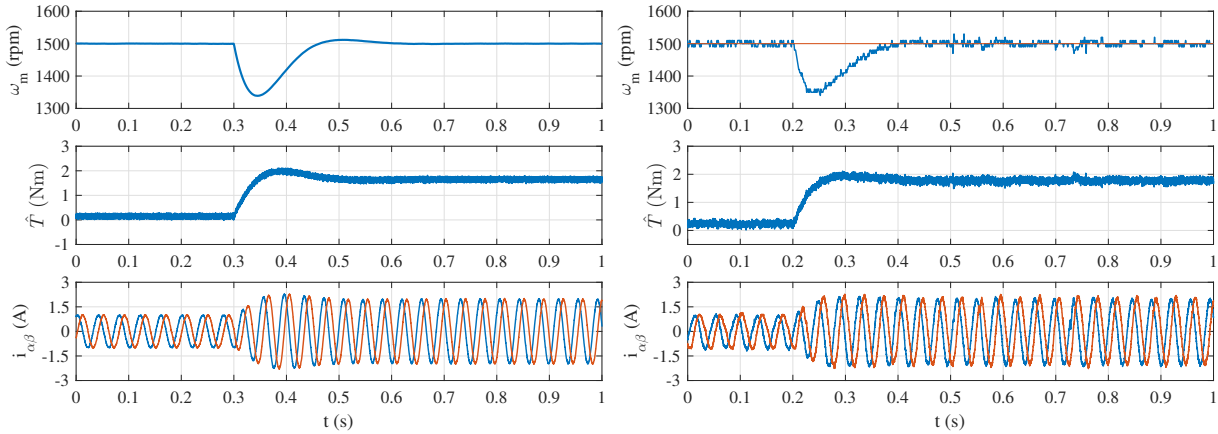

(a) Simulação. (b) Experimental.

Figura 25: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para fatores de ponderação da solução C - simulado (a) e experimental (b).

Na Tabela 8 estão os indicadores de desempenho obtidos em regime permanente de 1500 rpm para o uso da solução otimizada. O torque de carga foi sempre inferior a 0,5 Nm e maior do que o obtido pelo MPTC convencional. Porém, a qualidade do fluxo melhorou,

ficando abaixo dos 3% do fluxo nominal, superando também o MRMPTC. Analisando a oscilação de torque e fluxo, tem-se que a solução otimizada domina o MRMPTC, uma vez que possui menores valores nos dois índices. A qualidade das correntes melhorou com a adição de carga, e a frequência de chaveamento permaneceu próxima dos 6 kHz.

Tabela 8: Indicadores de desempenho experimentais obtidos para MPTC com fatores de ponderação da solução C, em regime de 1500 rpm, para duas condições de carga.

T_L	Solução	T_{rip} (Nm)	Ψ_{rip} (Wb)	$\overline{f_c}$ (kHz)	THD$_i$ (%)
0	C	0,493	0,0152	5,761	11,5
1,5	C	0,467	0,0153	5,365	3,45

6.5 Otimização da Frequência de Chaveamento

Por fim, a frequência de chaveamento foi adicionada no processo de otimização. A nova execução do NSGA-II, após todas as gerações, resultou na fronteira de Pareto mostrada na Figura 26, onde se vê a relação entre oscilação de torque T_{rip}, a oscilação de fluxo Ψ_{rip} e a frequência de chaveamento média $\overline{f_c}$ das soluções (o fenótipo da população). Ao contrário da otimização apenas do torque e fluxo, pode-se ver aqui o compromisso entre as variáveis, excursionando em uma região grande do espaço. Isto deve-se à influência da frequência de chaveamento nos indicadores de torque e fluxo, uma vez que a minimização dela ocorre às custas de deteriorar as suas dinâmicas. Três soluções são destacadas: a

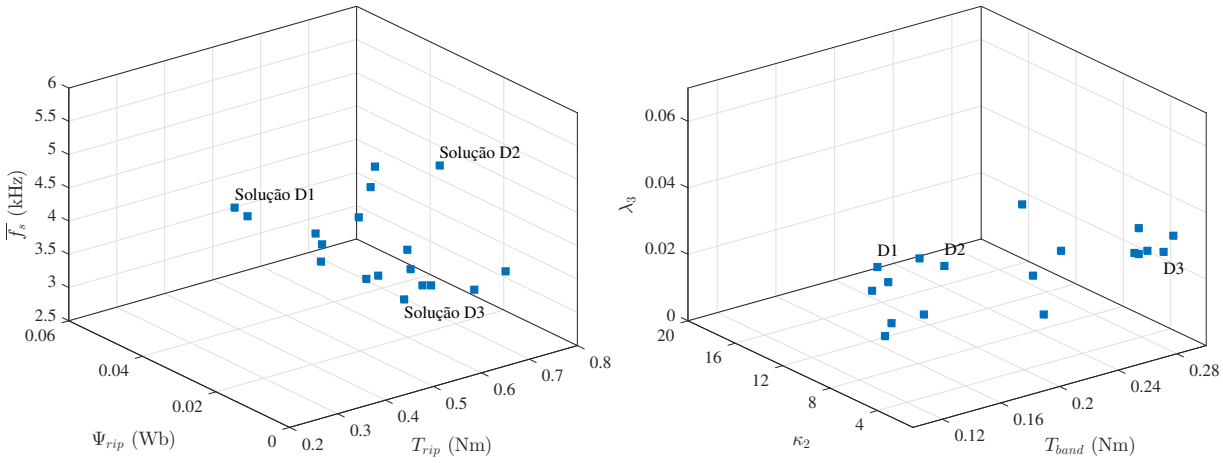

(a) Fenótipo. (b) Genótipo.

Figura 26: Fronteira de Pareto obtida pelo NSGA-II para otimização de torque, fluxo e frequência do MPTC aplicado ao MIT - fenótipo (a) e genótipo (b).

solução apontada como D1 oferece a menor oscilação de torque, enquanto que a solução denotada como D2 tem a menor oscilação de fluxo. A solução D3, por sua vez, oferece a menor frequência média de chaveamento. Estas três soluções, listadas na Tabela 9, foram

Tabela 9: Três soluções selecionadas para testes de validação do MPTC com torque, fluxo e frequência otimizados pelo NSGA-II.

Solução	T_{band}	κ_2	λ_3
D1	0,1044	3,8940	0,0219
D2	0,2352	15,091	0,0081
D3	0,2829	2,5016	0,0279

consideradas para as simulações e testes experimentais, a fim de validar a proposta. A solução D1 possui a banda de torque próxima do seu limite inferior, o que diminui a oscilação de torque. A solução D2 tem o menor valor de λ_3, ou seja, a menor influência do termo de penalização da frequência. Ainda, o fator κ_2 é o maior entre os três no espaço de busca, quase quatro vezes superior ao de D1 e seis vezes superior ao de D3. Assim, a maior importância do erro de fluxo na função custo implica a redução da oscilação de fluxo. A solução D3 por sua vez possui o maior valor de λ_3, ou seja, o termo de penalização da frequência possui maior importância nesta solução. Desse modo, aliado ao maior valor de banda de torque, resulta-se na menor frequência de chaveamento. As outras soluções providas pelo NSGA-II estão na Tabela 13, disponível no Apêndice A.

Os gráficos de magnetização para as soluções D1, D2 e D3 são mostrados nas Figuras 27, 28 e 29. Em oposição à solução padrão, mais uma vez as soluções providas pelo NSGA-II garantiram que a magnetização atingisse o fluxo de referência como desejado. Entre si, as soluções diferiram quanto à oscilação do fluxo em regime, de modo que a solução D3 apresentou o maior valor, com alguns picos. Isso se deve à minimização da frequência de chaveamento indicada pela fronteira de Pareto. No entanto, o seu desempenho ainda foi superior ao do MPTC com fator convencional, no qual o fluxo não foi corretamente controlado. A solução D2 de fato apresentou a menor oscilação de fluxo, como era esperado pela fronteira de Pareto.

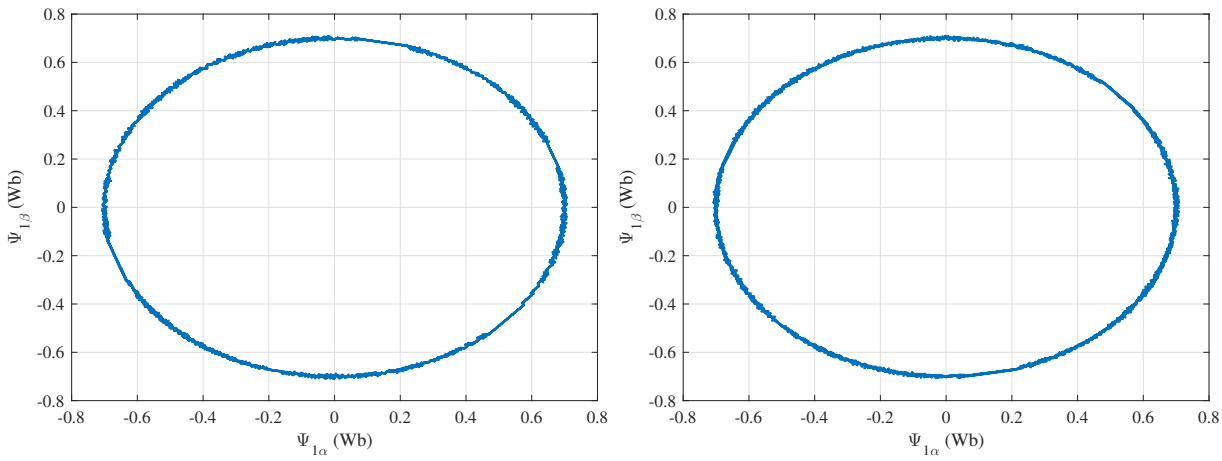

(a) Simulação. (b) Experimental.

Figura 27: Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D1 - simulado (a) e experimental (b).

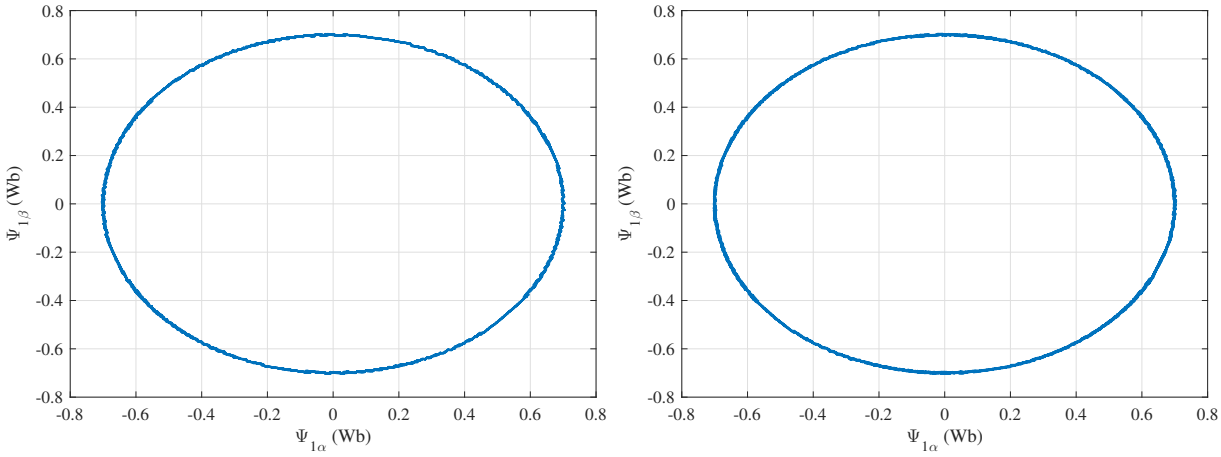

(a) Simulação. (b) Experimental.

Figura 28: Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D2 - simulado (a) e experimental (b).

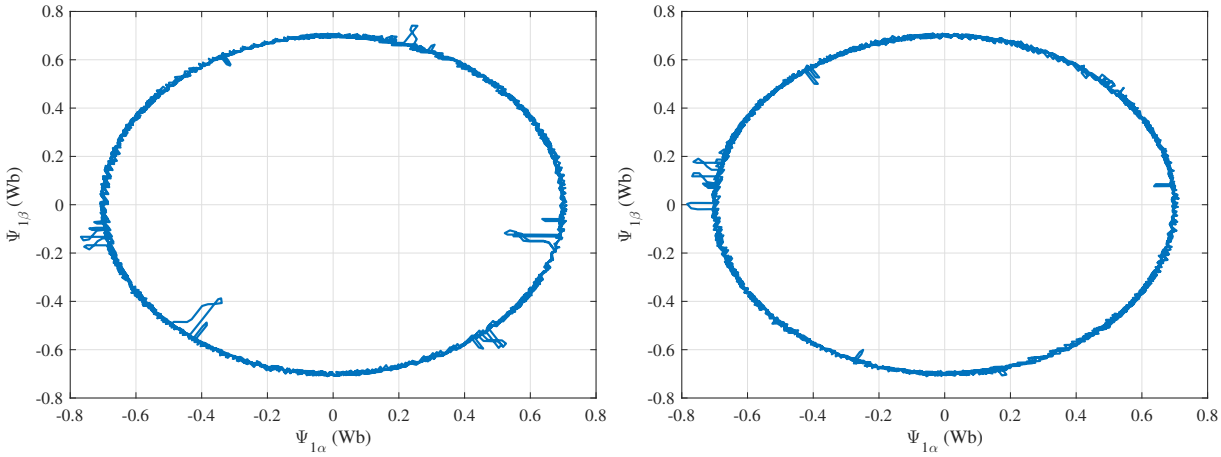

(a) Simulação. (b) Experimental.

Figura 29: Gráfico vetorial do fluxo de estator do MIT a 500 rpm sem carga, para fatores de ponderação da solução D3 - simulado (a) e experimental (b).

Quanto ao teste de resposta das soluções a um degrau de torque máximo, obtiveram-se gráficos de torque e vetores selecionados mostrados nas Figuras 30, 31 e 32 para as soluções D1, D2 e D3, respectivamente. Pode-se perceber que cada solução desenvolveu um torque com diferentes níveis de oscilação, seguido o esperado pela fronteira de Pareto, com tempos de resposta da ordem de 0,4 ms. Durante o transiente, novamente se vê que apenas vetores ativos foram selecionados pelo MPTC. Ainda, destaca-se que a solução D1 visivelmente causou mais chaveamentos no inversor, implicando uma maior frequência média de chaveamento, como era esperado. A solução D3 provocou menos chaveamentos, tanto na simulação quanto na prática. Consequentemente, essa solução obtém uma menor frequência média, sacrificando a oscilação de torque, como também indicado pelo resultado do NSGA-II.

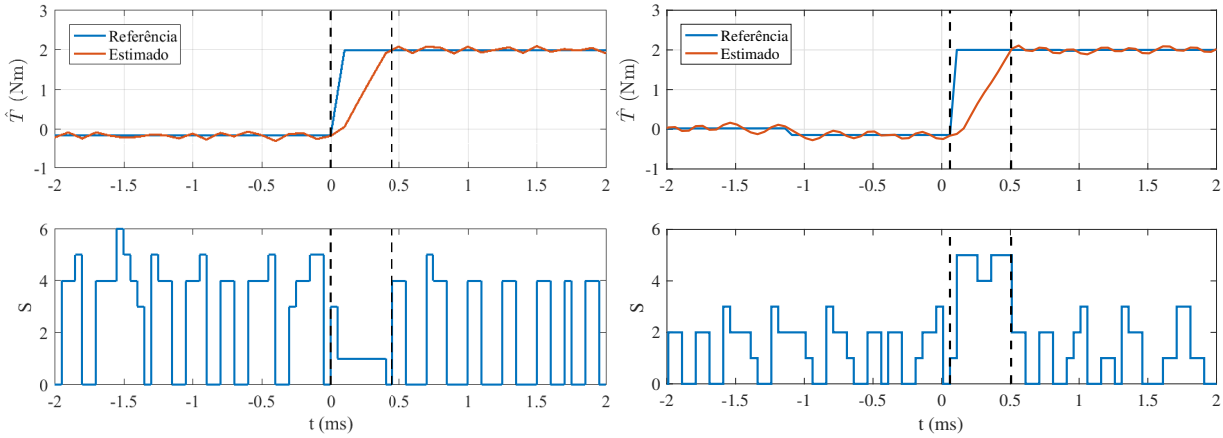

(a) Simulação. (b) Experimental.

Figura 30: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b).

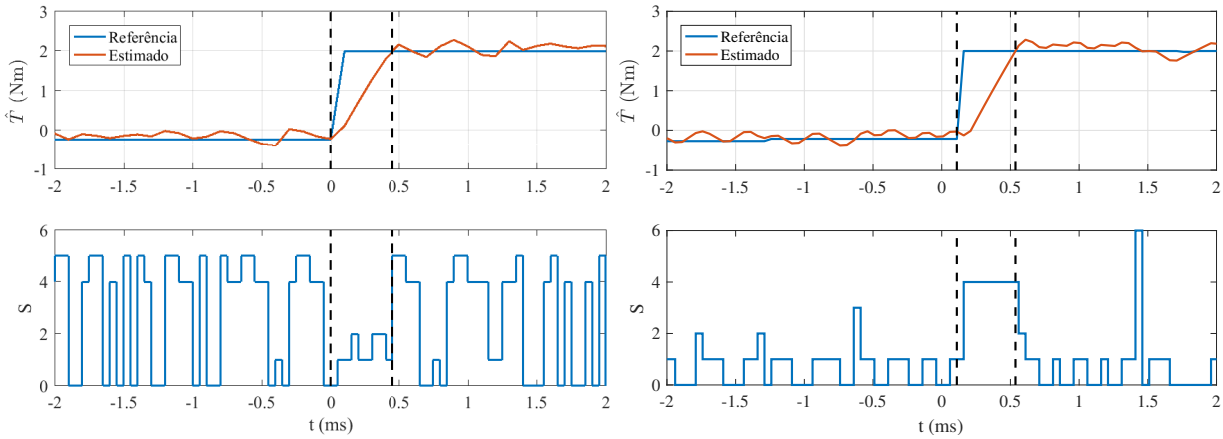

(a) Simulação. (b) Experimental.

Figura 31: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b).

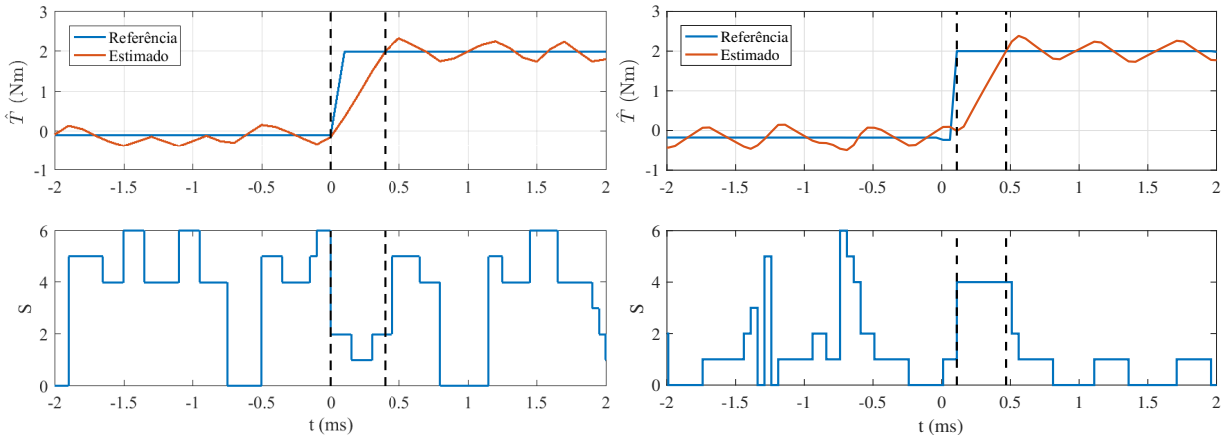

(a) Simulação. (b) Experimental.

Figura 32: Perfil de torque e vetores escolhidos pelo MPTC durante degrau de torque do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b).

Também se realizou para o MIT o teste de reversão de velocidade de -1500 a 1500 rpm, sem torque de carga aplicado. Novamente, os três conjuntos de fatores foram considerados. Os gráficos para o uso das soluções D1, D2 e D3 são apresentados nas Figuras 33, 34 e 35, respectivamente. Os resultados experimentais mostraram-se em conformidade com os simulados para as três soluções, e em todos os casos o sistema foi capaz de prover torque máximo durante a reversão, com torque desenvolvido sem picos intermitentes. Adicionalmente, as soluções diferiram entre si pela oscilação de torque, em que a menor foi obtida pela solução D1 e a maior pela solução D3, como esperado pela fronteira de Pareto e indicado pelos gráficos do degrau de torque. As formas de onda das correntes também melhoraram significantemente quando comparadas às da solução padrão.

O último teste realizado, que é o distúrbio de carga de 1,5 Nm em regime de velocidade igual a 1500 rpm, resultou nos gráficos simulados e experimentais das Figuras 36, 37 e 38, respectivamente para as soluções D1, D2 e D3. Mais uma vez as dinâmicas de velocidade foram similares, com o motor recuperando a velocidade desejada original. Ainda, assim como na reversão pode-se ver a diferença de oscilação e torque entre as soluções, em que a solução D1 apresentou o menor valor e a solução D3 o maior.

A oscilação de torque, a frequência média de chaveamento e a distorção harmônica da corrente são mostradas na Tabela 10, comprovando a relação inversa entre os indicadores de desempenho dinâmico e o de eficiência energética. A solução D3 apresentou a menor frequência média de chaveamento com e sem carga, ao custo de ter as maiores oscilações de torque de fluxo. A qualidade das correntes em regime foi superior em todos os casos ao aplicar-se a carga, e o pior valor de THD foi obtido pela solução D2.

Tabela 10: Indicadores de desempenho experimentais obtidos para as três soluções da otimização considerando frequência de chaveamento, em regime de 1500 rpm, para duas condições de carga.

T_L	Solução	T_{rip} (Nm)	Ψ_{rip} (Wb)	$\overline{f_c}$ (kHz)	THD$_i$ (%)
0	D1	0,439	0,0254	4,907	6,81
	D2	0,721	0,0147	5,136	10,0
	D3	0,772	0,0816	2,775	8,16
1,5	D1	0,425	0,0252	4,584	1,69
	D2	0,660	0,0157	4,926	3,59
	D3	0,734	0,0612	2,478	1,99

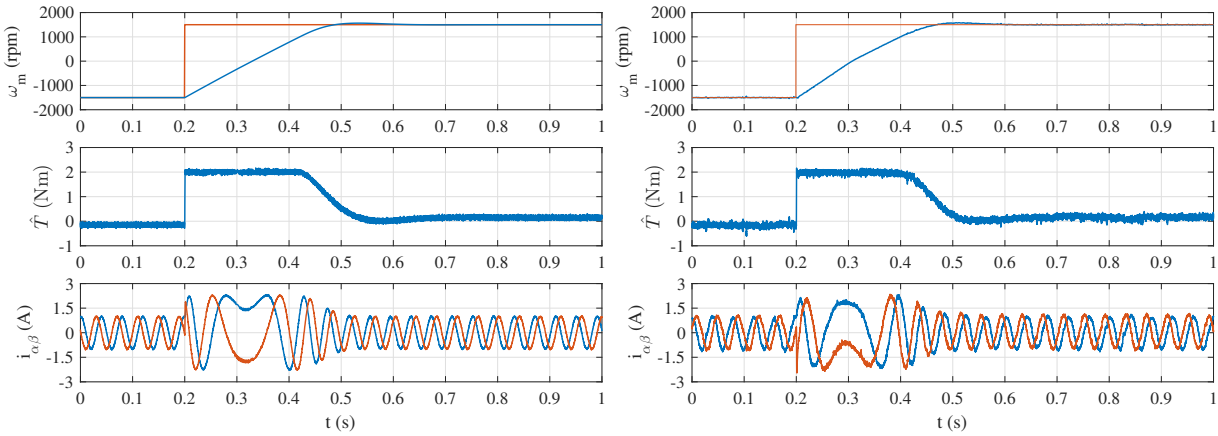

(a) Simulação. (b) Experimental.

Figura 33: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b).

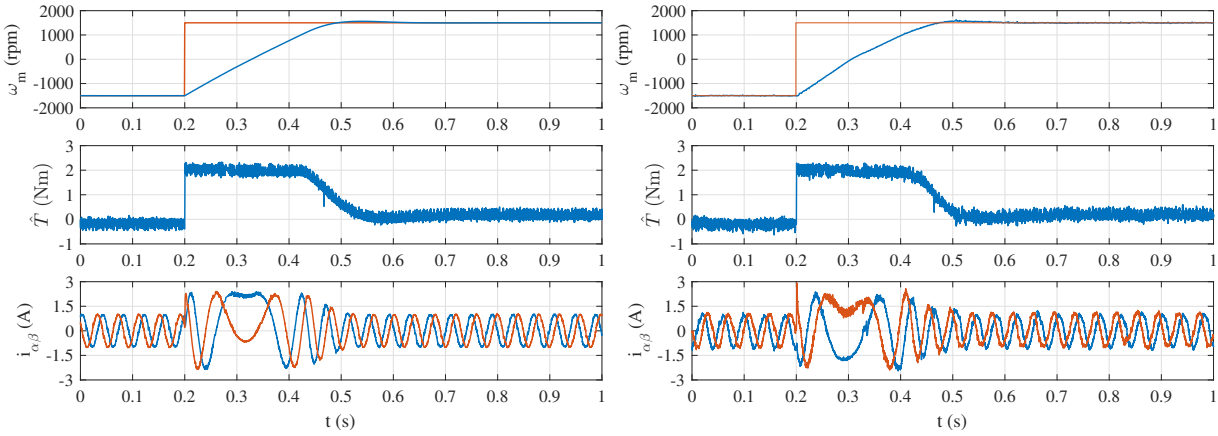

(a) Simulação. (b) Experimental.

Figura 34: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b).

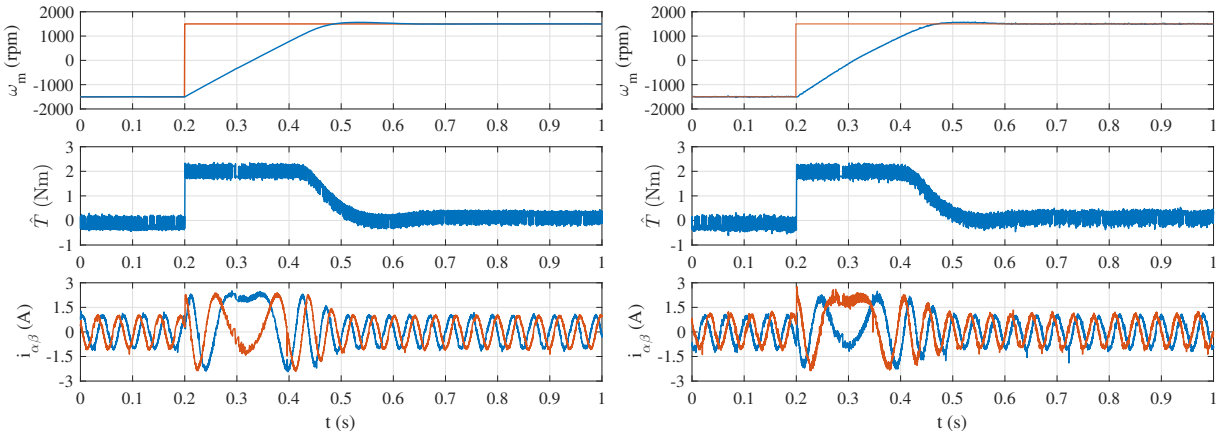

(a) Simulação. (b) Experimental.

Figura 35: Perfis de velocidade, torque e corrente durante reversão de velocidade do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b).

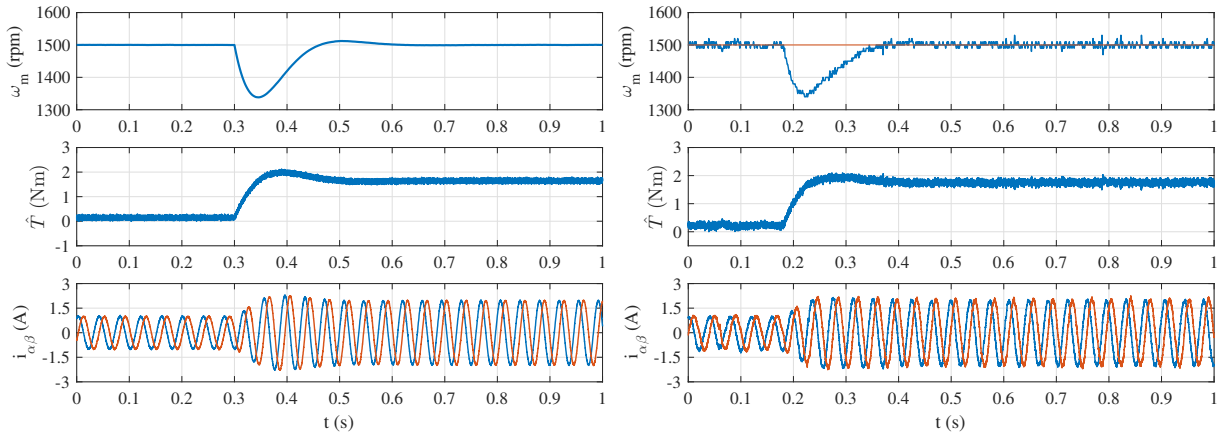

(a) Simulação. (b) Experimental.

Figura 36: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D1 - simulado (a) e experimental (b).

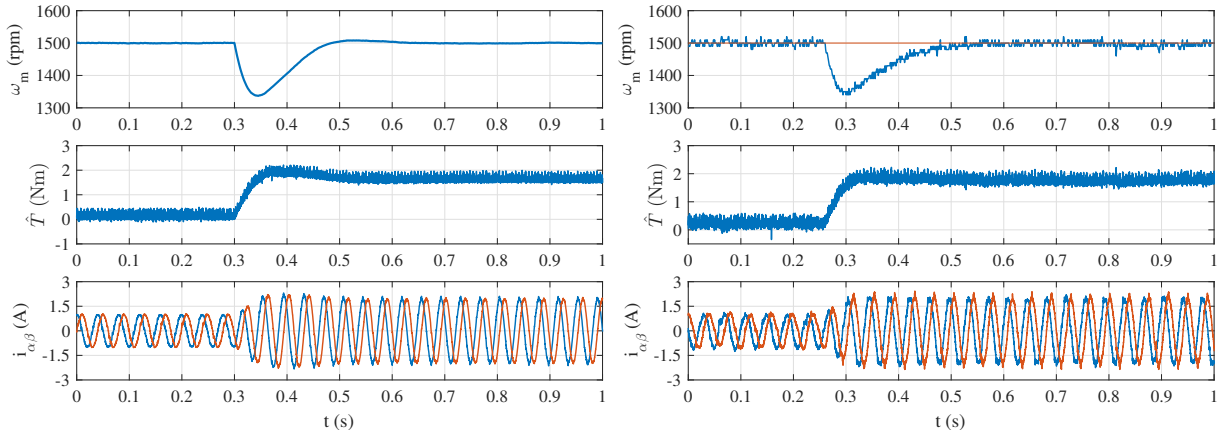

(a) Simulação. (b) Experimental.

Figura 37: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D2 - simulado (a) e experimental (b).

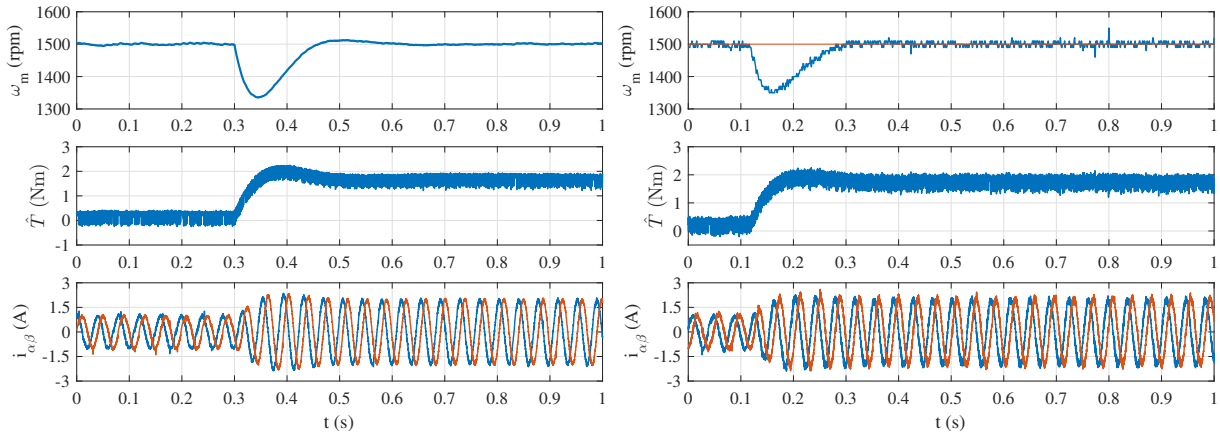

(a) Simulação. (b) Experimental.

Figura 38: Perfis de velocidade, torque e corrente durante distúrbio de carga do MIT, para os fatores de ponderação da solução D3 - simulado (a) e experimental (b).

6.6 Discussões

As medições de oscilação de torque, de fluxo e da frequência média a 1500 rpm permitem a obtenção dos gráficos da Figura 39, onde se vê a disposição dos indicadores de cada solução avaliada no espaço de desempenho, sem e com carga aplicada. Pode-se perceber que a solução A apresentou o pior desempenho de fluxo e a solução B a pior oscilação de torque.

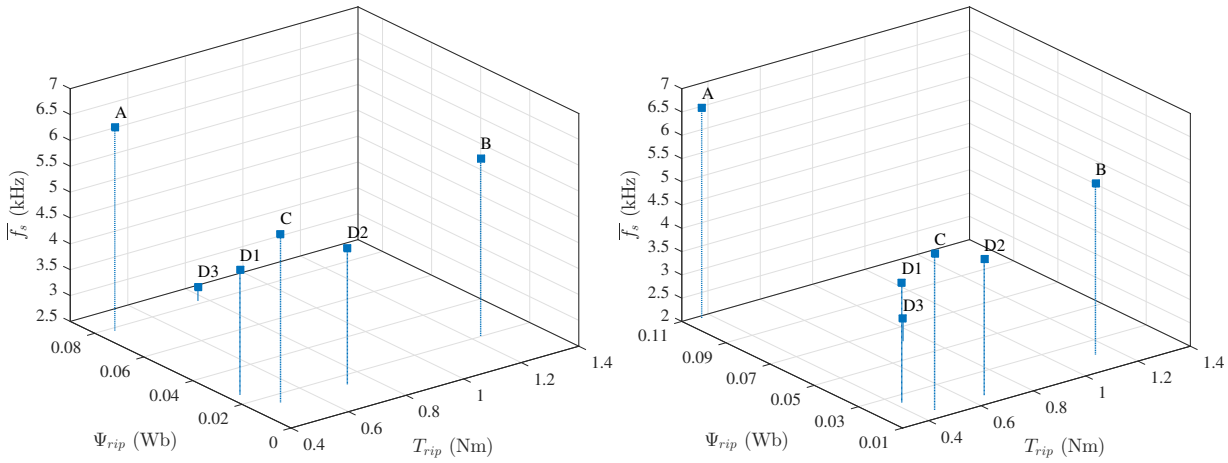

(a) Sem carga. (b) Com carga.

Figura 39: Índices de desempenho experimentais obtidos a 1500 rpm pelas soluções consideradas - sem carga (a) e com carga (b).

Uma análise dos gráficos possibilita a separação das soluções em classes não-dominadas, viabilizando a análise dos seus desempenhos. A Tabela 11 sumariza as relações para cada combinação de indicadores de desempenho. A solução D1 foi a única a sempre pertencer à classe não-dominada 1. Quando se analisam apenas as duas variáveis primárias de

Tabela 11: Relações de dominância entre as soluções testadas para cada combinação de índices, em regime de 1500 rpm, para duas condições de carga.

T_L	Índices	Classe 1	Classe 2	Classe 3	Classe 4
0	T_{rip}xΨ_{rip}	C/D1/D2	A/B	D3	—
	T_{rip}x$\overline{f_c}$	D1/D3	A/C/D2	B	—
	Ψ_{rip}x$\overline{f_c}$	D1/D2/D3	C	B	A
	T_{rip}xΨ_{rip}x$\overline{f_c}$	C/D1/D2/D3	A/B	—	—
1,5	T_{rip}xΨ_{rip}	A/C/D1/D2	B	D3	—
	T_{rip}x$\overline{f_c}$	A/D1/D3	C/D2	B	—
	Ψ_{rip}x$\overline{f_c}$	C/D1/D2/D3	B	A	—
	T_{rip}xΨ_{rip}x$\overline{f_c}$	A/C/D1/D2/D3	B	—	—

controle, tem-se que a solução C, advinda da otimização de torque e fluxo, e as soluções D1 e D2 da otimização incluindo frequência estiveram na classe 1 com e sem carga. A solução D3 pertenceu a última classe, resultado da ênfase em mitigar a frequência, que prejudicou torque e fluxo. A adição da frequência na análise, no entanto, coloca a solução D3 sempre na classe não-dominada 1.

No caso em que os três índices são considerados, tem-se que a solução B, obtida pelo MRMPTC, foi sempre dominada pelas soluções obtidas pelo NSGA-II. A solução A, apesar de eventualmente situar-se na classe 1, o fez apresentando a maior oscilação de fluxo.

Ainda, ressalta-se a diferença de tempo de execução entre as soluções. A solução B apresenta um acréscimo considerável no custo computacional em razão do algoritmo de ordenamento de vetores. As soluções providas pelo NSGA-II, por sua vez, apresentando exatamente o mesmo tempo de execução que a solução A no DSP. No entanto, o ajuste é feito offline, de modo que o custo computacional reside na necessidade de um computador.

Capítulo 7

Considerações Finais

7.1 Conclusões Finais

O controle e acionamento do motor de indução foi realizado pelo MPTC, técnica de otimização em tempo real baseado no modelo da planta. Em sua estrutura considerou-se a minimização da frequência de chaveamento do inversor, ao inserir-se um termo proporcional ao número de mudanças de chaves provocado pelo vetor de tensão. Simulações em ambiente computacional mostraram a influência dos fatores de ponderação no torque, fluxo de estator, corrente de estator e frequência de chaveamento do sistema, justificando a sua necessidade de ajuste.

Para suprir a necessidade de projeto dos fatores de peso, aplicou-se um sistema inteligente, a saber o NSGA-II, na otimização destes fatores, considerando duas topologias: otimização das oscilações de torque e fluxo, visando desempenho dinâmico, e adição da frequência de chaveamento, totalizando três variáveis de otimização e balanceando desempenho e eficiência energética. Adicionalmente, implementou-se o MPTC com fator de peso convencional, sem ajuste, e uma técnica de controle preditivo sem fatores de peso, baseada em otimização multiobjetivo *online*, o MRMPTC, possibilitando a comparação destas topologias.

Os resultados experimentais, que foram condizentes com os simulados, forneceram conclusões para o entendimento e a solução do problema. Primeiramente corroboraram a necessidade de ajuste dos fatores de ponderação, à medida em que o motor de indução não possuiu dinâmica de fluxo satisfatória com a função custo com ajuste convencional. Segundo, a otimização de torque e fluxo foi capaz de resolver o problema de magnetização do motor, e prover uma oscilação de torque próxima daquela da solução original, uma vez que o NSGA-II convergiu para uma fronteira de Pareto que maximizou o desempenho de torque e fluxo do motor. Ainda, a consideração da frequência de chaveamento no NSGA-II, efetuada na sua estrutura, aumentou a diversidade da fronteira de Pareto, pois agora um dos objetivos operou de forma contrária ao outros dois, tipificando um problema multiobjetivo. O NSGA-II proveu soluções com diferentes níveis de oscilação de

torque e fluxo e de frequência, de modo que cabe ao projetista selecionar mais adequada à aplicação. Destaca-se também que as soluções da fronteira de Pareto apresentaram desempenho em geral superior ao do MRMPTC, sem acréscimo de custo computacional ao hardware utilizado. Por outro lado, o uso do NSGA-II requer o projeto offline em ambiente computacional.

Como consequência, tem-se no NSGA-II uma ferramenta de projeto dos fatores de ponderação do MPTC, área aberta a avanços, tornando-o uma ferramenta ainda mais flexível para o controle e acionamento do motor de indução. O trabalho desenvolvido sobressai-se por incorporar no projeto vários fatores ao mesmo tempo, inclusive aquele advindo da minimização de frequência de chaveamento. Ressalta-se que a mesma abordagem pode ser empregada quando outras restrições são adicionadas ao MPTC, bem como a qualquer técnica de FS-MPC aplicada a outras plantas.

7.2 Diretivas de Trabalhos Futuros

O estudo do controle preditivo aplicado ao motor de indução possibilita diversas linhas de pesquisa. Para continuação deste trabalho, citam-se, quanto ao desenvolvimento do MPTC:

a) Adicionar outras restrições à função custo do MPTC;

b) Incorporar o termo de minimização de frequência de chaveamento ao MRMPTC;

c) Incorporar ao MPTC estratégias de enfraquecimento de campo visando eficiência energética do motor;

d) Investigar sobre técnicas de ajuste *online* dos fatores de ponderação, incorporando conceitos dos AGs, de modo a que os fatores variem de acordo com o ponto de operação do motor;

e) Investigar sensibilidade do MPTC à variações paramétricas do modelo, principalmente a resistência de estator, implementado técnicas de estimação *online*;

Quanto ao processo de otimização dos fatores de ponderação, citam-se:

a) Considerar outras combinações de índices para otimização pelo NSGA-II para o MPTC desenvolvido, como o THD da corrente;

b) Verificar a influência do valor dos parâmetros de seleção cruzamento e mutação, bem como o tamanho da população, na convergência do NSGA-II;

c) Considerar outros AGMs, como o NSGA-III, na resolução do problema, bem como outras técnicas multiobjetivo inteligentes;

Referências

BARBI, I. **Teoria Fundamental do Motor de Indução**. Florianópolis: UFSC, 1985. 225 p.

BAZZO, W. A.; PEREIRA, L. T. d. V. **Introdução à Engenharia: Conceitos, Ferramentas e Comportamentos**. 2. ed. Florianópolis: Editora da UFSC, 2009. 270 p. ISBN 978-85.328.0455-6.

BLASCHKE, F. A new method for the structural decoupling of ac induction machines. In: **Conference Record IFAC**. Dusseldorf, Germany: [s.n.], 1971. p. 1–15. ISBN 0-8058-0426-9.

CASADEI, D.; PROFUMO, F.; TANI, A. FOC and DTC: two viable schemes for induction motors torque control. **IEEE Transactions on Power Electronics**, 2002. v. 17, n. 5, p. 779–787, sep 2002. ISSN 0885-8993.

CENSOR, Y. Pareto optimality in multiobjective problems. **Applied Mathematics & Optimization**, 1977. v. 4, n. 1, p. 41–59, mar 1977. ISSN 0095-4616.

CORTES, P.; KOURO, S.; La Rocca, B.; VARGAS, R.; RODRIGUEZ, J.; LEON, J. I.; VAZQUEZ, S.; FRANQUELO, L. G. Guidelines for weighting factors design in Model Predictive Control of power converters and drives. In: **2009 IEEE International Conference on Industrial Technology**. [S.l.]: IEEE, 2009. p. 1–7. ISBN 978-1-4244-3506-7.

DAVARI, S. A. Predictive Direct Angle Control of Induction Motor. **IEEE Transactions on Industrial Electronics**, 2016. v. 63, n. 8, p. 1–1, 2016. ISSN 0278-0046.

DAVARI, S. A.; KHABURI, D. A.; KENNEL, R. An Improved FCS-MPC Algorithm for an Induction Motor With an Imposed Optimized Weighting Factor. **IEEE Transactions on Power Electronics**, 2012. v. 27, n. 3, p. 1540–1551, mar 2012. ISSN 0885-8993.

DEB, K. **Multi-Objective Optimization Using Evolutionary Algorithms**. New York, NY, USA: John Wiley & Sons, Inc., 2001. ISBN 047187339X.

DEB, K.; GOEL, T. Controlled Elitist Non-dominated Sorting Genetic Algorithms for Better Convergence. In: **Lectures Notes in Computer Science**. [S.l.: s.n.], 2001. v. 1993, p. 67–81. ISBN 978-3-540-41745-3.

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE Transactions on Evolutionary Computation**, 2002. v. 6, n. 2, p. 182–197, apr 2002. ISSN 1089778X.

FORBES, M. G.; PATWARDHAN, R. S.; HAMADAH, H.; GOPALUNI, R. B. Model Predictive Control in Industry: Challenges and Opportunities. **IFAC-PapersOnLine**, 2015. Elsevier Ltd., v. 48, n. 8, p. 531–538, 2015. ISSN 24058963.

GEYER, T.; PAPAFOTIOU, G.; MORARI, M. Model Predictive Direct Torque Control - Part I: Concept, Algorithm, and Analysis. **IEEE Transactions on Industrial Electronics**, 2009. v. 56, n. 6, p. 1894–1905, jun 2009. ISSN 0278-0046.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.

HABIBULLAH, M.; LU, D. D.-C.; XIAO, D.; RAHMAN, M. F. Finite-State Predictive Torque Control of Induction Motor Supplied From a Three-Level NPC Voltage Source Inverter. **IEEE Transactions on Power Electronics**, 2017. v. 32, n. 1, p. 479–489, jan 2017. ISSN 0885-8993.

KAMPISIOS, K.; ZANCHETTA, P.; GERADA, C.; TRENTIN, A.; JASIM, O. Induction Motor parameters identification using Genetic Algorithms for varying flux levels. **Power Electronics and Motion Control Conference, 2008. EPE-PEMC 2008. 13th**, 2008. p. 887 – 892, 2008.

KENNEL, R.; LINDER, A. Predictive control of inverter supplied electrical drives. In: **2000 IEEE 31st Annual Power Electronics Specialists Conference. Conference Proceedings (Cat. No.00CH37018)**. [S.l.]: IEEE, 2000. v. 2, n. c, p. 761–766. ISBN 0-7803-5692-6. ISSN 1098-6596.

KOURO, S.; CORTES, P.; VARGAS, R.; AMMANN, U.; RODRIGUEZ, J. Model Predictive Control - A Simple and Powerful Method to Control Power Converters. **IEEE Transactions on Industrial Electronics**, 2009. v. 56, n. 6, p. 1826–1838, jun 2009. ISSN 0278-0046.

KUMAR, A.; SAXENA, R.; KUMAR, A. A comparative study of the various genetic approaches to solve multi-objective optimization problems. In: **2014 International Conference on Issues and Challenges in Intelligent Computing Techniques (ICICT)**. [S.l.]: IEEE, 2014. p. 109–112. ISBN 978-1-4799-2900-9. ISSN 0003-990X.

LASCU, C.; ANDREESCU, G.-D. Sliding-mode observer and improved integrator with DC-offset compensation for flux estimation in sensorless-controlled induction motors. **IEEE Transactions on Industrial Electronics**, 2006. v. 53, n. 3, p. 785–794, jun 2006. ISSN 0278-0046.

LEUER, M.; BOCKER, J. Self-optimizing Model Predictive Direct Torque Control for electrical drives. In: **2015 IEEE 24th International Symposium on Industrial Electronics (ISIE)**. [S.l.]: IEEE, 2015. p. 1046–1051. ISBN 978-1-4673-7554-2.

MAHMOUDI, H.; ALEENEJAD, M.; MOAMAEI, P.; AHMADI, R. Fuzzy adjustment of weighting factor in model predictive control of permanent magnet synchronous

machines using current membership functions. In: **2016 IEEE Power and Energy Conference at Illinois (PECI)**. [S.l.]: IEEE, 2016. p. 1–5. ISBN 978-1-5090-0261-0.

MARTÍNEZ, M.; SENENT, J. S.; BLASCO, X. Generalized predictive control using genetic algorithms (GAGPC). **Engineering Applications of Artificial Intelligence**, 1998. v. 11, n. 3, p. 355–367, jun 1998. ISSN 09521976.

MARTINS, C.; CARVALHO, A.; ROBOAM, X.; MEYNARD, T. Evolution of induction motor control methods and related voltage-source inverter topologies. In: **AMC'98 - Coimbra. 1998 5th International Workshop on Advanced Motion Control. Proceedings (Cat. No.98TH8354)**. [S.l.]: IEEE, 1998. p. 15–20. ISBN 0-7803-4484-7.

MC NAMARA, P.; NEGENBORN, R. R.; De Schutter, B.; LIGHTBODY, G. Weight optimisation for iterative distributed model predictive control applied to power networks. **Engineering Applications of Artificial Intelligence**, 2013. Elsevier, v. 26, n. 1, p. 532–543, jan 2013. ISSN 09521976.

MUDDINENI, V. P.; BONALA, A. K.; SANDEPUDI, S. R. Enhanced weighting factor selection for predictive torque control of induction motor drive based on VIKOR method. **IET Electric Power Applications**, 2016. v. 10, n. 9, p. 877–888, nov 2016. ISSN 1751-8660.

PEREIRA, W. C. A. **Controle de velocidade sensorless aplicado ao controle direto de torque da máquina de indução**. 2014. 106 p. Dissertação (Mestrado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

RODRIGUEZ, J.; CORTES, P. **Predictive Control of Power Converters and Electrical Drives**. 1st. ed. [S.l.]: John Wiley & Sons, 2012. 230 p. ISBN 9781119963981.

RODRIGUEZ, J.; KAZMIERKOWSKI, M. P.; ESPINOZA, J. R.; ZANCHETTA, P.; ABU-RUB, H.; YOUNG, H. A.; ROJAS, C. A. State of the Art of Finite Control Set Model Predictive Control in Power Electronics. **IEEE Transactions on Industrial Informatics**, 2013. v. 9, n. 2, p. 1003–1016, may 2013. ISSN 1551-3203.

RODRIGUEZ, J.; KENNEL, R. M.; ESPINOZA, J. R.; TRINCADO, M.; SILVA, C. A.; ROJAS, C. A. High-Performance Control Strategies for Electrical Drives: An Experimental Assessment. **IEEE Transactions on Industrial Electronics**, 2012. v. 59, n. 2, p. 812–820, feb 2012. ISSN 0278-0046.

ROJAS, C. A.; KOURO, S.; PEREZ, M.; VILLARROEL, F. Multiobjective Fuzzy Predictive Torque Control of an induction machine fed by a 3L-NPC inverter. In: **2015 IEEE International Symposium on Predictive Control of Electrical Drives and Power Electronics (PRECEDE)**. [S.l.]: IEEE, 2015. p. 21–26. ISBN 978-1-5090-1717-1.

ROJAS, C. A.; RODRIGUEZ, J.; VILLARROEL, F.; ESPINOZA, J. R.; SILVA, C. A.; TRINCADO, M. Predictive Torque and Flux Control Without Weighting Factors. **IEEE Transactions on Industrial Electronics**, 2013. v. 60, n. 2, p. 681–690, feb 2013. ISSN 0278-0046.

SCHAFFER, J. D. Multiple objective optimization with vector evaluated genetic algorithms. In: **Proceedings of the 1st International Conference on Genetic Algorithms**. Hillsdale, NJ, USA: L. Erlbaum Associates Inc., 1985. p. 93–100. ISBN 0-8058-0426-9. Disponível em: <http://dl.acm.org/citation.cfm?id=645511.657079>.

SRINIVAS, N.; DEB, K. Muiltiobjective optimization using nondominated sorting in genetic algorithms. **Evolutionary Computation**, 1994. v. 2, n. 3, p. 221–248, Sept 1994. ISSN 1063-6560.

SU, T.-J.; TSOU, T.-Y.; WANG, S.-M.; LI, T.-Y.; VU, H.-Q. Torque ripple reduction of induction motor based on a hybrid method of model predictive torque control and particle swarm optimization. **Advances in Mechanical Engineering**, 2016. v. 8, n. 10, p. 1–13, oct 2016. ISSN 1687-8140.

TAKAHASHI, I.; OHMORI, Y. High-performance direct torque control of an induction motor. **IEEE Transactions on Industry Applications**, 1989. v. 25, n. 2, p. 257–264, 1989. ISSN 00939994.

THE MATHWORKS INC. **Global Optimization Toolbox User's Guide R 2016a**. [S.l.], 2016.

TRZYNADLOWSKI, A. **Control of Induction Motors**. [S.l.]: Academic Press, 2001.

UMANS, S. D. **Máquinas Elétricas de Fitzgerald e Kingsley**. 7. ed. Porto Alegre: AMGH, 2014. 708 p. ISBN 978-85-8055-373-4.

VAS, P. **Vector control of AC machines**. [S.l.]: Clarendon Press, 1990. 332 p. (Monographs in electrical and electronic engineering). ISBN 9780198593706.

WANG, F.; CHEN, Z.; STOLZE, P.; STUMPER, J.-F.; RODRIGUEZ, J.; KENNEL, R. Encoderless Finite-State Predictive Torque Control for Induction Machine With a Compensated MRAS. **IEEE Transactions on Industrial Informatics**, 2014. v. 10, n. 2, p. 1097–1106, may 2014. ISSN 1551-3203.

WANG, F.; LI, S.; MEI, X.; XIE, W.; RODRIGUEZ, J.; KENNEL, R. M. Model-Based Predictive Direct Control Strategies for Electrical Drives: An Experimental Evaluation of PTC and PCC Methods. **IEEE Transactions on Industrial Informatics**, 2015. v. 11, n. 3, p. 671–681, jun 2015. ISSN 1551-3203.

WANG, L.; NG, A. H. C.; DEB, K. **Multi-objective Evolutionary Optimisation for Product Design and Manufacturing**. London: Springer London, 2011. 505 p. ISBN 978-0-85729-617-7.

WEATHERFORD, H. H.; BRICE, C. W. Estimation of induction motor parameters by a genetic algorithm. **Pulp and Paper Industry Technical Conference, 2003. Conference Record of the 2003 Annual**, 2003. p. 21–28, 2003.

YONGCHANG, Z.; ZHENGMING, Z. Speed sensorless control for three-level inverter-fed induction motors using an Extended Luenberger Observer. In: **2008 IEEE Vehicle Power and Propulsion Conference**. [S.l.]: IEEE, 2008. p. 1–5. ISBN 978-1-4244-1848-0.

ZANCHETTA, P. Heuristic multi-objective optimization for cost function weights selection in finite states model predictive control. In: **2011 Workshop on Predictive Control of Electrical Drives and Power Electronics**. [S.l.]: IEEE, 2011. p. 70–75. ISBN 978-1-4577-1912-7.

ZELECHOWSKY, M. **Space Vector Modulated – Direct Torque Controlled (DTC – SVM) Inverter Fed – Induction Motor Drive**. 2005. 175 p. Ph.D. Thesis (Ph.D. in Electrical Engineering — Institue of Control and Industrial Electronics, Warsaw University of Technology, Warsaw, Poland, 2005.

ZHANG, Y.; YANG, H. Model Predictive Torque Control of Induction Motor Drives With Optimal Duty Cycle Control. **IEEE Transactions on Power Electronics**, 2014. v. 29, n. 12, p. 6593–6603, dec 2014. ISSN 0885-8993.

_____. Model-Predictive Flux Control of Induction Motor Drives With Switching Instant Optimization. **IEEE Transactions on Energy Conversion**, 2015. v. 30, n. 3, p. 1113–1122, sep 2015. ISSN 0885-8969.

_____. Two-Vector-Based Model Predictive Torque Control Without Weighting Factors for Induction Motor Drives. **IEEE Transactions on Power Electronics**, 2016. v. 31, n. 2, p. 1381–1390, feb 2016.

ZHANG, Y.; ZHU, J.; ZHAO, Z.; XU, W.; DORRELL, D. G. An Improved Direct Torque Control for Three-Level Inverter-Fed Induction Motor Sensorless Drive. **IEEE Transactions on Power Electronics**, 2012. v. 27, n. 3, p. 1502–1513, mar 2012. ISSN 0885-8993.

ZITZLER, E.; DEB, K.; THIELE, L. Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. **Evolutionary Computation**, 2000. v. 8, n. 2, p. 173–195, jun 2000. ISSN 1063-6560.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach. **IEEE Transactions on Evolutionary Computation**, 1999. v. 3, n. 4, p. 257–271, 1999. ISSN 1089778X.

Apêndices

APÊNDICE **A**

Soluções Otimizadas do NSGA-II

A otimização de torque e fluxo realizada pelo NSGA-II resultou nas soluções mostradas na Tabela 12. A solução C, utilizada nos testes de validação, está destacada em negrito. Pode-se ver que o parâmetro T_{band} variou de 0,1094 a 0,1356 Nm, κ_2 de 7,3140 a 9,9007, e λ_3 de 0,0007 a 0,0109. Também são mostrados os valores do fenótipo da fronteira de Pareto, relativos à simulação de regime permanente de 1000 rpm com carga de 1,5 Nm.

Tabela 12: Parâmetros das soluções do NSGA-II obtidos para a otimização de oscilação de torque e de fluxo, e respectivos valores das funções objetivo.

Parâmetros das Soluções			Funções Objetivo	
T_{band}	κ_2	λ_3	T_{rip} (Nm)	Ψ_{rip} (Wb)
0,1281	**8,7750**	**0,0007**	0,2763	0,0137
0,1353	9,5185	0,0013	0,2826	0,0131
0,1356	9,9007	0,0011	0,3066	0,0100
0,1198	8,9745	0,0026	0,2665	0,0150
0,1329	7,3140	0,0017	0,2868	0,0122
0,1094	6,9386	0,0109	0,2542	0,0169
0,1189	7,5519	0,0021	0,2705	0,0141
0,1200	8,9727	0,0023	0,2609	0,0151
0,1338	7,4248	0,0015	0,2989	0,0101
0,1356	9,9000	0,0011	0,3066	0,0100
0,1281	8,7723	0,0007	0,2763	0,0137
0,1094	6,9386	0,0109	0,2542	0,0169
0,1094	8,2875	0,0015	0,2563	0,0161
0,1189	7,5501	0,0021	0,2705	0,0141
0,1207	9,4257	0,0019	0,2592	0,0151
0,1354	9,4292	0,0013	0,2891	0,0103
0,1353	9,5184	0,0013	0,2826	0,0131
0,1352	9,3042	0,0009	0,2926	0,0101

A segunda otimização realizada pelo NSGA-II, visando minimizar as oscilações de otimização de torque e de fluxo e também a frequência de chaveamento por sua vez

resultou nas soluções mostradas na Tabela 13, junto aos valores do fenótipo da fronteira de Pareto, relativos à simulação de regime permanente de 1000 rpm com carga de 1,5 Nm. As soluções D1, D2 e D3, utilizadas nos testes de validação, estão destacadas em negrito. O parâmetro T_{band} variou de 0,1044 a 0,2942 Nm, enquanto que κ_2 variou de 2,5016 a 15,0911, e λ_3 de 0,0074 a 0,0342.

Tabela 13: Parâmetros das soluções do NSGA-II para a otimização de oscilação de torque, de fluxo e frequência de chaveamento, e respectivos valores das funções objetivo.

Parâmetros das Soluções			Funções Objetivo		
T_{band}	κ_2	λ_3	T_{rip} (Nm)	Ψ_{rip} (Wb)	$\overline{f_c}$ (kHz)
0,1044	**3,8940**	**0,0219**	0,2654	0,0234	5,0444
0,2352	**15,0911**	**0,0081**	0,5932	0,0106	5,3511
0,2829	**2,5016**	**0,0279**	0,6951	0,0334	2,5200
0,1836	14,8376	0,0074	0,4736	0,0125	5,5333
0,1412	8,1583	0,0265	0,4015	0,0193	4,4800
0,1774	13,5748	0,0175	0,4601	0,0150	4,7222
0,2942	5,9888	0,0276	0,7274	0,0186	2,9956
0,2741	2,7884	0,0286	0,6685	0,0403	2,6911
0,2253	5,4648	0,0111	0,5542	0,0143	4,0622
0,1832	10,3628	0,0080	0,4663	0,0128	5,2311
0,2521	10,5713	0,0323	0,6167	0,0158	3,3600
0,1572	7,4910	0,0327	0,4362	0,0220	4,1867
0,2298	6,9328	0,0196	0,5746	0,0158	3,6911
0,2203	3,4393	0,0342	0,6254	0,0312	3,0667
0,2657	2,7972	0,0290	0,6476	0,0499	2,7378
0,2938	3,0534	0,0302	0,7154	0,0312	2,7467
0,1100	4,0613	0,0248	0,2982	0,0241	4,8244
0,2942	5,9888	0,0198	0,7748	0,0161	3,2333