

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS CORNÉLIO PROCÓPIO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HELOISA OLIVEIRA DOS SANTOS

**OTIMIZAÇÃO DO FILTRO DE KALMAN ESTENDIDO APLICADO NA
ESTIMAÇÃO DE VELOCIDADE DE UM MOTOR DE INDUÇÃO TRIFÁSICO**

DISSERTAÇÃO

**CORNÉLIO PROCÓPIO
2024**

HELOISA OLIVEIRA DOS SANTOS

**OTIMIZAÇÃO DO FILTRO DE KALMAN ESTENDIDO APLICADO NA
ESTIMAÇÃO DE VELOCIDADE DE MOTOR DE INDUÇÃO TRIFÁSICO**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Engenharia Elétrica” – Área de Concentração: Acionamentos Eletroeletrônicos.

Orientador: Prof. Dr. Marcelo Favoretto Castoldi.
Coorientador: Prof. Dr. Alessandro Goedtel.

**CORNÉLIO PROCÓPIO
2024**



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio



HELOISA OLIVEIRA DOS SANTOS

OTIMIZAÇÃO DO FILTRO DE KALMAN ESTENDIDO APLICADO NA ESTIMAÇÃO DE VELOCIDADE DE UM MOTOR DE INDUÇÃO TRIFÁSICO

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas Eletrônicos Industriais.

Data de aprovação: 27 de Novembro de 2023

Dr. Marcelo Favoretto Castoldi, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Cristiano Marcos Agulhari, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Samuel Lourenco Nogueira, Doutorado - Universidade Federal de São Carlos (Ufscar)

Dr. Wesley Angelino De Souza, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 27/11/2023.

Dedico este trabalho à memória de minha avó Maria do Carmo, que foi uma mãe para mim do meu nascimento até a sua partida.

AGRADECIMENTOS

Agradeço aos meus pais Anailde e William, ao meu avô Ubirajara, à minha irmã Jéssica e a todos os meus familiares por acreditarem em meu potencial.

Ao meu companheiro Rodrigo Dalarmi que me acompanhou durante esta jornada e acreditou em meu potencial mesmo quando eu não acreditava.

Agradeço também à minha amiga Jacqueline, que sempre acreditou em mim e me apoiou em todos os âmbitos da minha vida.

Agradeço ao meu orientador Prof. Dr. Marcelo Favoretto Castoldi, que sempre se mostrou disposto a ajudar e que nos momentos difíceis trouxe uma palavra de conforto e uma luz ainda não vista.

A todos os meus amigos do Laboratório de Sistemas Inteligentes (LSI), que desde o primeiro instante me acolheram e se tornaram minha família em Cornélio Procópio.

Por fim, mas não menos importante, a Deus, que sempre me guiou para alcançar tudo o que almejei.

“O impossível é uma questão de opinião.”
(Alexandre Magno Abrão)

RESUMO

SANTOS, Heloisa Oliveira dos. **Otimização do Filtro de Kalman Estendido aplicado na estimação de velocidade de Motor de Indução Trifásico**. 2024. 102f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2024.

Este trabalho consiste no estudo da estimação de velocidade de um Motor de Indução Trifásico (MIT), pois a informação desta grandeza é de extrema importância para a aplicação de metodologias de controle de velocidade. Uma das formas de estimar esta grandeza é utilizar o filtro de Kalman estendido. Contudo, o desempenho do filtro de Kalman estendido depende diretamente da sintonização das suas matrizes de covariância e de predição, sendo estas tradicionalmente determinadas por procedimentos de tentativa e erro. Frente a isto, o presente trabalho propõe a determinação dos valores destas matrizes por meio de algoritmos de otimização baseados na seleção natural e no comportamento social de populações. O sucesso deste feito permite que uma técnica de estimação de velocidade substitua os medidores de velocidade nas metodologias de controle do MIT, aumentando a vantagem econômica do acionamento. Para isto, toda a estrutura do motor, do filtro e dos algoritmos de otimização foram implementadas e validadas no *software* MATLAB®.

Palavras-chave: Motor de Indução Trifásico. *Sensorless*. Estimação de Velocidade. Filtro de Kalman Estendido. Algoritmos de Otimização.

ABSTRACT

SANTOS, Heloisa Oliveira dos. **Otimização do Filtro de Kalman Estendido aplicado na estimação de velocidade de Motor de Indução Trifásico**. 2024. 102f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2024.

This work consists in the study of the velocity estimation of a three-phase induction motor, because the information of this magnitude is extremely important for both the drive and the application of control methodologies. One way to estimate this speed is use the extended Kalman filter. However, the performance of the extended Kalman filter depends directly on the tuning of its covariance and prediction matrices, and these are traditionally determined by trial and error procedures. The aim of this work is to determine the values of these matrices by means of an optimization algorithm based on natural selection and social behavior of the population. The success allows the sensorless to replace the encoder in the control methodologies, increasing the economic advantage of the three-phase induction motor. For this, the entire structure of the motor, the sensorless and the optimization algorithm, besides the computational simulations were realized in the software MATLAB®.

Keywords: Three-phase Induction Motor, Sensorless, Speed Estimation, Extended Kalman Filter, Optimization Algorithms.

LISTA DE FIGURAS

Figura 1 – Representação do sistema de coordenadas. (a) Trifásico (a, b, c). (b) Bifásico (α , β).	23
Figura 2 – Composição do dispositivo eletrônico utilizado para a variação de frequência.....	28
Figura 3 – Controle escalar em malha aberta.	30
Figura 4 – Controle escalar em malha fechada.	30
Figura 5 - Estrutura do Filtro de Kalman Estendido.....	35
Figura 6 - Processo de cruzamento da ED.	40
Figura 7 - Sistema elaborado para a implementação do otimizador em alimentação senoidal.....	49
Figura 8 – Sistema elaborado para a implementação do otimizador em alimentação não senoidal malha aberta	50
Figura 9 – Sistema elaborado para a implementação do otimizador em alimentação não senoidal malha fechada.....	51
Figura 10 - Arranjo do princípio de funcionamento para a etapa de otimização.....	54
Figura 11 – Arranjo do princípio de funcionamento para a etapa de validação.....	55
Figura 12 – Evolução do <i>fitness</i> dos otimizadores – alimentação senoidal.....	57
Figura 13 – <i>Boxplot</i> dos <i>fitness</i> dos algoritmos otimizadores – Execuções da etapa de otimização.	58
Figura 14 – Teste de otimização com alimentação senoidal.....	59
Figura 15 – 1º teste da fase de validação com alimentação senoidal, sem alteração de resistências e sem ruído.	61
Figura 16 - 1º teste da fase de validação com alimentação senoidal, sem alteração de resistências e com ruído.	62
Figura 17 - 2º teste da fase de validação com alimentação senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído.	62
Figura 18 - 2º teste da fase de validação com alimentação senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído.	63
Figura 19 - Evolução do <i>fit</i> dos otimizadores – malha aberta.....	64
Figura 20 - <i>Boxplot</i> dos <i>fitness</i> dos algoritmos otimizadores – Execuções da etapa de otimização em malha aberta.	65
Figura 21 - Teste de otimização com alimentação não senoidal – malha aberta.....	66

Figura 22 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha aberta.	69
Figura 23 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha aberta.	69
Figura 24 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha aberta.	70
Figura 25 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha aberta.	70
Figura 26 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha aberta.	71
Figura 27 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha aberta.	71
Figura 28 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha aberta.	72
Figura 29 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha aberta.	72
Figura 30 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha aberta.	73
Figura 31 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha aberta.	73
Figura 32 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha aberta.	74
Figura 33 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha aberta.	74
Figura 34 - Evolução do <i>fit</i> dos otimizadores – malha fechada.	76
Figura 35 - <i>Boxplot</i> dos <i>fitness</i> dos algoritmos otimizadores – Execuções da etapa de otimização em malha fechada.	76
Figura 36 - Teste de otimização com alimentação não senoidal – malha fechada. ..	78
Figura 37 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha fechada. .	81
Figura 38 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha fechada.	81

Figura 39 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha fechada. .	82
Figura 40 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha fechada.	82
Figura 41 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha fechada.	83
Figura 42 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha fechada.	83
Figura 43 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha fechada.	84
Figura 44 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha fechada.	84
Figura 45 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha fechada. .	85
Figura 46 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha fechada.	85
Figura 47 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha fechada. .	86
Figura 48 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha fechada.	86
Figura 49 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha fechada.	87
Figura 50 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha fechada.	87
Figura 51 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha fechada.	88
Figura 52 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha fechada.	88

Figura 53 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha fechada.	89
Figura 54 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha fechada.	89
Figura 55 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha fechada.	90
Figura 56 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha fechada.	90
Figura 57 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha fechada.	91
Figura 58 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha fechada.	91
Figura 59 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha fechada.	92
Figura 60 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha fechada.	92

LISTA DE TABELAS

Tabela 1 - Parâmetros do motor utilizado.	47
Tabela 2 - Espaço de busca utilizado para os algoritmos de otimização.	52
Tabela 3 – Ajuste paramétrico dos algoritmos de otimização.	53
Tabela 4 – Melhor <i>fitness</i> dos algoritmos otimizadores em alimentação senoidal– Execuções da etapa de otimização.	59
Tabela 5 – Parâmetros obtidos por meio dos otimizadores para o melhor <i>fitness</i> – alimentação senoidal.	60
Tabela 6 – <i>Fitness</i> dos algoritmos de otimização para os testes de validação – alimentação senoidal.	60
Tabela 7 – Melhor <i>fitness</i> dos algoritmos otimizadores – Execuções da etapa de otimização em malha aberta.	66
Tabela 8 – Parâmetros obtidos por meio dos otimizadores para o melhor <i>fitness</i>	67
Tabela 9 – <i>Fitness</i> dos algoritmos de otimização para os testes de validação em malha aberta.	68
Tabela 10 – Melhor <i>fitness</i> dos algoritmos otimizadores – Execuções da etapa de otimização em malha fechada.	77
Tabela 11 – Parâmetros obtidos por meio dos otimizadores para o melhor <i>fitness</i> – malha fechada.	78
Tabela 12 – <i>Fitness</i> dos algoritmos de otimização para os testes de validação em malha fechada.	79

SUMÁRIO

1 INTRODUÇÃO	13
1.1 PROBLEMA	17
1.2 OBJETIVOS	17
1.2.1 Objetivo geral	17
1.2.2 Objetivos específicos.....	17
1.3 JUSTIFICATIVA	18
1.4 DISPOSIÇÃO DO TRABALHO	19
2 MOTOR DE INDUÇÃO TRIFÁSICO	20
2.1 EQUACIONAMENTO DO MOTOR DE INDUÇÃO TRIFÁSICO	20
2.2 ACIONAMENTO E CONTROLE DO MOTOR DE INDUÇÃO TRIFÁSICO	26
3 FILTRO DE KALMAN ESTENDIDO	31
4 ALGORITMOS DE OTIMIZAÇÃO	38
4.1 EVOLUÇÃO DIFERENCIAL.....	38
4.2 ENXAME DE PARTÍCULAS.....	41
4.3 ENXAME DE VAGALUMES.....	42
4.4 LOBOS CINZENTOS	44
5 METODOLOGIA	47
6 RESULTADOS.....	56
6.1 ALIMENTAÇÃO SENOIDAL.....	56
6.2 ALIMENTAÇÃO NÃO SENOIDAL COM CONTROLE EM MALHA ABERTA.....	63
6.3 ALIMENTAÇÃO NÃO SENOIDAL COM CONTROLE EM MALHA FECHADA...	75
7 CONCLUSÃO	94

1 INTRODUÇÃO

O maior consumidor de energia elétrica do Brasil é o setor industrial, utilizando sozinho 36,6% de toda a eletricidade gerada (BEN, 2021). Grande parte deste consumo ocorre para que bombas, ventiladores, transportadores e roscas sejam movimentados, os quais, em sua maioria, são acionados por meio de motores elétricos. Estima-se que 68% do consumo industrial seja para alimentar tais máquinas elétricas e que deste montante, 90% são destinados para motores de indução do tipo gaiola de esquilo (SOUZA et al., 2022).

Devido à sua robustez e fácil manutenção, o Motor de Indução Trifásico (MIT) se tornou a principal máquina elétrica empregada no setor industrial (KOSOW, 2005). Sua aplicação pode depender ou não do controle de velocidade adequado, porém o ajuste de velocidade pode permitir que o ritmo de produção industrial varie. Além disso, permite que a máquina elétrica opere em baixa rotação, podendo evitar paradas e partidas sucessivas do motor, o que pode preservar a integridade e confiabilidade de tal equipamento, de acordo com o regime de partida (WEG, 2021).

Atualmente há duas grandes categorias de metodologias aplicadas ao controle de velocidade de motores elétricos, sendo escalar ou vetorial. Entretanto, para a aplicação adequada de ambas as metodologias é necessário que se tenha a informação da rotação do motor, tornando este parâmetro fundamental para o controle de velocidade (GOEDTEL, 2013).

Segundo Fitzgerald, Kingsley e Umans (2006), para o monitoramento da velocidade são aplicados dispositivos acoplados ao eixo da máquina girante, comumente conhecidos como *encoders*. Ainda, segundo Zhao et al. (2014), a utilização deste dispositivo acarreta custo adicional ao acionamento, além de em alguns casos ter a sua aplicação inviabilizada devido à carência de espaço para sua alocação, aplicação em ambientes industriais hostis ou, ainda, nas situações em que a máquina está posicionada distante do acionamento.

Frente a isso, foram desenvolvidas técnicas que estimam tal grandeza dispensando a necessidade de sua medição direta, sendo denominadas como técnicas *sensorless* (SANTOS, 2012). Contudo, ainda se vê restrições para a aplicação prática destas técnicas em baixas rotações (WEG, 2021).

Certas técnicas *sensorless* são provenientes da estimação de velocidade por meio da modelagem matemática da máquina em conjunto com as informações da medição de corrente e tensão do MIT (ZHAO et al., 2014). Dentre estas técnicas pode-se destacar a Rede Neural Artificial (RNA), o Sistema Adaptativo por Modelo de Referência (MRAS - do inglês, *Model Reference Adaptive System*) e observadores de estado como o Filtro de Kalman (KF – do inglês, *Kalman Filter*).

No trabalho de Goedel et al. (2013) a velocidade do motor de indução é estimada por meio de RNA, considerando problemas de qualidade de energia elétrica, como redução ou elevação da tensão nominal de alimentação da máquina. Já em Santos et al. (2012), a velocidade do motor foi estimada pela mesma técnica *sensorless*, sendo o MIT submetido a variações de velocidade e carga.

No artigo de Monadi et al. (2015), a velocidade do MIT é estimada por meio da MRAS, onde sua operação é avaliada sob falta e uma modificação no algoritmo é proposta para que tal condição seja levada em consideração na modelagem. Ainda, no trabalho de Smith, Gadoue e Finch (2016), a velocidade do motor de indução é estimada pela técnica Z-MRAS, onde é proposta uma nova formulação para a técnica tradicional com o intuito de aperfeiçoar o controle vetorial em baixas velocidades, onde os testes de validação contaram com inversão de fase e carga variável.

Em Laatra, Lotfi e Abdelhani (2017), dois observadores de estado são comparados quando aplicados na estimação de velocidade de um motor de indução. Os resultados obtidos pelo KF e Observador de Luenberger são validados por meio de análise experimental. Por fim, o KF apresentou melhor desempenho em razão de sua robustez frente aos ruídos provenientes dos medidores de tensão e corrente.

Em sua forma clássica, o Filtro de Kalman tem sua aplicação indicada para problemas lineares (MASCHIO, 2006). Contudo, segundo Vas (1998), para atuar em problemas que possuem não linearidades, utiliza-se da versão estendida da técnica, também conhecida como Filtro de Kalman Estendido (EKF – do inglês, *Extended Kalman Filter*). Por se tratar de uma técnica que mantém bom desempenho na sob problemas não lineares, este método se tornou muito utilizado dentro da teoria moderna de controle (SHI et al., 2002).

Em virtude de sua robustez a ruídos, é propícia a utilização do EKF para estimar a velocidade de MITs, tendo em vista que para a aplicação prática é necessária a utilização de sensores de corrente e tensão, os quais podem inserir ruídos e alterar o valor das grandezas medidas (SANTOS, 2020). Na implementação

do algoritmo EKF estes ruídos são representados por matrizes de covariância (VAS, 1998). Segundo Vas (1998), a inicialização de tais matrizes em conjunto com a matriz de predição influencia diretamente na estabilidade do filtro e em seu tempo de convergência. Vale ressaltar que determinar os valores ideais para inicializar estas matrizes ainda é um problema que está aberto à pesquisa (SANTOS et al., 2019).

Segundo Zerdali e Barut (2017), a sintonização destas matrizes é comumente feita por métodos empíricos baseados em tentativa e erro. Contudo, pode-se empregar métodos de otimização *offline* para que os valores destas matrizes sejam sintonizados, aprimorando o desempenho do EKF (SANTOS, 2020).

Comparado com os métodos tradicionais, os algoritmos baseados em comportamento populacional se destacam em problemas de otimização, devido à sua redução de complexidade e custo computacional (CAVALI, 2017). As metaheurísticas baseadas em comportamento populacional que possuem aplicação difundida em problemas de otimização são a Otimização por Exame de Partículas (PSO – do inglês, *Particle Swarm Optimization*), o Algoritmo Genético (GA – do inglês, *Genetic Algorithm*) e a Evolução Diferencial (DE – do inglês, *Differential Evolution*).

No trabalho de Rayyam e Zazi (2018), o EKF otimizado pela PSO foi aplicado na estimação de velocidade para o Controle de Campo Orientado Direto (DFOC - do inglês, *Direct Field Oriented Control*). O EKF com sintonização tradicional das matrizes de covariância e predição também foi utilizado como *sensorless* e o resultado foi comparado com o EKF otimizado.

Em She et al. (2020), o GA é utilizado para sintonizar as matrizes de covariância e de predição do EKF, quando aplicada na estimação de velocidade de um motor síncrono, confirmando que a robustez ao ruído independe da máquina acionada. Ainda, em Shi et al. (2002), a inicialização das matrizes de covariância e de predição do EKF foram determinadas por meio da técnica GA, que teve sua eficácia comprovada por meio de dados experimentais.

O artigo de Zerdali e Barut (2017), propõe que a inicialização das matrizes de covariância e de predição do EKF sejam estimadas por meio do DE. Entretanto, no estudo é realizada a comparação entre o EKF otimizado pelo DE e pela Evolução Diferencial Multiobjetivo (MODE - do inglês, *Mult-Objective Differential Evolution*), onde a função multiobjetivo conta com a combinação do erro de velocidade e de corrente da máquina.

No trabalho de Salvatore et al. (2010), a inicialização das matrizes de covariância e de predição do EKF como *sensorless* é feita pelo DE. Entretanto, os autores propuseram uma comparação com outras três metaheurísticas populares, sendo eles o Recozimento Simulado (SA – do inglês, *Simulated Annealing*), GA e PSO. Além disso, a função objetivo do trabalho contou com a somatória do erro médio de velocidade, da corrente quadratura e da corrente direta.

Entretanto, há novos métodos metaheurísticos baseados em comportamento populacional que estão se destacando quando o assunto é otimização sem uma boa solução para se iniciar o processo de iteração (TJAHJONO et al., 2017). Dentre estes, pode-se citar o Algoritmo Enxame de Vagalumes (FA – do inglês, *Firefly Algorithm*), o Algoritmo dos Fogos de Artifício (EFWA – do inglês, *Enhanced Fireworks Algorithm*) e o Algoritmo dos Lobos Cinzentos (GWO – do inglês, *Grey Wolf Optimizer*)

Em Santos (2020), as matrizes de covariância e predição do EKF são otimizadas por meio do FA. A técnica *sensorless* foi aplicada aos controles de velocidade escalar em malha fechada, onde os testes de validação contaram com operação em diferentes rotações, cargas e alterações das resistências rotóricas e estatóricas.

No artigo de Manson et al. (2018), é proposto que o EFWA seja aplicado para otimizar as matrizes de covariância e predição do EKF na estimação de velocidade com controle em malha fechada. Ainda, neste trabalho foi realizada a comparação entre as respostas obtidas pelo EFWA e GA, considerando como função objetivo o erro médio da velocidade.

Em Pilla et al. (2021), o GWO é utilizado para estimar as matrizes de covariância do EKF na estimação de velocidade sem sensor de um motor síncrono de ímã permanente. Ainda, neste trabalho, os resultados são comparados com a aplicação da PSO para otimização de tais matrizes do EKF, onde o desempenho do GWO superou o do algoritmo de enxame de partículas.

Assim, o objetivo deste trabalho consiste na comparação do desempenho do EKF aplicado na estimação de velocidade do MIT, quando as matrizes de covariância e de predição são otimizadas por FA, PSO, DE e GWO. O empenho no aperfeiçoamento das técnicas de estimação de velocidade do MIT visa possibilitar que os *encoders* possam ser substituídos por técnicas *sensorless*, aumentando a viabilidade econômica do acionamento e facilitando o controle de velocidade dos motores aplicados em ambientes hostis e dos posicionados distante do acionamento.

1.1 PROBLEMA

Para que se tenha eficiência no controle de velocidade do MIT é necessária a informação sobre a velocidade no eixo do rotor. Entretanto, os dispositivos comumente utilizados para esta função elevam o custo do acionamento, além de ser inaplicáveis em algumas situações devido à carência de espaço para sua alocação, aplicação em ambientes industriais hostis ou, ainda, nas situações em que a máquina está posicionada distante do acionamento.

Frente a isto, a técnica *sensorless* baseada no EKF é uma alternativa viável para as adversidades pontuadas. Entretanto, sua eficiência depende diretamente da sintonização das suas matrizes de covariância e de predição. Apesar disso, estas matrizes se bem ajustadas torna o EKF um método apto para aplicar-se no controle de velocidade. Assim, é interessante que métodos de otimização sejam aplicados na sintonização de tais matrizes.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Comparar o desempenho de algoritmos de otimização quando aplicados na sintonização das matrizes de covariância e de predição do estimador de velocidade baseado no Filtro de Kalman Estendido.

1.2.2 Objetivos específicos

- Realizar uma fundamentação teórica sobre a modelagem do motor de indução trifásico e do filtro de Kalman estendido;

- Modelar o motor de indução trifásico e posteriormente o filtro de Kalman estendido;
- Implementar algoritmos de otimização para otimizar as matrizes de covariância e de predição do filtro de Kalman estendido;
- Realizar simulações computacionais a partir da ferramenta Simulink/MATLAB para avaliar e comparar o desempenho do filtro de Kalman estendido otimizado;
- Avaliar o desempenho da otimização do filtro de Kalman estendido otimizado, quando submetido à variação de carga e resistências (rotor e estator);
- Avaliar o desempenho da otimização do filtro de Kalman estendido otimizado, quando submetido à alimentação senoidal e não senoidal.
- Analisar o desempenho dos algoritmos aplicados na sintonia do filtro de Kalman estendido.

1.3 JUSTIFICATIVA

Realizar a sintonização das matrizes de covariância e de predição do EKF ainda é um problema em aberto, pois a sintonização destas matrizes é tradicionalmente realizada por processos de tentativa e erro. Contudo, aplicar métodos de otimização *offline* para sintonização do EKF pode garantir o desempenho superior desta técnica *sensorless*, reduzindo também o tempo gasto com a sintonização tradicional.

Diferentes algoritmos de otimização podem ser aplicados na sintonização *offline* do EKF, porém, devem ser escolhidos de acordo com as características do problema. Por se tratar de um problema com inúmeras possíveis soluções, as metaheurísticas baseadas em população podem ter desempenho superior, pois possuem menor custo computacional em relação aos métodos matemáticos.

Com isto, o presente trabalho visa implementar e comparar a sintonização *offline* do EKF por meio de algoritmos. Inicialmente, quatro algoritmos bio-inspirados foram escolhidos para compor a primeira etapa de comparação, sendo eles o DE, a

PSO, o FA e o GWO. O DE é um método amplamente utilizado em problemas de otimização e baseia-se na teoria de evolução de Darwin, onde ocorre a seleção natural dos indivíduos mais fortes. Já a PSO é um método baseado no comportamento dos pássaros durante um voo de migração ou em busca de alimentos. Enquanto que, o FA é um algoritmo recentemente criado que se baseia no comportamento social dos vagalumes com a finalidade de parceiros e presas em potencial. Outro algoritmo recentemente desenvolvido foi o GWO, que se baseia na hierarquia de liderança e estratégia de caça dos lobos cinzentos.

1.4 DISPOSIÇÃO DO TRABALHO

Este trabalho está organizado da seguinte forma: no Capítulo 2 são abordados os conceitos do MIT, bem como os aspectos relacionados à sua modelagem dinâmica e ao controle escalar de velocidade. No Capítulo 3 é apresentada a modelagem matemática do EKF e os passos utilizados para a sua implementação. No Capítulo 4 os conceitos fundamentais dos algoritmos utilizados para a otimização do EKF são apresentados. No Capítulo 5 é apresentada a metodologia utilizada para otimização do EKF em alimentação senoidal e não senoidal. No Capítulo 6 são apresentados os resultados das otimizações e dos diferentes testes para validação. Por fim, no Capítulo 7 as conclusões são apresentadas.

2 MOTOR DE INDUÇÃO TRIFÁSICO

A implementação computacional do MIT é possível por meio da sua modelagem matemática. Esta modelagem descreve o comportamento da máquina por meio de equações matemáticas. Contudo, a modelagem exata que descreve este equipamento é um sistema complexo com diversas não linearidades. Tendo em vista esta complexidade, é necessário que algumas aproximações sejam consideradas para a implementação (KRAUSE et al., 2013).

Dentre estas considerações, podemos citar as quatro abaixo como sendo as mais importantes (KRISHNAN, 2001):

- O entreferro é de tamanho uniforme;
- Os enrolamentos do estator são idênticos;
- Os enrolamentos do estator e do rotor são igualmente defasados entre si;
- A saturação e mudança de parâmetros são negligenciadas.

Além disto, segundo Maschio (2006), quando se há interesse em analisar o acionamento e controle do motor, é necessário que as informações do transitório sejam consideradas no modelo. Com isso, se faz necessário a utilização das equações que descrevem o motor desde o regime transitório. Este conjunto de equações é denominado de modelagem dinâmica da máquina e através dela é possível observar as informações instantâneas de tensão, corrente, frequência do estator, velocidade e variações de torque (KRISHNAN, 2001).

2.1 EQUACIONAMENTO DO MOTOR DE INDUÇÃO TRIFÁSICO

Frente às considerações feitas, as equações que descrevem o comportamento dinâmico do MIT são exibidas de (1) a (2), onde os índices 1 e 2 referem-se aos parâmetros relacionados ao estator e ao rotor, respectivamente. Devido ao rotor ser do tipo gaiola de esquilo, os terminais do circuito rotórico são curto-circuitados internamente, ocasionando em tensão \underline{v}_2 nula;

$$\underline{v}_1 = R_1 \underline{i}_1 + \frac{d}{dt} \underline{\phi}_1 + \omega_\lambda \mathbf{K} \underline{\phi}_2 \quad (1)$$

$$\underline{v}_2 = R_2 \underline{i}_2 + \frac{d}{dt} \underline{\phi}_2 + \omega_2 \mathbf{K} \underline{\phi}_2 = 0 \quad (2)$$

$$\underline{\phi}_1 = L_1 \underline{i}_1 + L_H \underline{i}_2 \quad (3)$$

$$\underline{\phi}_2 = L_H \underline{i}_1 + L_2 \underline{i}_2 \quad (4)$$

$$m_d = -z_p \underline{\phi}_1^T \mathbf{K} \underline{i}_1 = z_p \underline{\phi}_2^T \mathbf{K} \underline{i}_2 \quad (5)$$

$$\frac{d}{dt} \omega_{mec} = \frac{1}{J} (m_d - K_D \omega_{mec} - m_l) \quad (6)$$

sendo:

$$\underline{v} = \begin{bmatrix} v_a \\ v_b \\ v_c \end{bmatrix}; \underline{i} = \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix}; \underline{\phi} = \begin{bmatrix} \phi_a \\ \phi_b \\ \phi_c \end{bmatrix} \quad (7)$$

$$\mathbf{K} = \frac{1}{\sqrt{3}} \begin{bmatrix} 0 & -1 & 1 \\ 1 & 0 & -1 \\ -1 & 1 & 0 \end{bmatrix} \quad (8)$$

$$\omega_2 = \omega_\lambda - Z_p \omega_{mec} \quad (9)$$

onde os coeficientes referem-se a:

- \underline{v}_1 e \underline{v}_2 Tensão trifásica relacionada ao estator e ao rotor, respectivamente;
- R_1 e R_2 Resistencia do estator e do rotor, respectivamente;
- \underline{i}_1 e \underline{i}_2 Corrente trifásica relacionada ao estator e ao rotor, respectivamente;
- $\underline{\phi}_1$ e $\underline{\phi}_2$ Fluxo de enlace do estator e do rotor, respectivamente;

ω_λ	Velocidade angular do referencial genérico;
L_1 e L_2	Indutância própria do estator e do rotor, respectivamente;
L_H	Indutância mútua entre os enrolamentos do estator e rotor;
m_d	Torque eletromagnético;
z_p	Número de pares de polos da máquina;
ω_{mec}	Velocidade do rotor;
J	Momento de inércia;
K_D	Coefficiente de atrito;
m_l	Carga imposta à máquina;

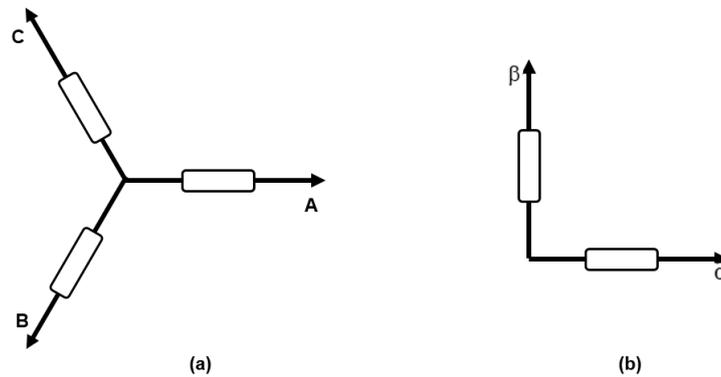
Tendo-se toda a modelagem dinâmica sido apresentada, é necessário que se defina o referencial adotado para o trabalho. Segundo Guedes (2016), usualmente este referencial é adotado na própria máquina, podendo ser no estator ou ainda no rotor. Sendo assim, para este trabalho, o referencial da máquina foi adotado como sendo o estator. Frente a isto, é possível que simplificações no equacionamento sejam realizadas devido ao deslocamento angular se tornar nulo, ou seja, $\omega_\lambda = 0$. Assim, as equações (1) e (2) são reescritas como:

$$\underline{v}_1 = R_1 \underline{i}_1 + \frac{d}{dt} \underline{\phi}_1 \quad (10)$$

$$0 = R_2 \underline{i}_2 + \frac{d}{dt} \underline{\phi}_2 - z_p \omega_{mec} \mathbf{K} \underline{\phi}_2 \quad (11)$$

Para facilitar a implementação da modelagem do MIT, pode-se aplicar ao sistema de coordenadas a transformada de Clarke, a qual altera o sistema de trifásico para bifásico. Como resultado da aplicação desta transformada temos que um sistema inicialmente trifásico com seus enrolamentos defasado em 120°, se torna bifásico com defasagem de 90°. A representação deste sistema é exibida na Figura 1.

Figura 1 – Representação do sistema de coordenadas. (a) Trifásico (a, b, c). (b) Bifásico (α , β).



Fonte: Adaptado de Castoldi (2006, p. 26).

Com a utilização deste novo sistema de coordenadas é necessário que as equações de corrente, tensão e fluxo descritas neste capítulo sejam reescritas. Sendo assim, a modelagem dinâmica da máquina passa a ser descrita por meio das equações (12), (13) e (14).

$$\bar{\mathbf{v}}_1 = R_1 \bar{\mathbf{i}}_1 + \frac{d}{dt} \bar{\boldsymbol{\phi}}_1 \quad (12)$$

$$0 = R_2 \bar{\mathbf{i}}_2 + \frac{d}{dt} \bar{\boldsymbol{\phi}}_2 + j(-z_p \omega_{mec}) \mathbf{K} \bar{\boldsymbol{\phi}}_2 \quad (13)$$

$$m_d = \frac{3}{2} z_p \text{Im} \left\{ \bar{\mathbf{i}}_1 \bar{\boldsymbol{\phi}}_1^* \right\} = -\frac{3}{2} z_p \text{Im} \left\{ \bar{\mathbf{i}}_2 \bar{\boldsymbol{\phi}}_2^* \right\} \quad (14)$$

onde:

$$\bar{\boldsymbol{\phi}}_1 = L_1 \bar{\mathbf{i}}_1 + L_H \bar{\mathbf{i}}_2 \quad (15)$$

$$\bar{\boldsymbol{\phi}}_2 = L_2 \bar{\mathbf{i}}_2 + L_H \bar{\mathbf{i}}_1 \quad (16)$$

Além disto, neste trabalho o MIT será descrito por meio do modelo de espaço de estado, possuindo como entrada o vetor de estado da tensão no estator e como saída o vetor de estado da corrente do estator e do fluxo do rotor. A modelagem por espaço de estados ocorre em função dos estados escolhidos e do modelo vetorial

descrito pelas equações (12) e (13), que com o auxílio das equações (15) e (16), permite que as equações (17) e (18) sejam escritas.

$$\begin{cases} \frac{d}{dt} i_{1\alpha} = \frac{1}{L_1 \sigma} v_{1\alpha} - \left(\frac{1}{T_1 \sigma} + \frac{1-\sigma}{T_2 \sigma} \right) i_{1\alpha} + \frac{L_H}{L_1 L_2 \sigma T_2} \phi_{2\alpha} - \omega_2 \frac{L_H}{L_1 L_2 \sigma} \phi_{2\beta} \\ \frac{d}{dt} i_{1\beta} = \frac{1}{L_1 \sigma} v_{1\beta} - \left(\frac{1}{T_1 \sigma} + \frac{1-\sigma}{T_2 \sigma} \right) i_{1\beta} + \frac{L_H}{L_1 L_2 \sigma T_2} \phi_{2\beta} - \omega_2 \frac{L_H}{L_1 L_2 \sigma} \phi_{2\alpha} \end{cases} \quad (17)$$

$$\begin{cases} \frac{d}{dt} \phi_{2\alpha} = -\frac{1}{T_2} \phi_{2\alpha} + \frac{L_H}{T_2} i_{1\alpha} + \omega_2 \phi_{2\beta} \\ \frac{d}{dt} \phi_{2\beta} = -\frac{1}{T_2} \phi_{2\beta} + \frac{L_H}{T_2} i_{1\beta} + \omega_2 \phi_{2\alpha} \end{cases} \quad (18)$$

onde:

$$\sigma = \left(1 - \frac{L_H^2}{L_1 L_2} \right) \quad (19)$$

$$T_1 = \frac{L_1}{R_1} \quad (20)$$

$$T_2 = \frac{L_2}{R_2} \quad (21)$$

Assim, a equação (14) em função das variáveis de estados desejadas passa a ser descrita como:

$$m_d = \frac{3}{2L_2} L_H z_p (\phi_{2\alpha} i_{1\beta} + \phi_{2\beta} i_{1\alpha}) \quad (22)$$

Com base na definição do referencial e dos vetores de estado, a equação de estado que descreve o modelo vetorial pode ser representada como:

$$\begin{cases} \frac{d}{dt} \mathbf{x} = \mathbf{Ax} + \mathbf{Bu} \\ \mathbf{y} = \mathbf{Cx} \end{cases} \quad (23)$$

onde:

$$\mathbf{x} = [i_{1\alpha} \quad i_{1\beta} \quad \phi_{2\alpha} \quad \phi_{2\beta}]^T \quad (24)$$

$$\mathbf{u} = [v_{1\alpha} \quad v_{1\beta}]^T \quad (25)$$

$$\mathbf{y} = [i_{1\alpha} \quad i_{1\beta}]^T \quad (26)$$

$$\mathbf{A} = \begin{bmatrix} -a & 0 & b & c\omega_{mec} \\ 0 & -a & -c\omega_{mec} & b \\ d & 0 & -e & -z_p\omega_{mec} \\ 0 & d & z_p\omega_{mec} & -e \end{bmatrix} \quad (27)$$

$$\mathbf{B} = \begin{bmatrix} g & 0 \\ 0 & g \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (28)$$

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (29)$$

em que os coeficientes das equações (27) e (28) são descritos entre as equações de (30) a (35).

$$a = \left(\frac{1}{T_1\sigma} + \frac{1-\sigma}{T_2\sigma} \right) \quad (30)$$

$$b = \frac{L_H}{L_1 L_2 \sigma T_2} \quad (31)$$

$$c = z_p \frac{L_H}{L_1 L_2 \sigma} \quad (32)$$

$$d = \frac{L_H}{T_2} \quad (33)$$

$$e = \frac{1}{T_2} \quad (34)$$

$$g = \frac{1}{L_1 \sigma} \quad (35)$$

2.2 ACIONAMENTO E CONTROLE DO MOTOR DE INDUÇÃO TRIFÁSICO

Compatível com a vasta aplicabilidade do MIT, os métodos empregados em seu acionamento também são variados, como partida direta, partida estrela-triângulo, *soft starter*, inversores de frequências entre outros.

Segundo WEG (2014), o método partida direta é a técnica mais simples empregada nos acionamentos de MIT. Contudo, esta técnica não permite que seja realizada a variação de velocidade do motor, uma vez que a máquina é conectada diretamente a uma fonte senoidal. Por sua vez, esta característica do acionamento limita a dinâmica dos processos industriais, além de exigir uma elevada corrente de partida, podendo chegar a 7 vezes o valor nominal da máquina. Para motores de elevadas potências, este valor de corrente durante a partida pode ocasionar em um afundamento brusco da tensão na linha em que a máquina está conectada, comprometendo a operação de outros equipamentos conectados ao mesmo barramento (SANTOS, 2012).

Com a evolução da eletrônica de potência, novas técnicas surgiram para reduzir os altos níveis de corrente de partida do motor, como é o caso das *soft starter*, contudo, esta técnica não permite que a máquina opere com velocidade variável.

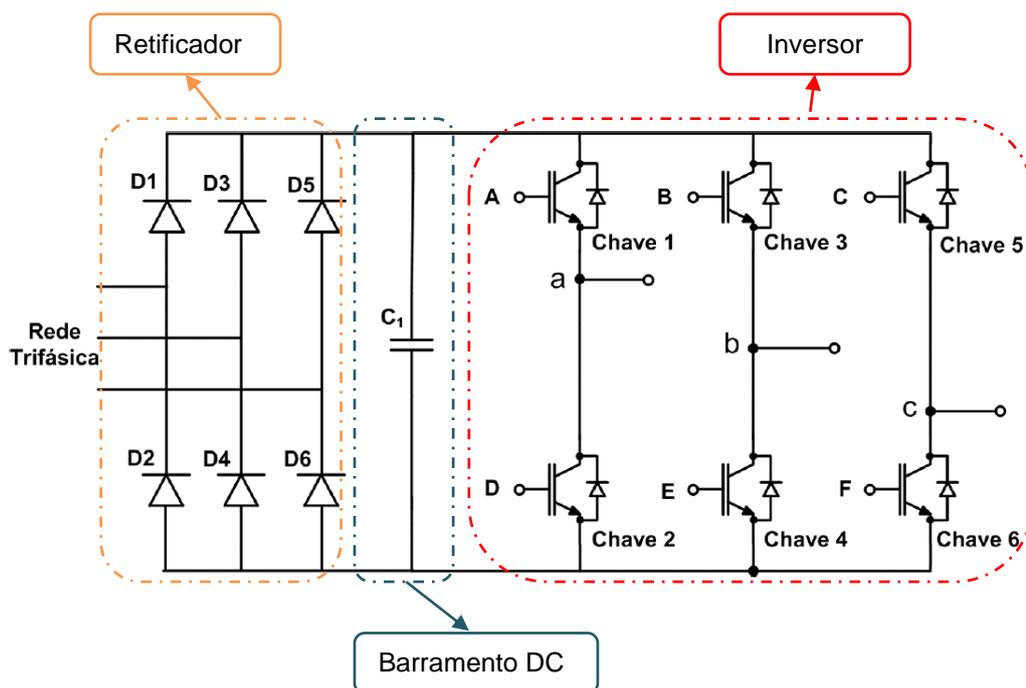
Entretanto, avaliando-se a equação (36), percebe-se que a velocidade síncrona da máquina é dependente da frequência imposta ao motor, bem como a sua quantidade de polos.

$$n = \frac{120 \cdot f}{p} \quad (36)$$

onde: n é a velocidade síncrona do motor; f é a frequência da tensão de alimentação; p é a quantidade de polos do motor.

A quantidade de polos do motor é algo característico de sua construção e, portanto, impossível de ser alterada conforme a necessidade de variação de velocidade. Porém, dispositivos eletrônicos variadores de frequência podem ser aplicados ao acionamento do motor para que sua velocidade seja variada e controlada. Tais dispositivos são chamados de inversores de frequência e são comumente associados com retificadores e banco de baterias para a realização de tal feito. A topologia destes dispositivos é apresentada na Figura 2, onde o retificador é responsável por transformar a tensão senoidal em contínua, enquanto que o barramento DC busca manter o nível desta tensão constante (GRACIOLA, 2016). Ainda, a tensão de saída do inversor é controlada pela combinação de suas chaves de potência. Por sua vez, estas chaves podem ser comandadas por técnicas baseadas em largura de pulso, como: Modulação por Largura de Pulso (PWM - do inglês, *Pulse Width Modulation*), Modulação por Largura de Pulso Senoidal (SPWM - do inglês, *Sine Pulse Width Modulation*) ou Modulação por Largura de Pulso do Vetor de Estado (SVPWM - do inglês, *Space Vector Pulse Width Modulation*), onde a última se destaca dentre as demais por possuir níveis reduzidos de harmônicos, devido ao menor número de comutações (PINHEIRO; BOTTERÓN, 2005).

Figura 2 – Composição do dispositivo eletrônico utilizado para a variação de frequência.



Fonte: Adaptado de Graciola (2016).

A técnica SVPWM busca aproximar o vetor de tensão gerado pelo inversor de um vetor de referência, tornando assim este último vetor o responsável pelo controle do inversor e da velocidade no eixo do motor.

Por sua vez, este vetor de referência pode ser gerado por técnicas variadas, sendo o controle escalar, controle vetorial e controle direto de torque os mais comuns (SANTOS, 2012).

Segundo Krause et al. (2013), possivelmente a estratégia por controle escalar seja a mais simples e barata de se aplicar, porém, apresentará desempenho limitado quando operado em baixas velocidades (BOSE, 2002). Devido a esta objetividade e simplicidade, o controle escalar será utilizado neste trabalho para operar o MIT em alimentação não senoidal.

Basicamente, o controle escalar varia a velocidade do MIT por meio da relação entre a amplitude e frequência da tensão de alimentação do motor, de modo a manter o fluxo eletromagnético no entreferro constante (SANTOS, 2012). Por sua vez, o fluxo eletromagnético no entreferro pode ser calculado pela equação (37).

$$\Phi_m = \frac{V_p}{f} = K_v \quad (37)$$

onde: Φ_m é o fluxo máximo do entreferro; V_p é a tensão de pico por fase e; K_v é a constante de proporcionalidade que garante o máximo fluxo do entreferro.

Contudo, a constante de proporcionalidade apresentada em (37) não leva em conta as perdas no cobre do estator, porém, em baixa velocidade, estas perdas influenciam no desempenho do controle escalar (KRISHNAN, 2001). A fim de minimizar os efeitos destas perdas, a equação (37) deve ser complementada pela queda de tensão estatórica, a qual é denominada V_{boost} e é apresentada na equação (38)(43).

$$V_{boost} = R_1 \cdot i_1 \cdot \sqrt{2} \quad (38)$$

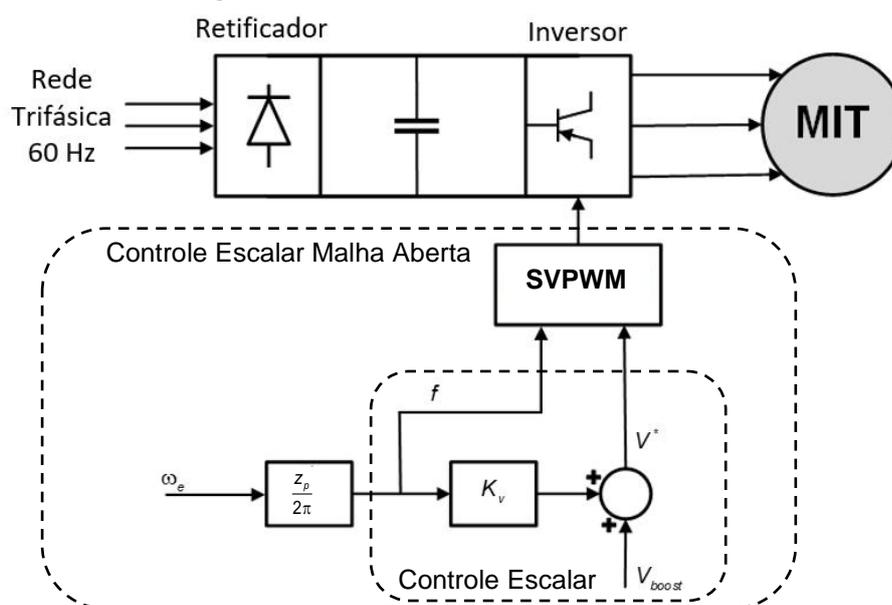
onde: i_1 é a corrente nominal do motor e R_1 é a resistência do estator.

Com esta complementação, a equação (37) passa a ser descrita pela equação (39).

$$\Phi_m = \frac{V_p - V_{boost}}{f} = K_v \quad (39)$$

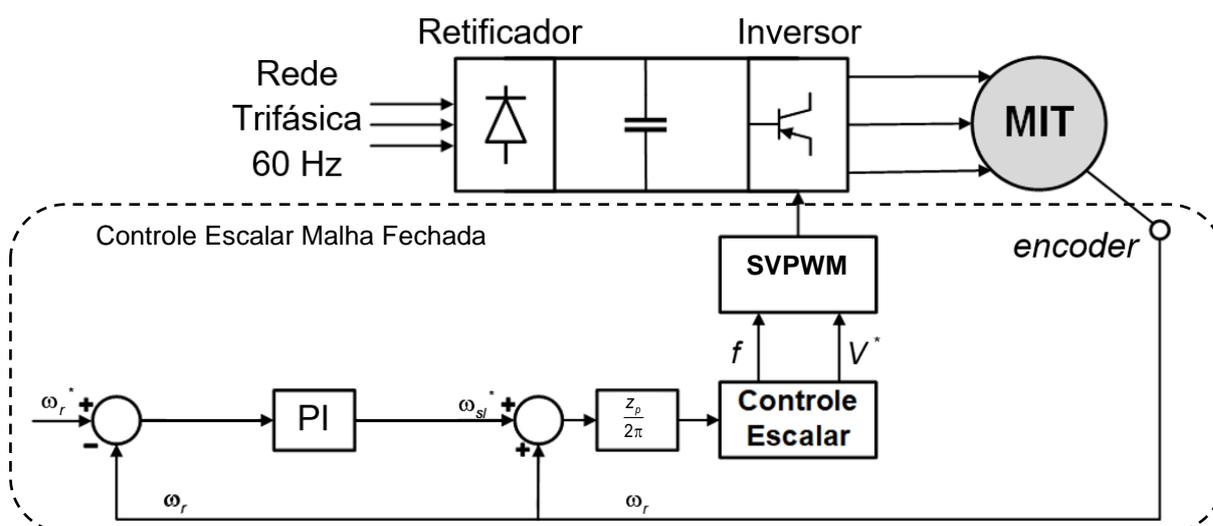
Implementando o controle escalar em malha aberta, tem-se apenas a imposição da relação apresentada na equação (39), ou seja, não se aplica realimentação de velocidade. Diferente da malha aberta, na implementação do controle escalar em malha fechada, a informação de velocidade no eixo do motor é constantemente monitorada, o que garante que velocidade da máquina seja corrigida (SANTOS, 2012). Os diagramas que esboçam o controle escalar em malha aberta e fechada são apresentados na Figura 3 e Figura 4, respectivamente.

Figura 3 – Controle escalar em malha aberta.



Fonte: Adaptado de Santos (2020).

Figura 4 – Controle escalar em malha fechada.



Fonte: Adaptado de Santos (2020).

onde: ω_{sl}^* é a velocidade de escorregamento, ω_r^* é a velocidade de referência, ω_r é a velocidade medida no eixo do rotor.

Neste contexto, este trabalho utiliza um método de estimação de velocidade que substitui o encoder, tornando o sistema mais barato e robusto.

Este capítulo abordou os princípios relacionados a modelagem do MIT e de seu acionamento em controle escalar. O próximo capítulo abordará os princípios e implementação do estimador de velocidade EKF.

3 FILTRO DE KALMAN ESTENDIDO

Segundo Vas (1998), o EKF é um estimador de estado recursivo que obtém estados não mensuráveis de um sistema não linear por meio de estados medidos. Além disso, a aplicação do EKF permite que ruídos provindos dos medidores de corrente e tensão sejam incorporados ao modelo.

Devido à maioria dos casos físicos se basearem em fenômenos não lineares, o EKF se tornou um produto largamente utilizado na teoria moderna de controle (SHI et al., 2002).

Para implementar o EKF como *sensorless* é necessário que seja realizada inicialmente a etapa de predição, onde a estimação dos estados é executada a partir da modelagem da máquina. Posterior à etapa de predição, ocorre a correção, onde os estados preditos são corrigidos por um processo de realimentação.

Para que o primeiro estágio seja implementado é necessário que a velocidade esteja incorporada como estado a ser predito no modelo matemático do MIT por espaço de estado. Portanto, a equação (23) é reescrita e a nova representação da modelagem dinâmico do MIT por espaço de estado é exibida em (40).

$$\begin{cases} \frac{d}{dt} \mathbf{x} = \mathbf{Ax} + \mathbf{Bu} \\ \mathbf{y} = \mathbf{Cx} \end{cases} \quad (40)$$

onde:

$$\mathbf{x} = [i_{1\alpha} \quad i_{1\beta} \quad \phi_{2\alpha} \quad \phi_{2\beta} \quad \omega_{mec}]^T \quad (41)$$

$$\mathbf{u} = [v_{1\alpha} \quad v_{1\beta}]^T \quad (42)$$

$$\mathbf{y} = [i_{1\alpha} \quad i_{1\beta}]^T \quad (43)$$

$$\mathbf{A} = \begin{bmatrix} -a & 0 & b & c\omega_{mec} & 0 \\ 0 & -a & -c\omega_{mec} & b & 0 \\ d & 0 & -e & -z_p\omega_{mec} & 0 \\ 0 & d & z_p\omega_{mec} & -e & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (44)$$

$$\mathbf{B} = \begin{bmatrix} g & 0 \\ 0 & g \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (45)$$

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (46)$$

relembrando que:

- \underline{v}_1 e \underline{v}_2 Tensão trifásica relacionada ao estator e ao rotor, respectivamente;
- \underline{i}_1 e \underline{i}_2 Corrente trifásica relacionada ao estator e ao rotor, respectivamente;
- $\underline{\phi}_1$ e $\underline{\phi}_2$ Fluxo de enlace do estator e do rotor, respectivamente;
- z_p Número de pares de polos da máquina;
- ω_{mec} Velocidade do rotor;

Além disto, para que a modelagem dinâmica do MIT seja implementada ao EKF ela deve ser discretizada. Assim:

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}_d \mathbf{x}(k) + \mathbf{B}_d \mathbf{u}(k) \\ \mathbf{y}(k) = \mathbf{C}_d \mathbf{x}(k) \end{cases} \quad (47)$$

Ainda, segundo Vas (1998), a matriz de saída discretizada é idêntica à matriz de saída contínua, portanto $\mathbf{C}_d = \mathbf{C}$, enquanto os termos \mathbf{A}_d e \mathbf{B}_d podem ser descritos como:

$$\mathbf{A}_d = \exp^{[\mathbf{A}T_o]} \cong \mathbf{I} + \mathbf{A}T_o + \frac{(\mathbf{A}T_o)^2}{2} \dots \quad (48)$$

$$\mathbf{B}_d = \mathbf{B}T_0 + \frac{\mathbf{A}\mathbf{B}T_0^2}{2} \dots \quad (49)$$

onde, T_0 é o período de amostragem.

Contudo, para que sejam levadas em conta as aproximações do modelo ideal do MIT e os ruídos advindos das medições de corrente e tensão, é necessário que vetores de ruídos sejam considerados (VAS,1998). Para isto, a equação (47) é representada pela equação (50) e seu diagrama de blocos pode ser visualizado na Figura 5.

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{A}_d \mathbf{x}(k) + \mathbf{B}_d \mathbf{u}(k) + \mathbf{v}(k) \\ \mathbf{y}(k) = \mathbf{C}_d \mathbf{x}(k) + \mathbf{w}(k) \end{cases} \quad (50)$$

onde:

- $\mathbf{v}(k)$ Ruído do medidor de tensão e das imprecisões do modelo;
- $\mathbf{w}(k)$ Ruído do medidor de corrente.

Na modelagem do EKF estes ruídos são do tipo branco gaussiano e são representados por matrizes de covariância. O ruído do medidor de tensão é representado pela matriz de covariância \mathbf{Q} , enquanto o do medidor de corrente é representado pela matriz de covariância \mathbf{R} . Além disto, no primeiro estágio é feita a atualização da matriz de predição (\mathbf{P}), que é utilizada no segundo estágio para compor a construção da matriz ganho de Kalman (\mathbf{K}).

Na aplicação do filtro, a matriz de predição e as matrizes de covariância dos ruídos são matrizes diagonais, sendo que $\mathbf{Q} \in \mathbb{R}^{5 \times 5}$, $\mathbf{P} \in \mathbb{R}^{5 \times 5}$ e $\mathbf{R} \in \mathbb{R}^{2 \times 2}$. Segundo Vas (1998) a análise por meio do sistema bifásico faz com que os termos da diagonal principal tenham valores repetidos, reduzindo assim para 5 elementos desconhecidos, que são:

$$\mathbf{Q} = \begin{bmatrix} q_{11} & 0 & 0 & 0 & 0 \\ 0 & q_{11} & 0 & 0 & 0 \\ 0 & 0 & q_{33} & 0 & 0 \\ 0 & 0 & 0 & q_{33} & 0 \\ 0 & 0 & 0 & 0 & q_{55} \end{bmatrix} \quad (51)$$

$$\mathbf{P} = \begin{bmatrix} p_{11} & 0 & 0 & 0 & 0 \\ 0 & p_{11} & 0 & 0 & 0 \\ 0 & 0 & p_{11} & 0 & 0 \\ 0 & 0 & 0 & p_{11} & 0 \\ 0 & 0 & 0 & 0 & p_{11} \end{bmatrix} \quad (52)$$

$$\mathbf{R} = \begin{bmatrix} r_{11} & 0 \\ 0 & r_{11} \end{bmatrix} \quad (53)$$

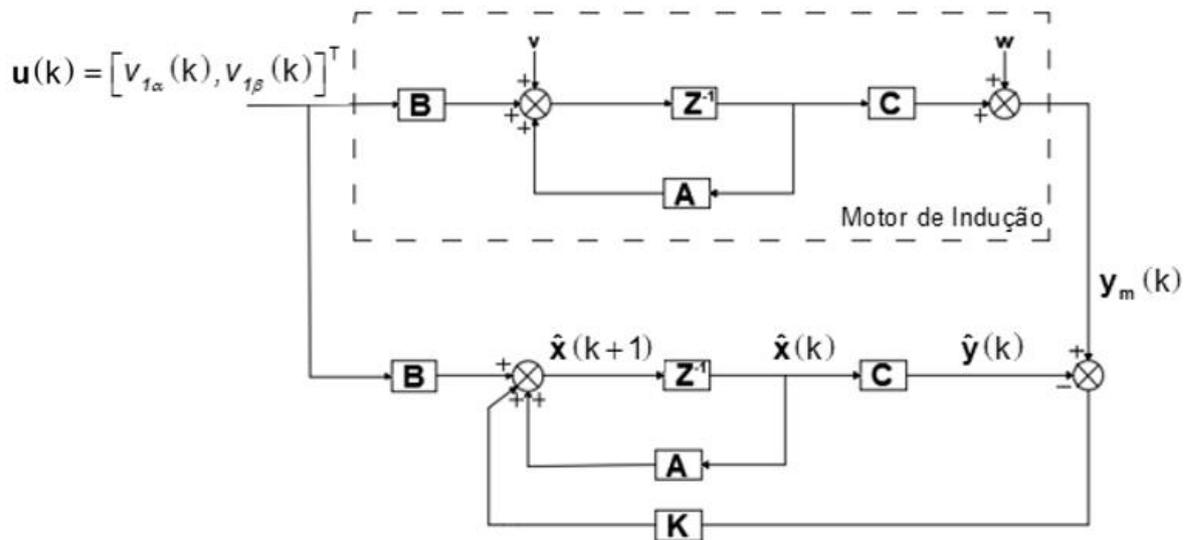
No segundo estágio o vetor de estado predito $\mathbf{x}(k+1)$ é corrigido conforme a equação a seguir:

$$\hat{\mathbf{x}}(k+1) = \mathbf{A}_d \mathbf{x}(k) + \mathbf{B}_d \mathbf{u}(k) + \mathbf{K}(\mathbf{y}_m - \hat{\mathbf{y}}) \quad (54)$$

onde, $\hat{\mathbf{x}}(k+1)$ é o próximo vetor de estado estimado, \mathbf{K} é a matriz de ganho Kalman, $\hat{\mathbf{y}}$ é a saída estimada e \mathbf{y}_m é a saída simulada do MIT.

A Figura 5 exibe o diagrama de blocos da estrutura do EKF.

Figura 5 - Estrutura do Filtro de Kalman Estendido.



Fonte: Adaptado de Vas (1998, p.487).

Após a determinação das condições iniciais dos estados a serem estimados e dos valores iniciais das matrizes de covariância e predição, pode-se descrever a implementação prática do EKF em seis etapas, sendo elas:

- Etapa 1: Predição do vetor de estado por meio da equação (55).

$$\mathbf{x}(k+1) = \mathbf{A}_d \hat{\mathbf{x}}(k) + \mathbf{B}_d \mathbf{u}(k) \quad (55)$$

onde, $\hat{\mathbf{x}}(k)$ é o vetor de estado estimado.

Para pequenos valores de T_0 , permite-se que \mathbf{A}_d e \mathbf{B}_d sejam escritos como:

$$\mathbf{A}_d = (\mathbf{I} + \mathbf{A}T_0) = \begin{bmatrix} 1 - aT_0 & 0 & bT_0 & c\omega_{mec}T_0 & 0 \\ 0 & 1 - aT_0 & -c\omega_{mec} & bT_0 & 0 \\ dT_0 & 0 & 1 - eT_0 & -z_p\omega_{mec}T_0 & 0 \\ 0 & dT_0 & z_p\omega_{mec}T_0 & 1 - eT_0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (56)$$

$$\mathbf{B}_d = \mathbf{B}T_o = \begin{bmatrix} gT_o & 0 \\ 0 & gT_o \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (57)$$

em que \mathbf{I} é uma matriz identidade de ordem 5.

- Etapa 2: A determinação da matriz de predição é realizada por meio da equação (58).

$$\mathbf{P}(k+1) = \mathbf{f}(k+1)\hat{\mathbf{P}}(k)\mathbf{f}^T(k+1) + \mathbf{Q} \quad (58)$$

onde, $\hat{\mathbf{P}}(k)$ é a matriz de predição estimada e $\mathbf{f}(k+1)$ é uma matriz gradiente calculada por meio da equação (59).

$$\mathbf{f}(k+1) = \left. \frac{\partial}{\partial \mathbf{x}} (\mathbf{A}_d \mathbf{x} + \mathbf{B}_d \mathbf{u}) \right|_{\mathbf{x}=\hat{\mathbf{x}}(k+1)} \quad (59)$$

Aplicando \mathbf{A}_d e \mathbf{B}_d em (59), tem-se:

$$\mathbf{f}(k+1) = \begin{bmatrix} 1-aT_o & 0 & bT_o & c\omega_{mec}T_o & c\phi_{2\beta}T_o \\ 0 & 1-aT_o & -c\omega_{mec} & bT_o & -c\phi_{2\alpha}T_o \\ dT_o & 0 & -eT_o & -z_p\omega_{mec}T_o & \phi_{2\beta}T_o \\ 0 & dT_o & z_p\omega_{mec}T_o & -eT_o & \phi_{2\alpha}T_o \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (60)$$

- Etapa 3: A predição da matriz ganho Kalman é realizada por meio da equação (61).

$$\mathbf{K}(k+1) = \mathbf{P}(k+1)\mathbf{h}^T(k+1)[\mathbf{h}(k+1)\mathbf{P}(k+1)\mathbf{h}^T(k+1) + \mathbf{R}]^{-1} \quad (61)$$

onde, $\mathbf{h}(k+1)$ é uma matriz gradiente que é calculada por meio da equação (62).

$$\mathbf{h}(k+1) = \left. \frac{\partial}{\partial \mathbf{x}} (\mathbf{C}_d \mathbf{x}) \right|_{\mathbf{x}=\hat{\mathbf{x}}(k+1)} \quad (62)$$

Por sua vez, a equação (62) pode a ser escrita como:

$$\mathbf{h}(k+1) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (63)$$

- Etapa 4: A estimação do vetor de estado é realizada por meio da equação (64).

$$\hat{\mathbf{x}}(k+1) = \mathbf{x}(k+1) + \mathbf{K}(k+1) [\mathbf{y}_m(k+1) - \hat{\mathbf{y}}(k+1)] \quad (64)$$

onde:

$$\mathbf{y}(k+1) = \mathbf{C}_d \mathbf{x}(k+1) = [i_{1\alpha}(k+1) \quad i_{1\beta}(k+1)]^T \quad (65)$$

- Etapa 5: A estimação do erro da matriz de predição é obtida por meio da expressão (66).

$$\hat{\mathbf{P}}(k+1) = \mathbf{P}(k+1) - \mathbf{K}(k+1) \mathbf{h}(k+1) \mathbf{P}(k+1) \quad (66)$$

- Etapa 6: Atualização de todos os valores e retorno para a etapa 1.

Este capítulo abordou os princípios relacionados à modelagem e implementação do EKF. O próximo capítulo abordará os princípios e implementação dos algoritmos otimizadores que serão utilizados na determinação das matrizes de covariância e de predição do EKF.

4 ALGORITMOS DE OTIMIZAÇÃO

Devido à constante busca pela maximização dos lucros, desempenho, eficiência, limitação de recursos e minimização de custos, a otimização se tornou uma ferramenta fundamental na engenharia, economia e indústria (YANG, 2010).

Com isto, diversas metodologias de otimização são exploradas para que um determinado resultado seja aprimorado. Dentre estas metodologias têm-se os métodos determinísticos, ou seja, os algoritmos que retornam o mesmo valor, desde que, iniciados do mesmo ponto. Contudo, há também os métodos estocásticos, os quais percorrem caminhos aleatórios para encontrar o valor ótimo.

Dentre os métodos estocásticos, há destaque para as metaheurísticas baseadas em população, as quais se baseiam no comportamento de grupos, como insetos, pássaros, peixes, entre outros (CAVALI, 2017).

A seguir, serão apresentados as quatro metaheurísticas baseadas em população que foram propostas neste trabalho para otimizar o problema estudado.

4.1 EVOLUÇÃO DIFERENCIAL

Desenvolvido por Storn e Price em 1995, o algoritmo de otimização DE se baseia nas teorias evolutivas darwinianas, onde uma determinada população evolui por meio da aplicação dos processos de seleção, mutação e cruzamento (STORN e PRICE, 1997).

Diferente dos demais algoritmos baseados em teoria de evolução, o DE não utiliza distribuições probabilísticas para efetuar a mutação, para este processo, o otimizador emprega os próprios indivíduos da população, os combinando através de operações de soma vetorial e multiplicação escalar (GOULART et al., 2011).

Segundo Rutkowski (2008), para compreender a implementação do DE, é necessário que se tenha conhecimento sobre os seguintes componentes:

- População de indivíduos: soluções candidatas, indivíduos também são conhecidos como cromossomos;

- Seleção: processo em que os indivíduos mais adaptados ao meio sobrevivem;
- Mutação: processo em que ocorre a modificação do material genético dos indivíduos, introduzindo características distintas das existentes nos demais seres;
- Cruzamento: processo em que ocorre a transferência de material genético dos ascendentes aos descendentes.

Para a implementação do DE, é necessário que inicialmente se gere a população inicial de indivíduos, considerando o espaço de busca delimitado. Posteriormente, todas as soluções candidatas são avaliadas por meio da Função Objetivo (FO) definida, onde está deve ser intimamente ligada ao problema que se deseja otimizar.

Na sequência ocorre o processo de mutação, onde dois ou mais indivíduos da população inicial são aleatoriamente escolhidos para darem origem ao sujeito mutado, onde a equação (67) apresenta tal processo. O cromossomo utilizado como primeiro indivíduo para o processo de mutação é denominado *target vector*, o qual é posteriormente aplicado ao processo de cruzamento.

$$\mathbf{v}_i(k) = \mathbf{x}_{r_1}(k) + F(\mathbf{x}_{r_2}(k) + \mathbf{x}_{r_3}(k)) \quad (67)$$

onde $\mathbf{v}_i(k)$ é o indivíduo da população mutada; F é fator de ponderação do vetor de diferença entre os indivíduos, variando tipicamente entre 0 e 1; \mathbf{x}_{r_1} , \mathbf{x}_{r_2} e \mathbf{x}_{r_3} são os indivíduos escolhidos aleatoriamente da população inicial.

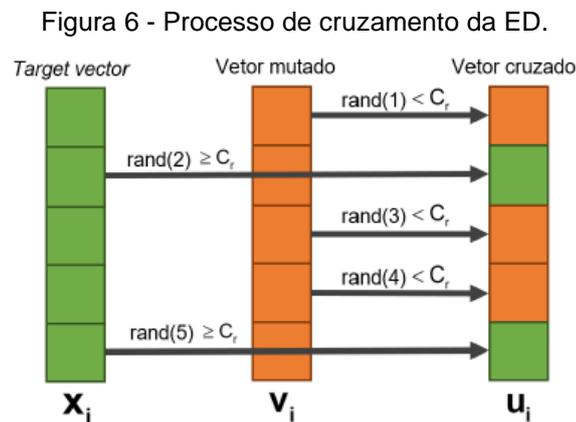
A determinação do fator de ponderação define o nível de perturbação do indivíduo mutado em relação aos que o gerou, ou seja, quanto mais próximo de zero, menor a perturbação, ao passo que, quanto mais próximo de um, maior a perturbação (GUEDES, 2016).

Após a mutação ocorre o processo de cruzamento entre a população mutada e a inicial. Neste processo o indivíduo mutado é cruzado com o *target vector* para que um cromossomo com melhor aptidão seja gerado. Para que este processo ocorra é necessário que um vetor aleatório do mesmo tamanho do cromossomo e com valores entre 0 e 1 seja criado. Posteriormente define-se a taxa de cruzamento, a qual tem por objetivo direcionar quais os genes serão passados aos descendentes e está

contida entre 0 e 1. Então, para os casos em que o valor do gene do cromossomo é inferior a taxa de cruzamento, o gene do indivíduo mutado é selecionado, caso contrário, seleciona-se o gene do *target vector*. O processo de cruzamento é apresentado na equação (68), o qual é ilustrado na Figura 6.

$$\mathbf{u}_i(k) = \begin{cases} \mathbf{v}_i(k) & \text{se } \text{rand} < C_r \\ \mathbf{x}_i(k) & \text{se } \text{rand} \geq C_r \end{cases} \quad (68)$$

onde: *rand* é o vetor aleatório do mesmo tamanho dos cromossomos que é utilizado para comparar com C_r .



Fonte: Adaptado de Bernardes (2020, p. 31).

Finalizando o processo de cruzamento é necessário que todos os indivíduos da nova população tenham seu valor de FO calculado, pois ao mutar e cruzar os cromossomos não se tem a garantia de que o novo indivíduo possui desempenho superior ao da população inicial. Frente a isto, é necessário que se realize uma comparação do valor da FO do indivíduo cruzado e do cromossomo da população inicial para que apenas os melhores indivíduos sejam direcionados para a próxima geração, como apresentado na equação (69).

$$\mathbf{x}_i(k+1) = \begin{cases} \mathbf{u}_i(k) & \text{se } \text{FO}(\mathbf{u}_i(k)) < \text{FO}(\mathbf{x}_i(k)) \\ \mathbf{x}_i(k) & \text{se } \text{FO}(\mathbf{u}_i(k)) \geq \text{FO}(\mathbf{x}_i(k)) \end{cases} \quad (69)$$

Então, todo o processo é executado até que o critério de parada estabelecido pelo usuário seja alcançado.

4.2 ENXAME DE PARTÍCULAS

Elaborado por Kennedy em 1995, a PSO é um algoritmo bio-inspirado que se concentra em solucionar problemas de otimização com base no comportamento social de enxames, como o dos pássaros durante um voo de migração ou busca por alimentos. O processo de otimização é influenciado pela experiência de cada indivíduo, onde o enxame compartilha constantemente informações sobre o espaço de busca (KENNEDY, 2010).

Para implementação da PSO, é necessário que inicialmente se tenha três informações fundamentais, que são a posição inicial e a melhor posição que o indivíduo encontrou dentro do espaço de busca, além da velocidade dos pássaros. As posições iniciais dos pássaros, bem como sua velocidade inicial são informações atribuídas de forma aleatória com base em um intervalo definido. Então, por meio destas informações é possível atualizar a posição dos indivíduos, a qual é realizada por meio das equações (70) e (71).

$$\mathbf{v}_{ij}(k+1) = w\mathbf{v}_{ij}(k) + c_1r_1(\mathbf{p}_{ij} + \mathbf{z}_{ij}(k)) + c_2r_2(\mathbf{p}_{best} + \mathbf{z}_{ij}(k)) \quad (70)$$

$$\mathbf{z}_{ij}(k+1) = \mathbf{z}_{ij}(k) + \mathbf{v}_{ij}(k+1) \quad (71)$$

onde $\mathbf{v}_{ij}(k)$ é a velocidade atual do indivíduo, enquanto $\mathbf{v}_{ij}(k+1)$ é a velocidade a ser utilizada para a atualização da posição do pássaro em questão, e w é o coeficiente de inércia. Por sua vez, c_1 e c_2 são constantes de ponderação com valor típico sendo 2, já r_1 e r_2 são valores aleatórios entre 0 e 1. Enquanto a variável, \mathbf{p}_{ij} é a melhor solução encontrada pelo indivíduo em movimento, já \mathbf{p}_{best} é a melhor solução encontrada pelo enxame. Então, todos estes parâmetros são utilizados para mover o pássaro da posição atual $\mathbf{z}_{ij}(k)$ para a nova posição $\mathbf{z}_{ij}(k+1)$.

Então, por meio da equação (72) é realizada a atualização da melhor solução encontrada.

$$p(k+1) = \begin{cases} p(k) & \text{se } FO(p(k)) < FO(\mathbf{z}(k+1)) \\ \mathbf{z}(k+1) & \text{se } FO(p(k)) \geq FO(\mathbf{z}(k+1)) \end{cases} \quad (72)$$

Por fim, a última atualização realizada na implementação do algoritmo é a do $p_{\text{best}}(k+1)$, que assume o melhor valor de $p(k)$.

4.3 ENXAME DE VAGALUMES

Criado em 2008, o algoritmo de otimização baseado no comportamento social do vagalume é um dos mais recentes dentro da categoria de bio-inspirados. O FA busca solucionar problemas de otimização utilizando a característica de bioluminescência dos vagalumes, a qual é utilizada para atrair parceiros e presas em potencial.

Para que a implementação do FA ocorra é necessário que três regras fundamentais sejam compreendidas, sendo elas (YANG, 2010).

- A atração entre os vagalumes não depende de seu gênero;
- A atratividade de um vagalume é diretamente proporcional à sua luminosidade, portanto o vagalume mais luminoso atrairá para si os vagalumes de menor intensidade de luz. Com isto, à medida que a distância diminui a atratividade entre os vagalumes aumenta. Caso possuam a mesma atratividade os vagalumes se movimentam de forma aleatória;
- A função objetivo a ser otimizada influencia diretamente na atratividade dos vagalumes.

Inicialmente, é necessário que se determine a FO a ser otimizada. Posteriormente se define a posição da população inicial, a qual deve ser gerada de forma aleatória e atualizada a cada iteração (ALB et al., 2016). A atualização da

posição dos indivíduos do enxame é intimamente ligada à atratividade entre dois vagalumes, podendo ser calculada por meio da equação (73).

$$\beta = \beta_0 e^{-\gamma r^2} \quad (73)$$

onde β_0 é a atratividade em $r = 0$ e seu valor para a maior parte das aplicações é 1, já γ é o coeficiente relacionado a absorção de luz de um determinado meio e seu valor varia tipicamente entre 0,1 e 10 (YANG, 2010).

Por sua vez, o termo r_{ij} representa a distância entre os vagalumes i e j , em \mathbf{x}_i e \mathbf{x}_j , sendo calculada por meio da equação (74).

$$r_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{\sum_{n=1}^d [\mathbf{x}_i(n) - \mathbf{x}_j(n)]^2} \quad (74)$$

Com base nas determinações acima, o vagalume menos atrativo caminha em direção ao mais atraente por meio equação (75).

$$\mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \beta_0 e^{-\gamma r_{ij}^2} [\mathbf{x}_j(k) - \mathbf{x}_i(k)] + \alpha \epsilon_i \quad (75)$$

onde $\mathbf{x}_i(k+1)$ representa a posição do indivíduo após o movimento e $\alpha \epsilon_i$ refere-se ao termo de aleatoriedade, sendo α um coeficiente que corresponde a um valor aleatório gerado para maioria dos casos a partir de uma distribuição gaussiana e neste caso pode ser substituído por valores aleatórios de -0,5 a 0,5.

Segundo Alb et al. (2016), tem-se como opção para aprimorar o tempo de convergência do algoritmo de otimização, a atualização de maneira progressiva do parâmetro de aleatoriedade, onde um dos métodos aplicados é exibido em (76).

$$\alpha = \delta \alpha_0^k \quad (76)$$

onde α_0 corresponde ao valor de α da iteração anterior, e o fator δ assume valores entre 0,9 e 0,99.

Vale ressaltar que o processo descrito neste capítulo se repete até que o critério de parada definido pelo usuário seja atingindo.

4.4 LOBOS CINZENTOS

Proposta por Mirjalili em 2014, o GWO é um algoritmo bio-inspirado que se baseia no comportamento de caça e hierarquia dos lobos cinzentos. Em alcateia, os lobos cinzentos se organizam ao dividir a sua estrutura hierárquica em 4 níveis, sendo alfa, beta, delta e ômega. No topo da hierarquia se encontram os alfas, os quais são responsáveis por decisões e também os únicos do grupo que podem acasalar. Logo abaixo se encontram os betas, que auxiliam nas decisões e são os mais aptos a assumir o comando caso o alfa venha a falecer. Ainda, há os deltas, que são subalternos ao alfa e beta, porém superiores aos ômegas, onde o último é a base da hierarquia (MIRJALILI et. al, 2014). Por sua vez, o método de caça se baseia em basicamente três processos, sendo a busca, o cercamento e o ataque de suas presas.

Para implementação do GWO, o nível hierárquico será seguido para otimizar a função objetivo, onde o alfa apresenta a melhor solução, seguido do beta e delta. Todas as demais soluções são chamadas de ômega e seguirão o caminho traçado pelos três melhores indivíduos (alfa, beta e delta).

Inicialmente, os lobos rodeiam a presa, onde este comportamento é expresso pela equação (77) e (78).

$$D = |CX_p(k) - X_i(k)| \quad (77)$$

$$X_i(k+1) = X_p(k) - AD \quad (78)$$

onde $X_p(k)$ é a posição da presa na iteração k , $X_i(k+1)$ é a posição do lobo em $(k+1)$ e A e C são vetores calculados por meio das equações (79) e (80), respectivamente.

$$A = 2ar_1 - a \quad (79)$$

$$C = 2r_2 \quad (80)$$

onde r_1 e r_2 são vetores aleatórios $[0,1]$ e a é um vetor que inicia em 2 e decresce linearmente à medida que ocorre as iterações.

Após rodear a presa, os lobos iniciam a caçada, a qual é guiada pelo alfa, porém ocasionalmente o evento conta com a participação do beta e delta. Como não se tem a exata localização da presa (ótimo global), supõe-se que alfa, beta e delta possuem melhor conhecimento sobre a posição da presa. Frente a isto, se armazena as três melhores soluções e se obriga os demais lobos a seguirem alfa, beta e delta por meio da equação (81).

$$X_i(k+1) = \frac{X_1(k) + X_2(k) + X_3(k)}{3} \quad (81)$$

onde:

$$X_1(k) = X_\alpha - A_1 D_\alpha \quad (82)$$

$$X_2(k) = X_\beta - A_2 D_\beta \quad (83)$$

$$X_3(k) = X_\delta - A_3 D_\delta \quad (84)$$

onde:

$$D_\alpha = |C_1 X_\alpha - X_i| \quad (85)$$

$$D_\beta = |C_2 X_\beta - X_i| \quad (86)$$

$$D_\omega = |C_3 X_\omega - X_i| \quad (87)$$

em que A_1 , A_2 e A_3 são calculados pela equação (79) e C_1 , C_2 e C_3 são calculados pela equação (80).

Quando a presa para de se mover, os lobos cinzentos a ataca, terminando assim a etapa de caçada. Para modelar esta aproximação da presa, diminui-se o valor do parâmetro a . Como A varia em um intervalo dependente de a $[-2a, 2a]$, ao reduzir-se a , também se tem a redução de A . Frente a isto, quando A está entre -1 e 1 , a próxima posição do lobo cinzento pode estar entre sua posição atual e a de sua presa.

Outra etapa importante para a exploração do espaço de busca do algoritmo GWO é a de pesquisa da presa. Nesta etapa os lobos alfa, beta e delta divergem um dos outros para buscar novas presas e voltam a convergir para que então a presa seja atacada. Para modelar esta etapa utiliza-se A com valores aleatórios que estejam fora do intervalo -1 e 1 . Outro componente que incrementa a exploração do espaço de busca é o C , o qual possui valores aleatórios entre 0 e 2 e fornece pesos para a presa. Caso o peso atribuído à presa seja superior a 1 , ocorre a estimulação do efeito da presa na definição da distância. Caso o peso atribuído para a presa seja inferior a 1 , o efeito da presa na definição da distância é desestimulado.

Este capítulo abordou os princípios relacionados a modelagem e implementação dos algoritmos otimizadores DE, PSO, FA e GWO. O próximo capítulo apresentará a metodologia aplicada ao trabalho.

5 METODOLOGIA

Inicialmente, para verificar o desempenho do EKF como estimador de velocidade de um motor de indução trifásico, foi realizada a implementação de tal algoritmo por meio da plataforma Simulink e das ferramentas do *Power System Blockset* (PSB), disponíveis no software MATLAB®. Basicamente, nesta implementação foi elaborado um sistema utilizando o bloco do motor de indução trifásico, que foi ajustado conforme os parâmetros exibidos na Tabela 1 e um *toolbox S-Function*, o qual executou o algoritmo EKF dentro do Simulink.

Tabela 1 - Parâmetros do motor utilizado.

Dados do motor: 1HP, 220/380V, 60Hz, 4 polos	
Resistência de estator (R_1)	7,56 Ω
Resistência de rotor (R_2)	3,84 Ω
Indutância de estator (L_1)	0,35085 H
Indutância de rotor (L_2)	0,35085 H
Indutância mútua (L_M)	0,33615 H
Momento de inércia (J)	0,017 Kg/m ²
Coefficiente de atrito (K_D)	0,0001 N·m·s

Fonte: Autoria própria.

Para compor o sistema em alimentação senoidal, foi incorporada uma fonte de alimentação trifásica equilibrada de sequência direta e amplitude $220 \cdot \sqrt{2}$ V. O esquemático que representa este sistema por completo é apresentado na Figura 7.

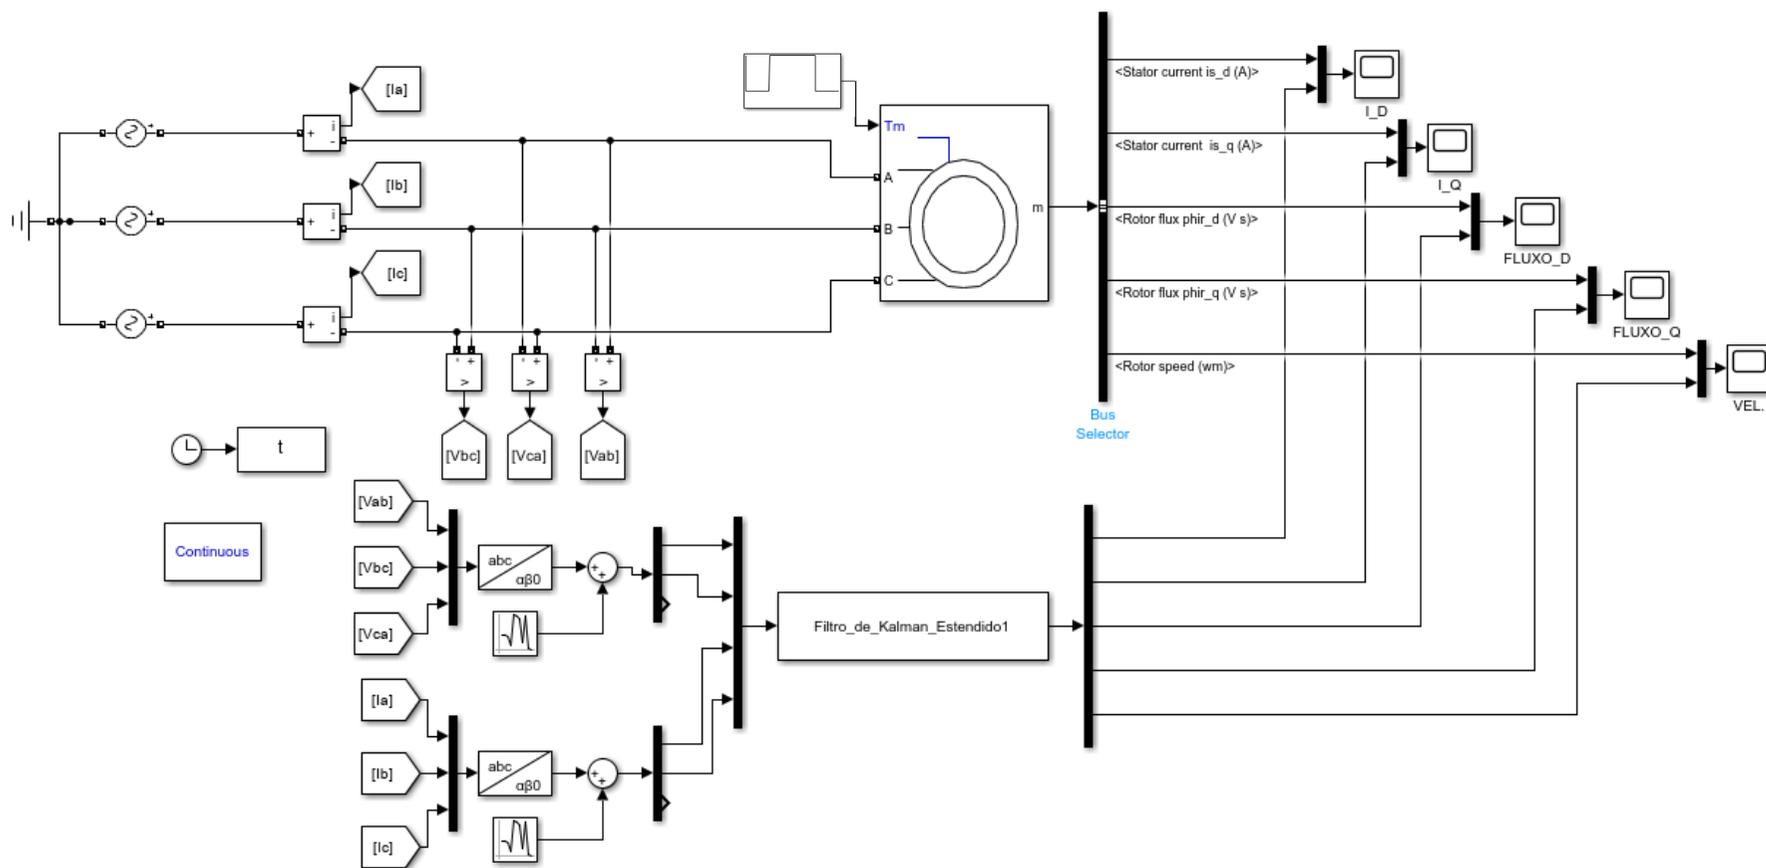
Para a implementação em alimentação não senoidal em malha aberta, foi conectado à fonte de alimentação senoidal um retificador trifásico a diodo, seguido de um capacitor de $37 \cdot 10^{-3}$ F para manter o nível da tensão contínua o mais estável no link CC e, por fim, conectou-se o conjunto a um inversor de frequência de 6 chaves de potência, as quais eram comandadas pelo SVPWM conforme a velocidade imposta como referência. O esquemático que representa este sistema é exibido na Figura 8.

O sistema em malha fechada contou com o mesmo esquemático para alimentação aplicado em malha aberta. Contudo, em malha fechada é necessário ajustar o controlador Proporcional-Integral (PI) que incorporará o controle de velocidade. Para este caso, o PI foi sintonizado de forma empírica, com ganho de 4,9532 para o K_p e de 24,4546 para o K_i . Além disso, neste modelo foi utilizada a velocidade estimada pelo EKF como realimentação para o controle de velocidade, substituindo assim a aplicação do *encoder* no diagrama exibido na Figura 4. O esquemático que exhibe este sistema por completo é apresentado na Figura 9.

Posteriormente, implementou-se os algoritmos FA, PSO, DE e GWO para que as matrizes de covariância e de predição do EKF fossem otimizadas quando o sistema fosse submetido à alimentação senoidal e não senoidal. Neste processo, cada otimizador foi empregado individualmente na otimização do EKF quando aplicado ao sistema em alimentação senoidal, não senoidal em malha aberta e em malha fechada.

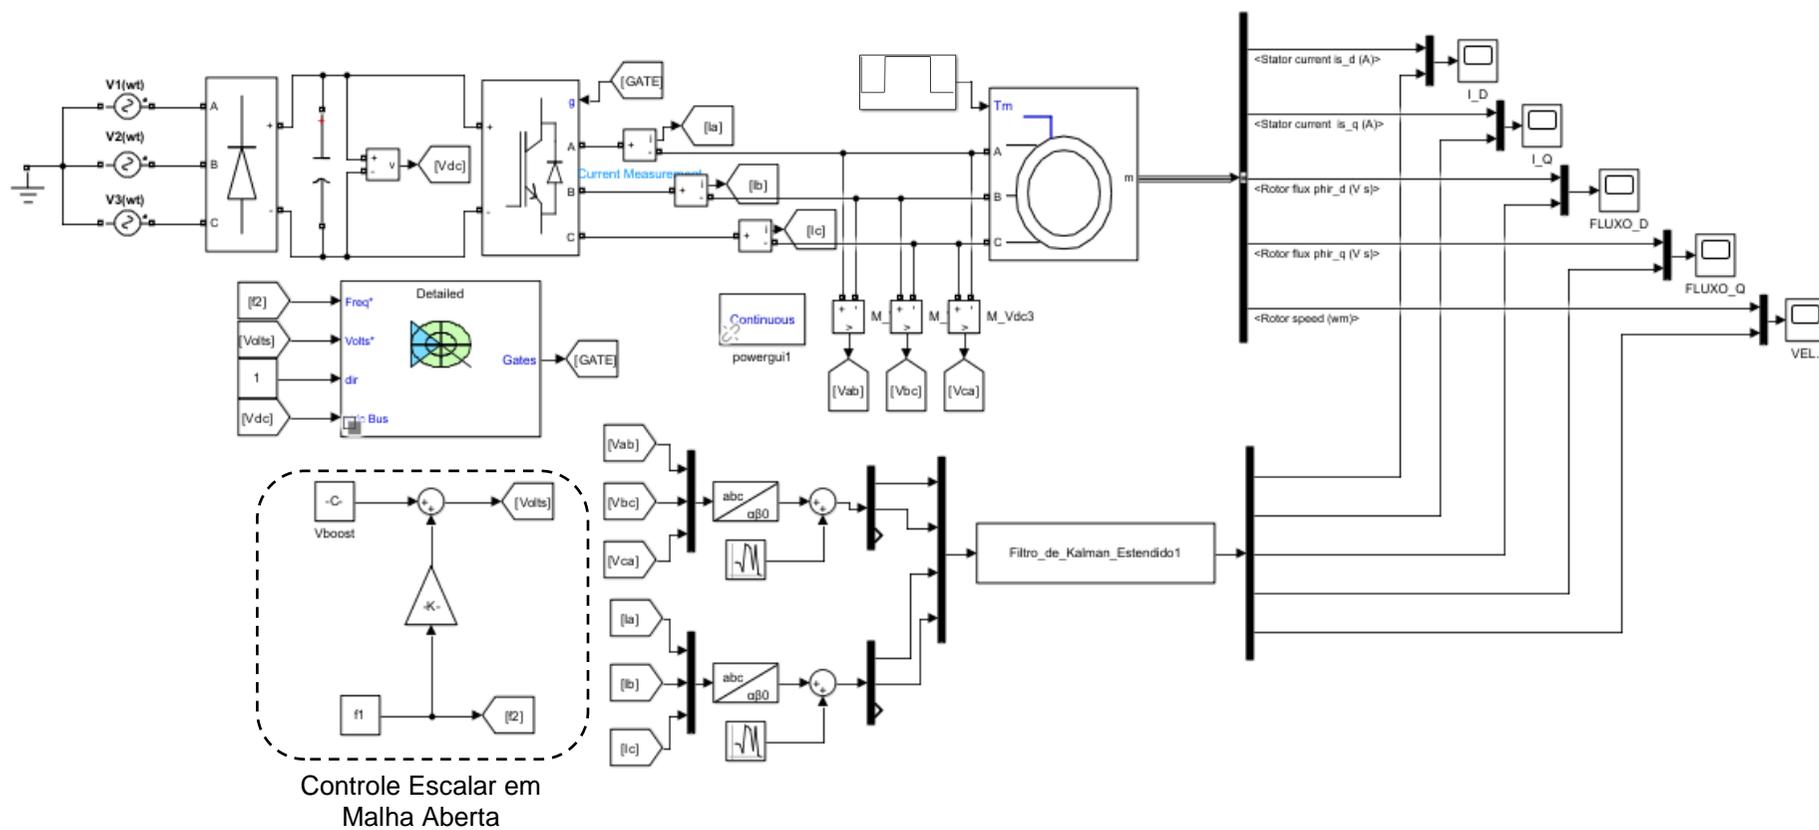
Inicialmente, para a implementação dos algoritmos otimizados, é necessário a definição do espaço de busca que será explorado. Para permitir que os algoritmos de otimização explorem novas combinações e possivelmente encontre o valor ótimo global, o espaço de busca foi ampliado na ordem de 10^{+4} em relação ao valor base tipicamente aplicado em cada parâmetro do filtro (P_{ff}), ou seja, $P_{ff} \cdot 10^{+4}$ como limite superior e $P_{ff} \cdot 10^{-4}$ como limite inferior do espaço de busca. A Tabela 2 exhibe os valores utilizados no espaço de busca, bem como os parâmetros comumente usados. Vale ressaltar que a população definida para ser a inicial foi gerada de forma aleatória dentro do espaço de busca estabelecido.

Figura 7 - Sistema elaborado para a implementação do otimizador em alimentação senoidal.



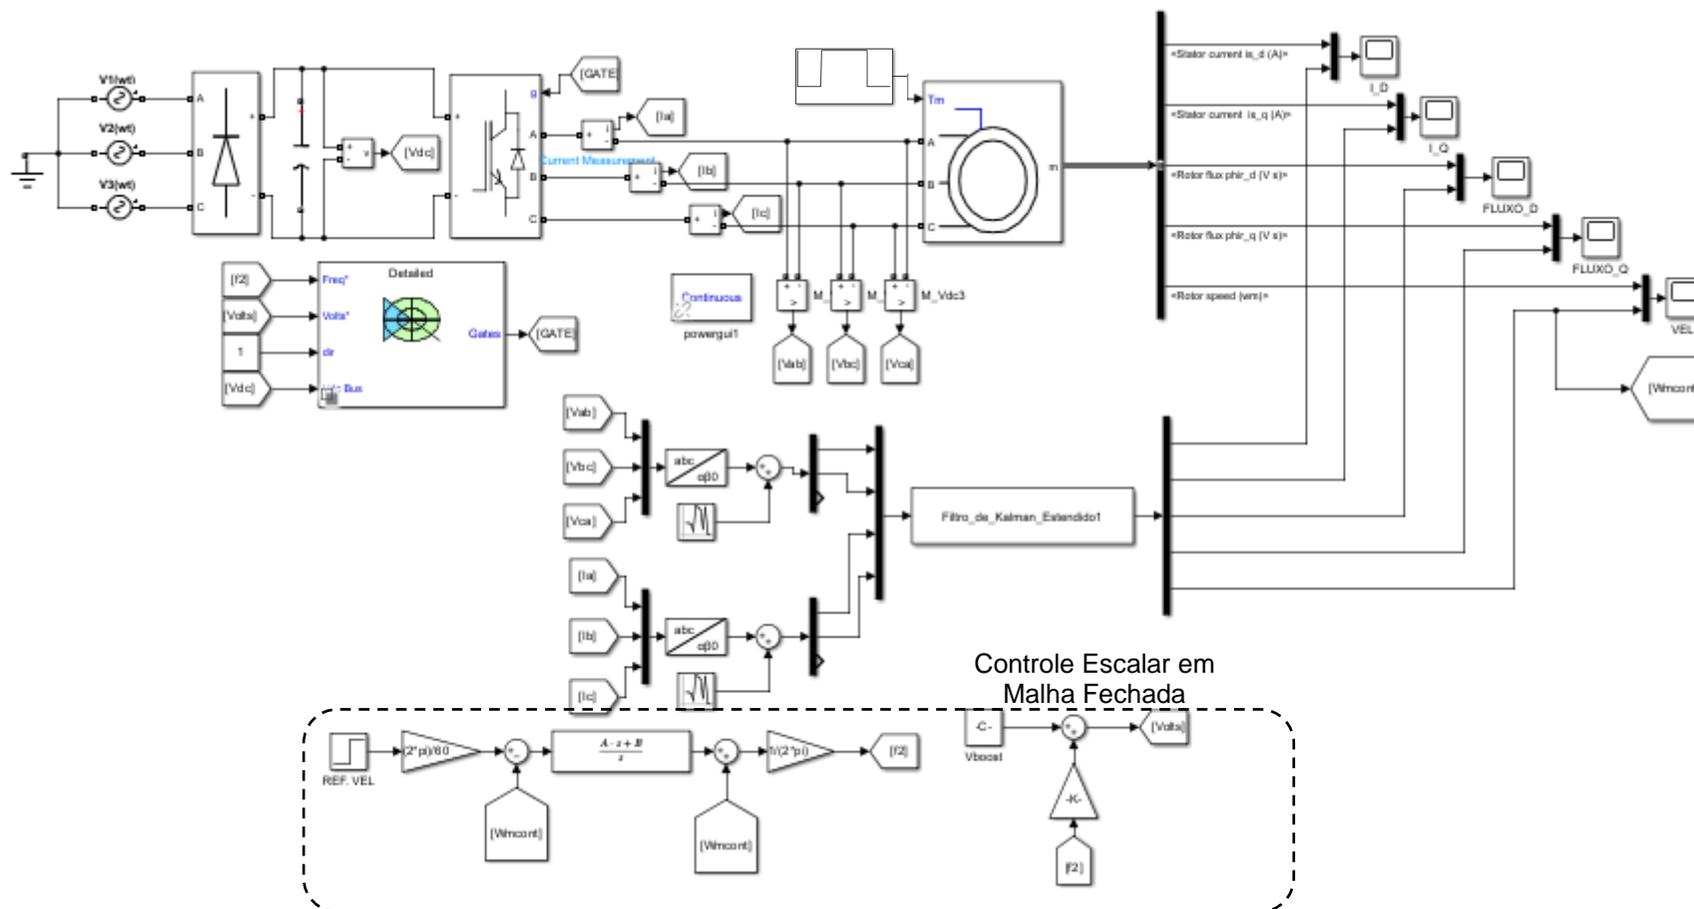
Fonte: Autoria própria

Figura 8 – Sistema elaborado para a implementação do otimizador em alimentação não senoidal malha aberta



Fonte: Autoria própria

Figura 9 – Sistema elaborado para a implementação do otimizador em alimentação não senoidal malha fechada.



Fonte: Autoria própria

Tabela 2 - Espaço de busca utilizado para os algoritmos de otimização.

Parâmetro	P_{if}	Limite inferior do espaço de busca	Limite superior do espaço de busca
p_{11}	10^{-9}	10^{-13}	10^{-5}
q_{11}	10^{-6}	10^{-10}	10^{-2}
q_{33}	10^{-7}	10^{-11}	10^{-3}
q_{55}	10^{-3}	10^{-7}	10^1
r_{11}	10^0	10^{-4}	10^4

Fonte: Autoria própria.

Com a definição do espaço de busca para geração inicial dos algoritmos de otimização, foi necessário determinar a FO a ser otimizada.

Para todos os métodos de otimização aplicados no EKF em alimentação senoidal e não senoidal, foi utilizada a mesma FO, a qual busca a minimização da diferença entre a curva de velocidade do bloco do MIT e a estimada pelo EKF otimizado. O método escolhido para esta FO foi o dos mínimos quadrados e é exibida em (88).

$$FO = \frac{1}{N} \sum_{n=0}^N \left(\omega_{mec_simulada_n} - \omega_{mec_estimada_n} \right)^2 \quad (88)$$

onde: N é o número de pontos utilizados, $\omega_{mec_simulada}$ é a velocidade medida do MIT e $\omega_{mec_estimada}$ é a velocidade estimada pelo filtro.

Posteriormente, foi determinada a configuração paramétrica para cada algoritmo de otimização, os quais são apresentados na Tabela 3. Vale ressaltar que os parâmetros dos métodos de otimização foram determinados de forma empírica. Contudo, para que não houvesse parcialidade com relação ao desempenho, todos os algoritmos foram iniciados com a mesma população inicial de 30 indivíduos e possuíram o mesmo critério de parada, o qual foi definido como o número máximo de 50 iterações.

Tabela 3 – Ajuste paramétrico dos algoritmos de otimização.

FA		PSO		DE		GWO	
β_0	1,00	c_1	2,05	F	0,80	a	2
α_0	1,00	w	0,68				
γ	0,10	c_2	2,05	C_r	0,50		
δ	0,97						

Fonte: Autoria própria.

A comparação entre as respostas dos algoritmos de otimização se deu por meio do fitness, o qual é determinado como o menor valor obtido para a FO e está apresentado na equação (89).

$$fitness = \min FO \quad (89)$$

Com isto, os otimizadores atuaram de forma a encontrar as matrizes de covariância e predição do EKF que possivelmente retornem o menor valor de *fitness* dentro do espaço de busca definido e para o princípio de funcionamento estabelecido para o MIT. Cada tipo de alimentação contou com um determinado princípio de funcionamento para o MIT. No caso da alimentação senoidal, o motor partia a vazio e, em 0,5 s, uma carga de 4 N.m era acrescentada em seu eixo. Já para os casos em alimentação não senoidal, o motor partia a vazio e, em 0,5 s, uma carga de 0,8 N.m era acrescentada ao eixo. Vale ressaltar que para explorar a limitação do desempenho do controle escalar, optou-se por realizar a otimização com uma referência de velocidade em 20% da nominal. A Figura 10 apresenta o arranjo utilizado para esta etapa.

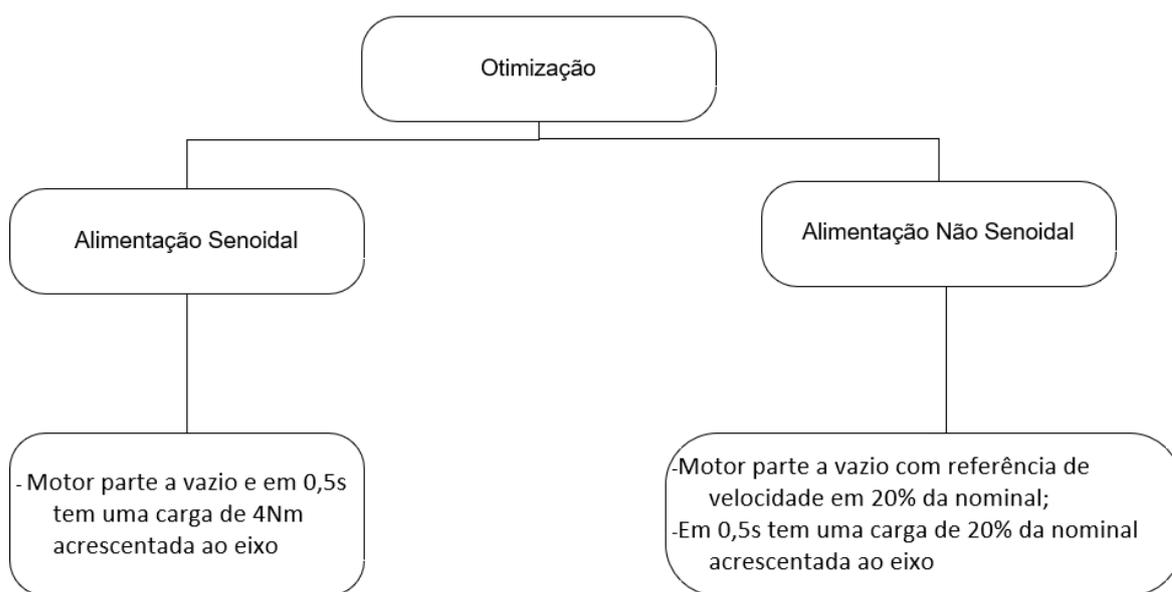
Para validar a robustez dos parâmetros sintonizados pelos otimizadores, testes diferentes do realizado para a etapa de otimização foram executados. Nestes testes, foram considerados entrada e saída de cargas, variação de resistência do rotor e estator, além de diferentes referências de velocidade. A Figura 11 apresenta o arranjo utilizado para esta etapa.

Ainda, o EKF acionado em alimentação senoidal e não senoidal também teve seu desempenho avaliado quanto aos ruídos introduzidos pelos sensores de tensão e corrente. Para isto, os testes foram executados inicialmente ignorando os ruídos provindos dos medidores e, mais tarde, os considerando.

Nos esquemáticos, os ruídos dos medidores foram inseridos por meio de uma fonte de ruído, representada pelo bloco *Random Number*. Tal fonte foi configurada

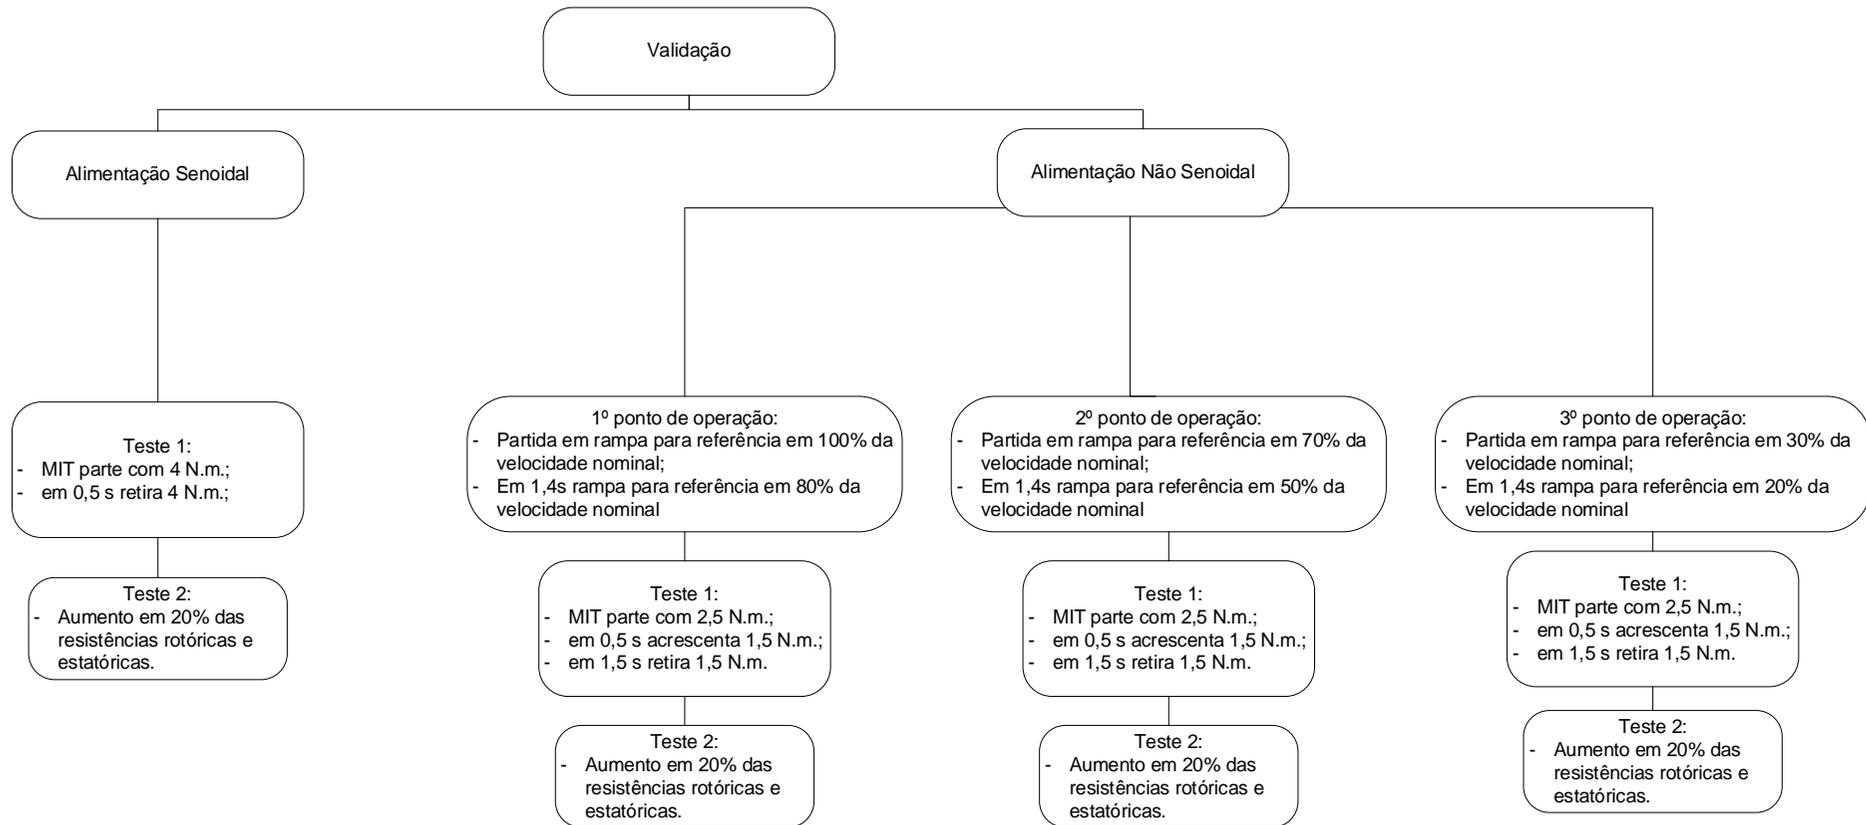
para ter média 0 e variância de 5% para os medidores de tensão e de 10% para os medidores de corrente. Tal diferença entre os medidores se deve aos sensores de corrente medirem por efeito hall (MASCHIO, 2006).

Figura 10 - Arranjo do princípio de funcionamento para a etapa de otimização.



Fonte: Autoria própria.

Figura 11 – Arranjo do princípio de funcionamento para a etapa de validação.



Fonte: Autoria própria.

6 RESULTADOS

Os resultados apresentados nesta seção estão divididos em três partes. A primeira apresenta os resultados referentes à alimentação senoidal, a segunda e a terceira referem-se à alimentação não senoidal com controle escalar em malha aberta e em malha fechada, respectivamente.

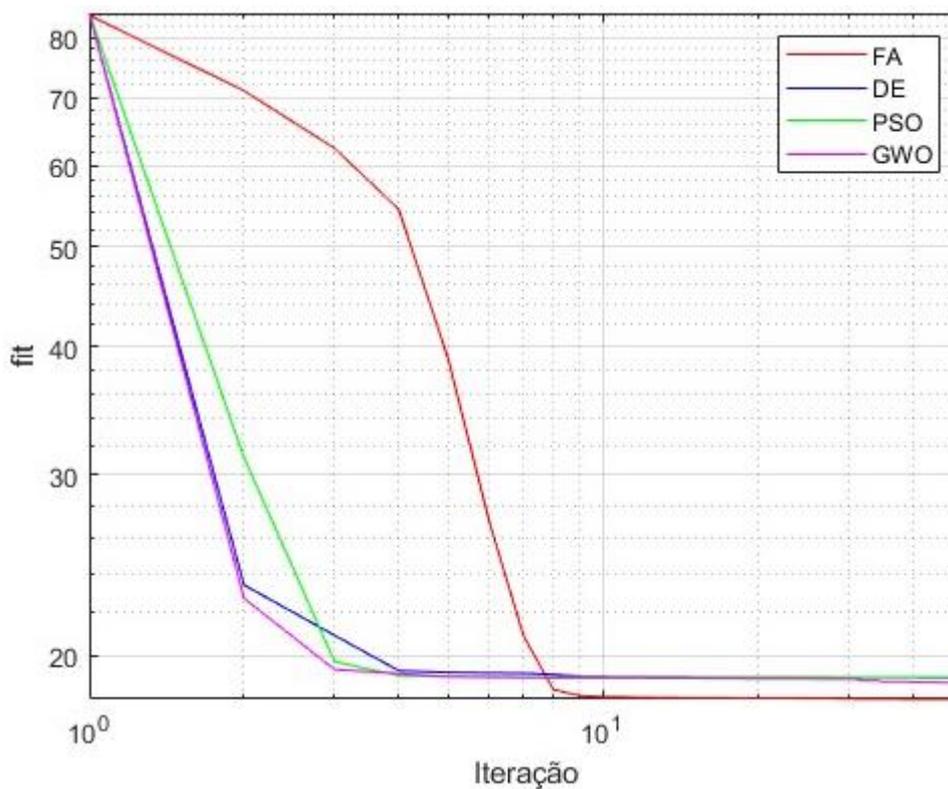
Contudo, para verificar a convergência dos algoritmos otimizadores, realizou-se dez execuções das otimizações, onde cada esquemático contou com a mesma população inicial.

Todas as simulações da fase de otimização foram realizadas com frequência de 1 kHz durante 1 s. Para fase de validação em alimentação senoidal foi mantida a mesma frequência e tempo de simulação. Contudo, para alimentação não senoidal foi necessário estender o tempo de simulação para 2 s, permitindo assim que houvesse variação de velocidade dentro da mesma simulação.

6.1 ALIMENTAÇÃO SENOIDAL

Com o intuito de verificar a convergência dos algoritmos otimizadores, realizou-se dez execuções das otimizações, onde cada execução contou com a mesma população inicial. A Figura 12 apresenta a evolução do *fitness* dos otimizadores, onde o fit para cada iteração foi calculado por meio do valor médio dos *fitness* encontrados nas execuções.

Figura 12 – Evolução do *fitness* dos otimizadores – alimentação senoidal.

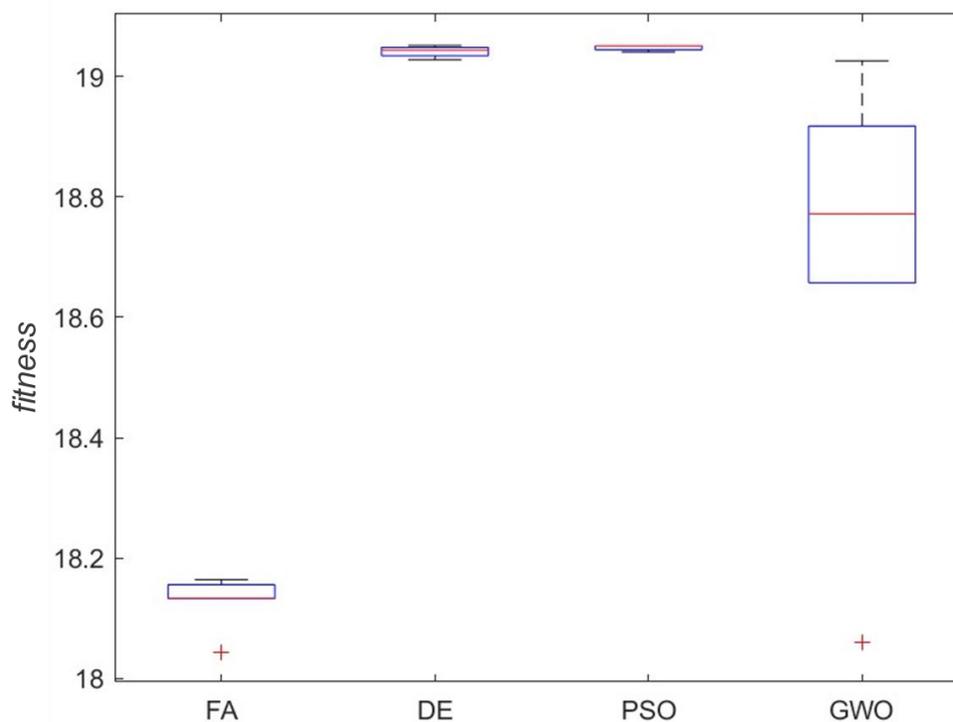


Fonte: Autoria própria.

Como pode ser observado na Figura 12, os otimizadores DE, PSO e GWO encontraram um ponto de convergência ainda nas primeiras iterações e se estabeleceram neste mínimo, tendo pouca ou nenhuma variação ao final das 50 iterações. Em contrapartida, o FA precisou de mais iterações para encontrar um mínimo, contudo, ao final das iterações avaliadas, o otimizador em questão identificou um *fitness* menor do que os demais. De forma geral, é possível observar que os otimizadores convergiram para valores próximos, indicando que possivelmente estavam na região de mínimo local ou, ainda, em um local que demandaria grande desprendimento de energia para encontrar regiões melhores.

Para avaliar a distribuição dos *fitness* encontrados na última iteração das 10 execuções, utilizou-se a ferramenta *boxplot*, a qual tem seus resultados apresentados na Figura 13.

Figura 13 – *Boxplot* dos *fitness* dos algoritmos otimizadores – Execuções da etapa de otimização.



Fonte: Autoria própria.

Analisando apenas o *fitness* encontrado na última iteração, observa-se que o melhor desempenho foi obtido pelo FA, pois tanto sua mediana quanto seus valores mínimo e máximo foram menores que os encontrados para a PSO, DE e GWO. Além disso, observa-se que durante as dez execuções, o FA encontra mínimos melhores, o que demonstra maior estabilidade na convergência. Contudo, nota-se que a PSO e o DE possuem menor variabilidade, ou seja, tendem a se direcionar rapidamente para o mesmo mínimo, ainda que este não seja o melhor mínimo já identificado para o problema. Ao contrário da PSO, DE e FA, o GWO apresentou maior variabilidade e em um *outlier* encontrou um mínimo próximo ao melhor mínimo identificado.

Avaliando as 10 execuções da etapa de otimização foi possível identificar quais os menores valores de *fitness* encontrados pelos algoritmos otimizadores, apresentados na Tabela 4. Além disso, também foi incorporado na tabela em questão o valor de *fitness* encontrado para o EKF parametrizado pelo melhor indivíduo da população inicial.

Tabela 4 – Melhor *fitness* dos algoritmos otimizadores em alimentação senoidal– Execuções da etapa de otimização.

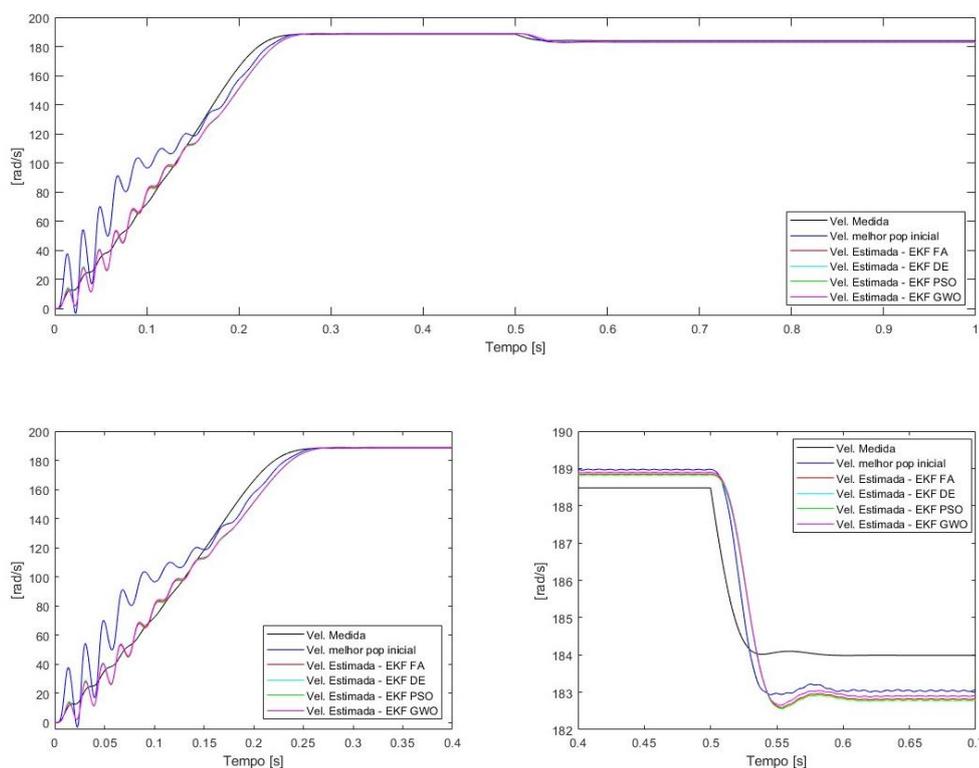
	INICIAL	FA	PSO	DE	GWO
Execução	-	5	5	3	6
<i>fitness</i>	84,53	18,0431	19,0408	19,0280	18,0605

Fonte: Autoria própria.

Por meio da Tabela 4 é possível perceber que o otimizador de melhor desempenho foi o FA, contudo, nota-se que todos os otimizadores fornecem resultados melhores do que o identificado na população inicial.

De maneira qualitativa, as curvas estimadas que resultaram no valor dos *fitness* da Tabela 4 podem ser observadas na Figura 14, onde percebe-se que as curvas estimadas pelo EKF otimizado se tornaram mais próximas à velocidade medida desde o regime transitório.

Figura 14 – Teste de otimização com alimentação senoidal.



Fonte: Autoria própria.

Os parâmetros das matrizes de covariância do EKF que retornaram os valores de *fitness* da Tabela 4 estão apresentados na Tabela 5.

Tabela 5 – Parâmetros obtidos por meio dos otimizadores para o melhor *fitness* – alimentação senoidal.

Parâmetro	Valor FA	Valor PSO	Valor DE	Valor GWO
p_{11}	$1,00 \cdot 10^{-5}$	$8,17 \cdot 10^{-6}$	$5,20 \cdot 10^{-6}$	$5,16 \cdot 10^{-6}$
q_{11}	$1,00 \cdot 10^{-2}$	$1,00 \cdot 10^{-2}$	$1,00 \cdot 10^{-2}$	$1,00 \cdot 10^{-2}$
q_{33}	$1,00 \cdot 10^{-11}$	$8,23 \cdot 10^{-4}$	$1,00 \cdot 10^{-3}$	$1,00 \cdot 10^{-11}$
q_{55}	$3,62 \cdot 10^{-1}$	$3,74 \cdot 10^0$	$2,54 \cdot 10^0$	$1,38 \cdot 10^{-1}$
r_{11}	$7,59 \cdot 10^2$	$7,60 \cdot 10^3$	$5,13 \cdot 10^3$	$2,81 \cdot 10^2$

Fonte: Autoria própria.

Ao analisar os parâmetros obtidos pelos otimizadores percebe-se que o q_{11} retornou o mesmo valor para o FA, PSO, DE e GWO, o que pode indicar que este é o melhor valor encontrado dentro do espaço de busca para este parâmetro. Ainda, percebe-se que este parâmetro se estabilizou no limite superior do espaço de busca, o que pode indicar a necessidade em se expandir o espaço de busca para o parâmetro em questão. Além disso, o parâmetro q_{33} também se estabeleceu no limite superior do espaço de busca para os *fitness* dos otimizadores que retornaram melhor desempenho, o que indica que para este espaço de busca e condição avaliada este é o melhor valor, ou ainda, que é necessário a expansão do espaço de busca.

Os conjuntos de parâmetros que retornaram os melhores valores de *fitness* foram aplicados aos testes de validação. Este processo foi necessário para que a robustez do estimador otimizado fosse averiguada quando o MIT estivesse submetido à variação do conjugado de carga e de suas resistências (rotor e estator). Os *fitness* provenientes dos testes de validação com os parâmetros apresentados na Tabela 5 são exibidos na Tabela 6.

Tabela 6 – *Fitness* dos algoritmos de otimização para os testes de validação – alimentação senoidal.

Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído								
1º teste	210,24	311,12	70,00	115,61	72,41	119,30	72,35	119,20	70,46	118,93
2º teste	291,92	425,83	129,01	208,25	132,78	213,63	132,67	213,46	131,77	211,56

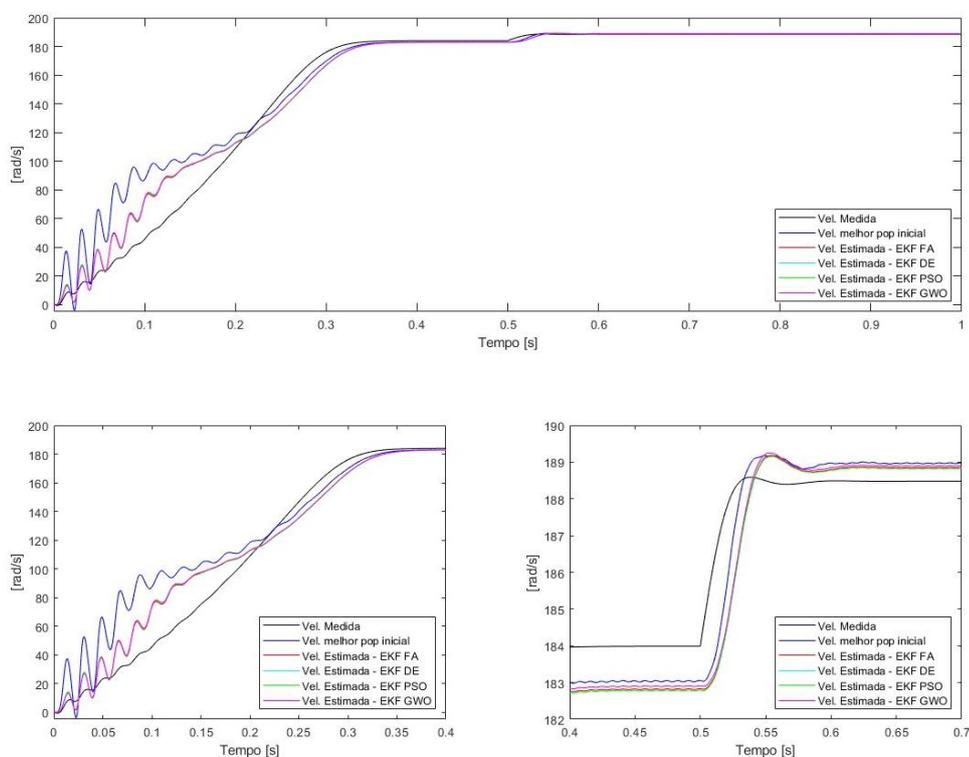
Fonte: Autoria própria.

Observando a Tabela 6 pode-se perceber que de forma geral o desempenho dos EKF otimizados foram superiores ao EKF com os ajustes paramétricos do melhor

indivíduo da população inicial. Além disso, comparando os *fitness* provenientes dos algoritmos otimizadores, percebe-se a mesma tendência do teste de otimização, onde o FA e o GWO retornaram melhores valores de *fitness*. Ainda, percebe-se que o EKF otimizado manteve desempenho superior ao da população inicial quando submetido a ruído e variação das resistências da máquina. Contudo o ruído degradou o desempenho do EKF otimizado, o que fez com que houvesse um aumento do valor do *fitness*. Esta análise é complementada ao observar a Figura 15, Figura 16, Figura 17 e Figura 18.

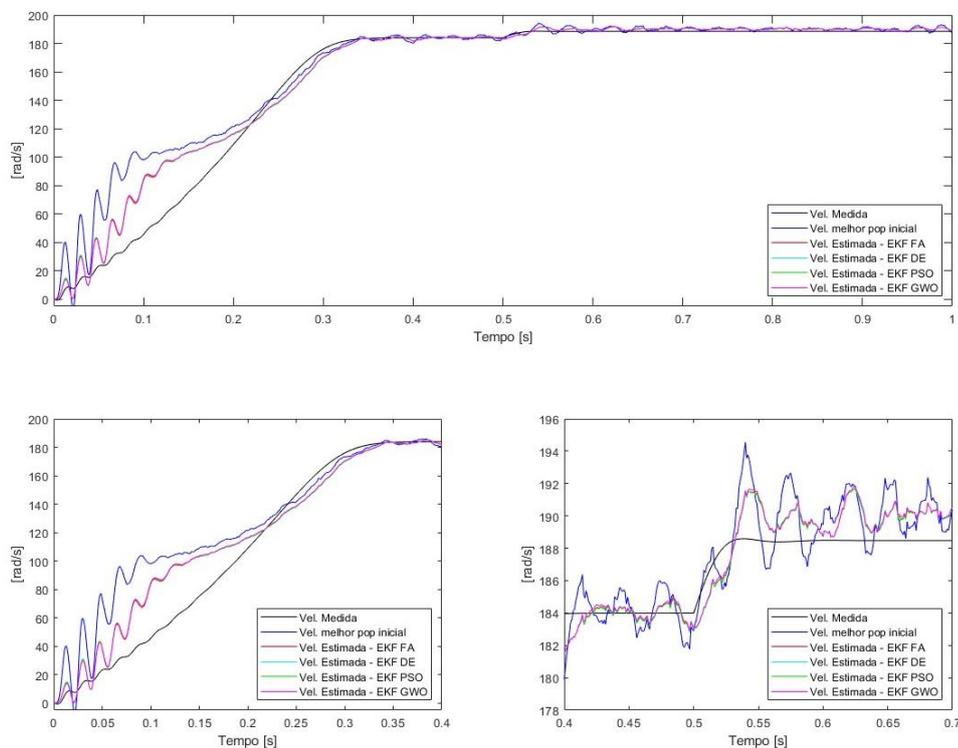
Ainda, quando compara-se os *fitness* exibidos na Tabela 4 com os da Tabela 6 e a Figura 14 com a Figura 15, percebe-se que para o primeiro teste, houve um aumento do valor do *fitness* e a curva estimada se tornou distante da real no período transitório. Este comportamento ocorreu devido a inversão de entrada e saída de carga do teste de otimização para o primeiro teste de validação.

Figura 15 – 1º teste da fase de validação com alimentação senoidal, sem alteração de resistências e sem ruído.



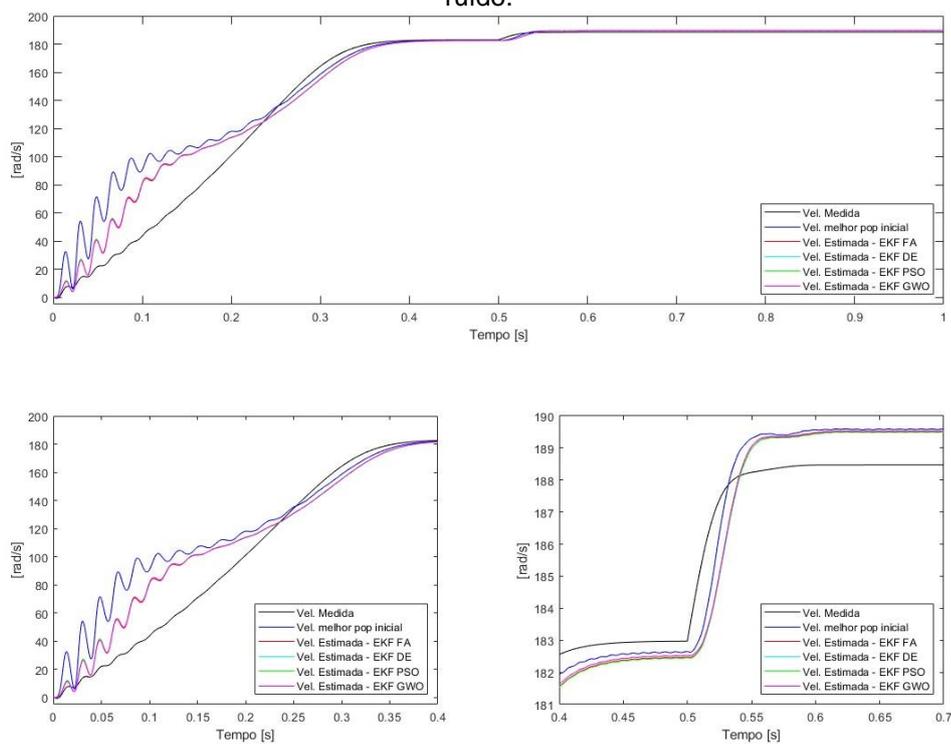
Fonte: Autoria própria.

Figura 16 - 1º teste da fase de validação com alimentação senoidal, sem alteração de resistências e com ruído.



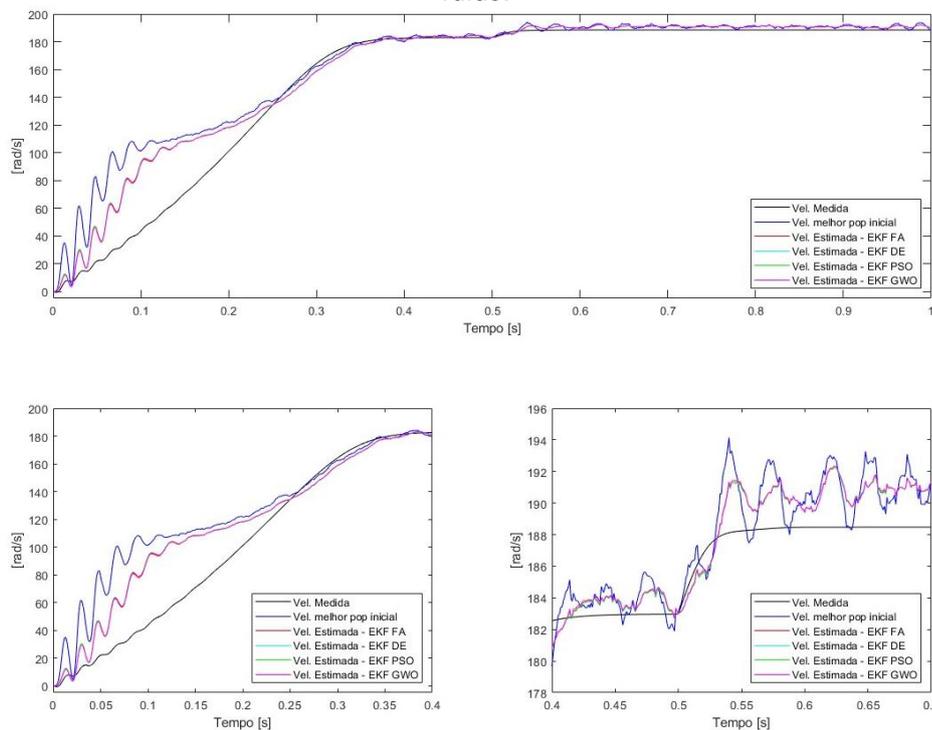
Fonte: Autoria própria.

Figura 17 - 2º teste da fase de validação com alimentação senoidal com $R_1+20\%$ e $R_2+20\%$ e sem ruído.



Fonte: Autoria própria.

Figura 18 - 2º teste da fase de validação com alimentação senoidal com $R_1 +20\%$ e $R_2 +20\%$ e com ruído.

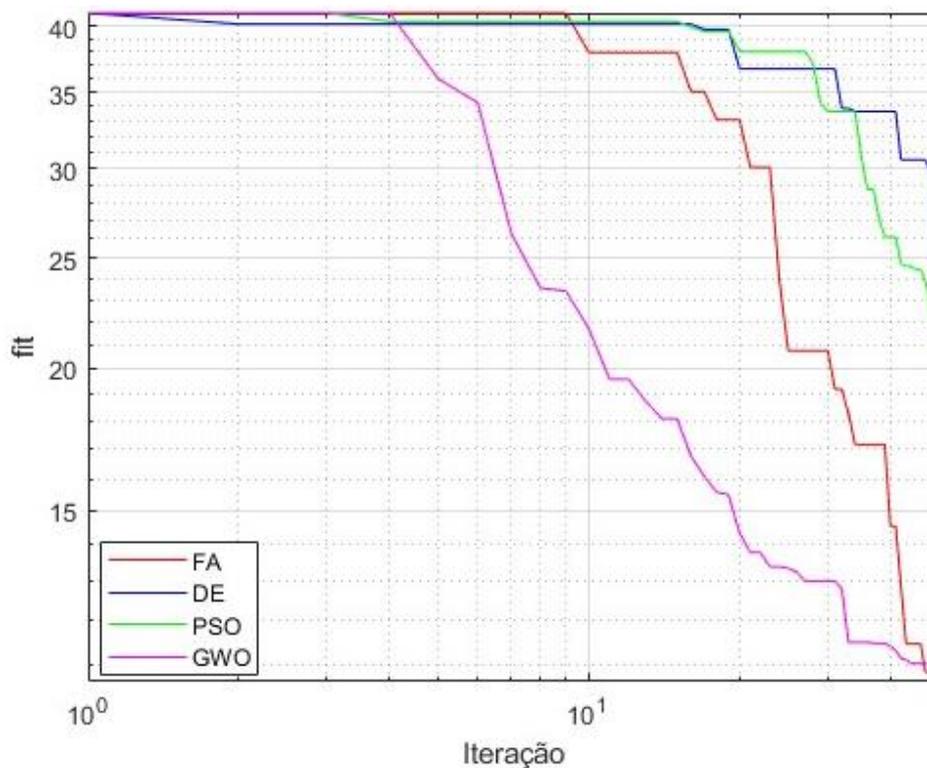


Fonte: Autoria própria.

Observando as Figura 15, Figura 16, Figura 17 e Figura 18, percebe-se que a velocidade estimada pelo EKF otimizado retornou uma curva mais próxima à medida, desde o regime transitório, quando comparado ao EKF com o melhor indivíduo da população inicial. O mesmo comportamento foi observado para os testes com alteração de resistência e consideração dos ruídos medidores.

6.2 ALIMENTAÇÃO NÃO SENOIDAL COM CONTROLE EM MALHA ABERTA

Uma nova otimização foi realizada para a alimentação não senoidal com controle escalar em malha aberta, onde a velocidade de referência foi mantida em 20% da nominal. Assim como em alimentação senoidal, foi verificado em malha aberta o comportamento do *fitness* durante as iterações. Para isto, aplicou-se a média dos *fitness* das dez execuções, a qual é exibida na Figura 19. Vale ressaltar que todos os otimizadores nas dez execuções partiram da mesma população inicial.

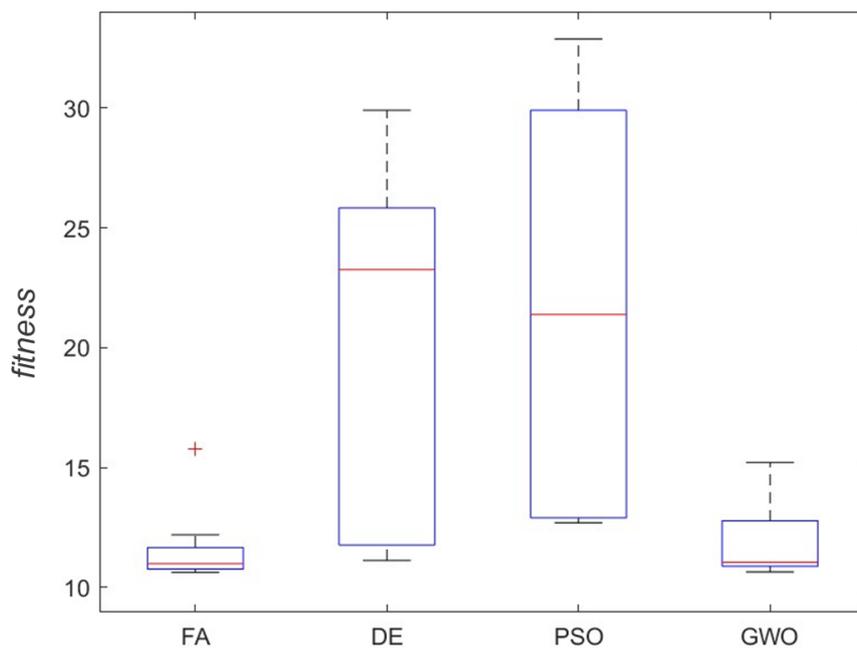
Figura 19 - Evolução do *fit* dos otimizadores – malha aberta.

Fonte: Autoria própria.

Como pode ser observado na Figura 19, os otimizadores DE, PSO e GWO iniciam seu processo de evolução ainda nas primeiras 9 iterações, ao contrário do FA, que precisou de 10 iterações para começar a progredir. Apesar disto, nas próximas 40 iterações, o FA conseguiu apresentar uma evolução superior ao DE e a PSO, se juntando ao GWO na região do melhor mínimo médio encontrado. Ainda, pode-se perceber que possivelmente a quantidade de iterações estipulada para a otimização não foi suficiente para que o DE e a PSO convergissem para a mesma região encontrada pelo FA e GWO.

Para avaliar a distribuição dos *fitness* encontrados na iteração final das 10 execuções, utilizou-se a ferramenta *boxplot*, a qual tem seus resultados apresentados na Figura 20.

Figura 20 - *Boxplot* dos *fitness* dos algoritmos otimizadores – Execuções da etapa de otimização em malha aberta.



Fonte: Autoria própria.

Analisando apenas o *fitness* encontrado na última iteração, observa-se que o melhor desempenho foi obtido pelo FA, pois tanto sua mediana, quanto seus valores mínimo e máximo foram menores do que os encontrados para a PSO, DE e GWO. Além disso, percebe-se que o DE e PSO tiveram maior variabilidade quando comparado ao FA e ao GWO, o que pode confirmar a necessidade de uma maior quantidade de iterações, conforme analisado no teste de convergência. Contudo, nota-se que o FA, o DE e o GWO, ao menos em uma execução, chegaram na mesma região de mínimo, o que pode indicar que para o espaço de busca analisado, este seria o mínimo global para a otimização em questão.

Avaliando as dez execuções da etapa de otimização foi possível identificar os menores valores de *fitness* encontrados pelos algoritmos otimizadores, onde estes valores são apresentados na Tabela 7. Além disso, também foi incorporado na tabela em questão o valor de *fitness* encontrado para o EKF otimizado pelo conjunto do melhor indivíduo da população inicial.

Tabela 7 – Melhor *fitness* dos algoritmos otimizadores – Execuções da etapa de otimização em malha aberta.

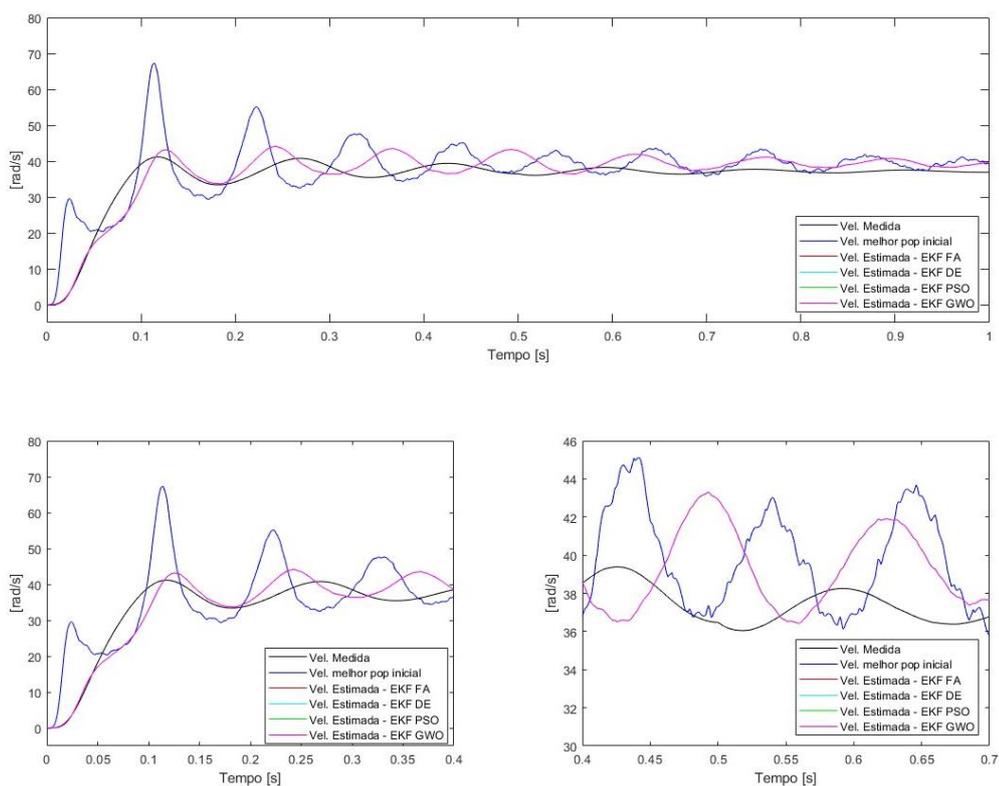
	INICIAL	FA	PSO	DE	GWO
Execução	-	3	8	8	1
<i>fitness</i>	41,0684	10,6183	12,6897	10,7237	10,6373

Fonte: Autoria própria.

De maneira qualitativa, as curvas estimadas que resultaram no valor dos *fitness* da Tabela 7 podem ser observadas na Figura 21, onde percebe-se que as curvas estimadas pelo EKF otimizado se tornaram mais próximas a velocidade medida desde o regime transitório.

Os parâmetros das matrizes de covariância do EKF que retornaram os valores de *fitness* da Tabela 7 estão apresentados na Tabela 8.

Figura 21 - Teste de otimização com alimentação não senoidal – malha aberta.



Fonte: Autoria própria.

Tabela 8 – Parâmetros obtidos por meio dos otimizadores para o melhor *fitness*.

Parâmetro	Valor FA	Valor PSO	Valor DE	Valor GWO
p_{11}	$1,00 \cdot 10^{-5}$	$1,00 \cdot 10^{-5}$	$2,23 \cdot 10^{-6}$	$9,62 \cdot 10^{-6}$
q_{11}	$1,00 \cdot 10^{-10}$	$1,00 \cdot 10^{-10}$	$1,00 \cdot 10^{-10}$	$1,00 \cdot 10^{-10}$
q_{33}	$1,00 \cdot 10^{-11}$	$4,7 \cdot 10^{-4}$	$1,00 \cdot 10^{-3}$	$1,21 \cdot 10^{-4}$
q_{55}	$1,32 \cdot 10^{-1}$	$5,48 \cdot 10^{-1}$	$2,64 \cdot 10^{-1}$	$5,19 \cdot 10^{-1}$
r_{11}	$2,39 \cdot 10^3$	$1,00 \cdot 10^4$	$4,80 \cdot 10^3$	$9,41 \cdot 10^3$

Fonte: Autoria própria.

Ao analisar os parâmetros obtidos pelos otimizadores percebe-se que assim como na otimização em alimentação senoidal, o q_{11} retornou o mesmo valor para o FA, PSO, DE e GWO. Este comportamento pode indicar que este é o melhor valor encontrado dentro do espaço de busca ou ainda, que para o tipo de problema em questão é necessário que o espaço de busca deste parâmetro seja ampliado.

Os conjuntos de parâmetros que retornaram os melhores valores de *fitness* foram aplicados aos testes de validação. Este processo foi necessário para que a robustez do estimador otimizado fosse averiguada, quando o MIT estivesse submetido à variação do conjugado de carga e de suas resistências (rotor e estator), e a máquina operando em outras faixas de velocidade.

Os *fitness* provenientes dos testes de validação considerando o EKF com os parâmetros apresentados na Tabela 8 são exibidos na Tabela 9, onde também são apresentados os valores encontrados quando os ruídos dos medidores são incluídos na simulação.

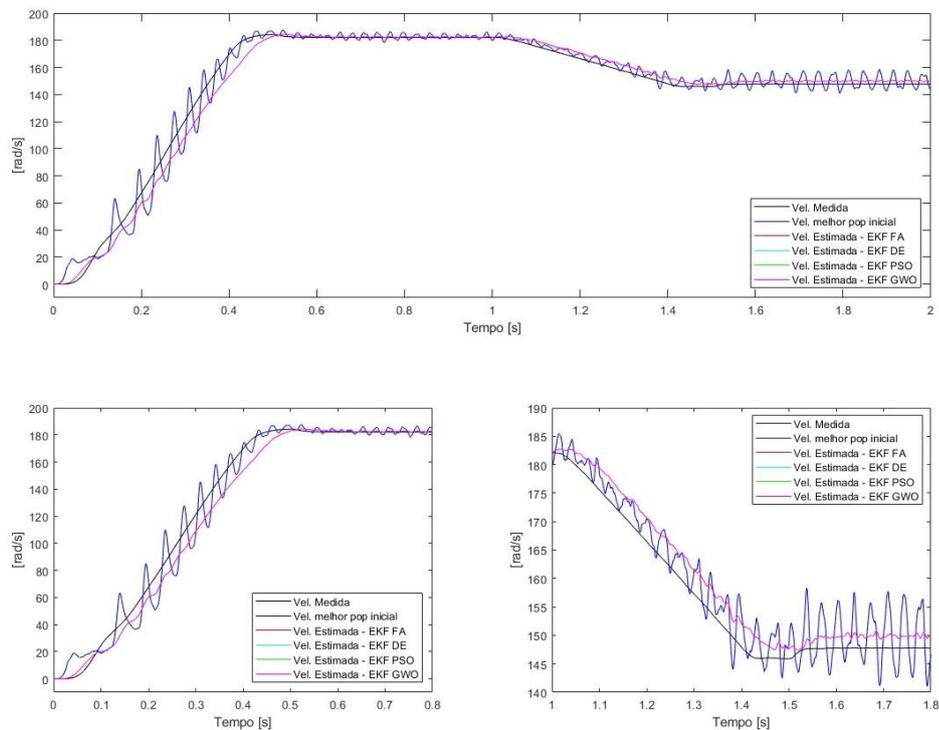
Tabela 9 – *Fitness* dos algoritmos de otimização para os testes de validação em malha aberta.

Primeiro Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	45,25	49,12	31,32	32,14	31,87	32,28	31,77	32,17	31,73	32,13
2º teste	80,58	84,28	33,45	34,05	33,57	34,18	33,48	35,57	33,44	35,53
Segundo Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	294,33	303,64	15,20	15,60	15,24	15,63	15,21	15,61	15,21	15,61
2º teste	449,66	465,70	16,94	17,59	16,97	17,62	16,95	17,60	16,94	17,59
Terceiro Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	71,78	73,06	12,80	12,82	12,83	12,85	12,82	12,87	12,82	12,85
2º teste	127,96	128,51	14,49	14,55	14,51	14,57	14,51	14,58	14,52	14,56

Fonte: Autoria própria.

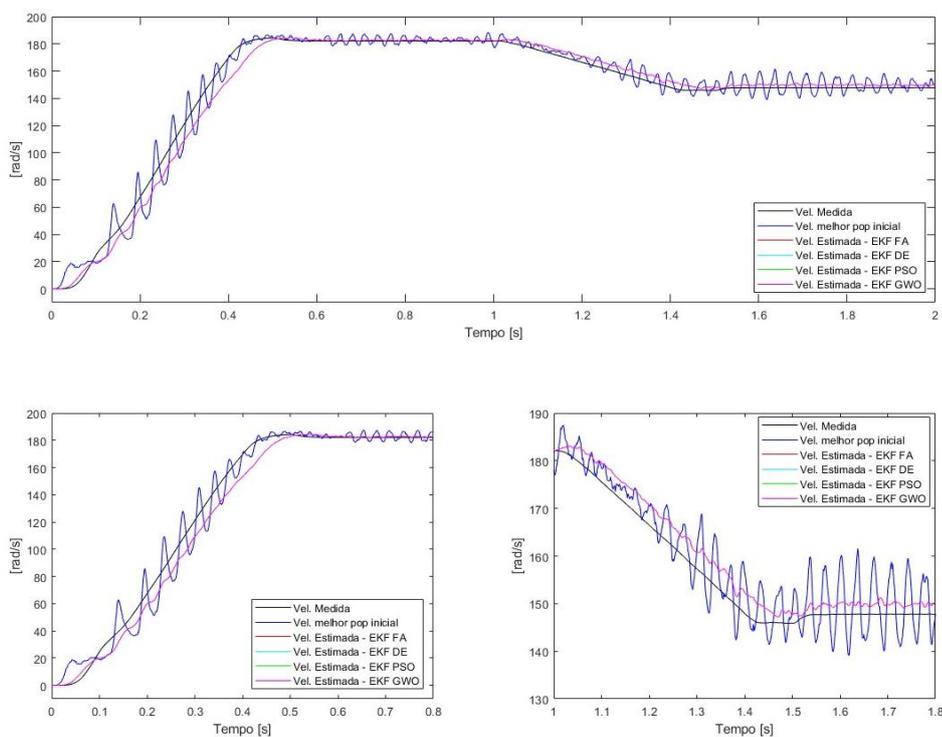
Observando a Tabela 9 pode-se perceber que o desempenho do EKF otimizado foi superior ao EKF com os ajustes paramétricos do melhor indivíduo da população inicial. Além disso, comparando os *fitness* provenientes dos algoritmos otimizadores, percebe-se a mesma tendência do teste de otimização, onde o FA e o GWO retornaram melhores valores de *fitness*. Ainda, nota-se que diferente do teste em alimentação senoidal, em malha aberta, o EKF otimizado manteve desempenho próximo considerando ou não os ruídos provenientes dos medidores de tensão e corrente. Essa análise é complementada ao observar a Figura 22, Figura 23, Figura 24, Figura 25, Figura 26, Figura 27, Figura 28, Figura 29, Figura 30, Figura 31, Figura 32 e Figura 33.

Figura 22 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha aberta.



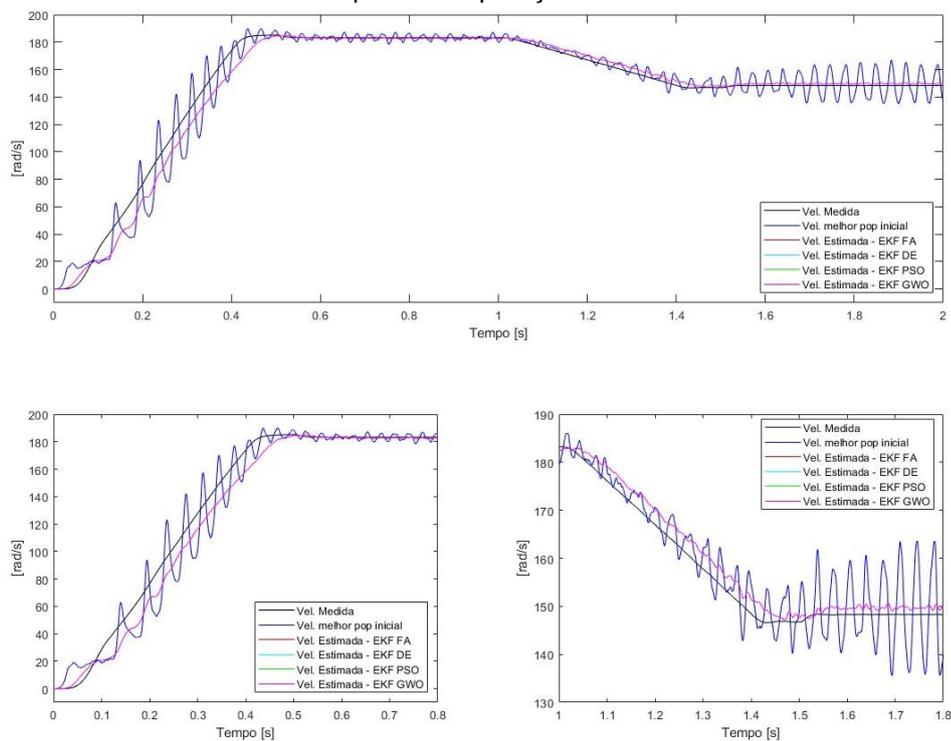
Fonte: Autoria própria.

Figura 23 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha aberta.



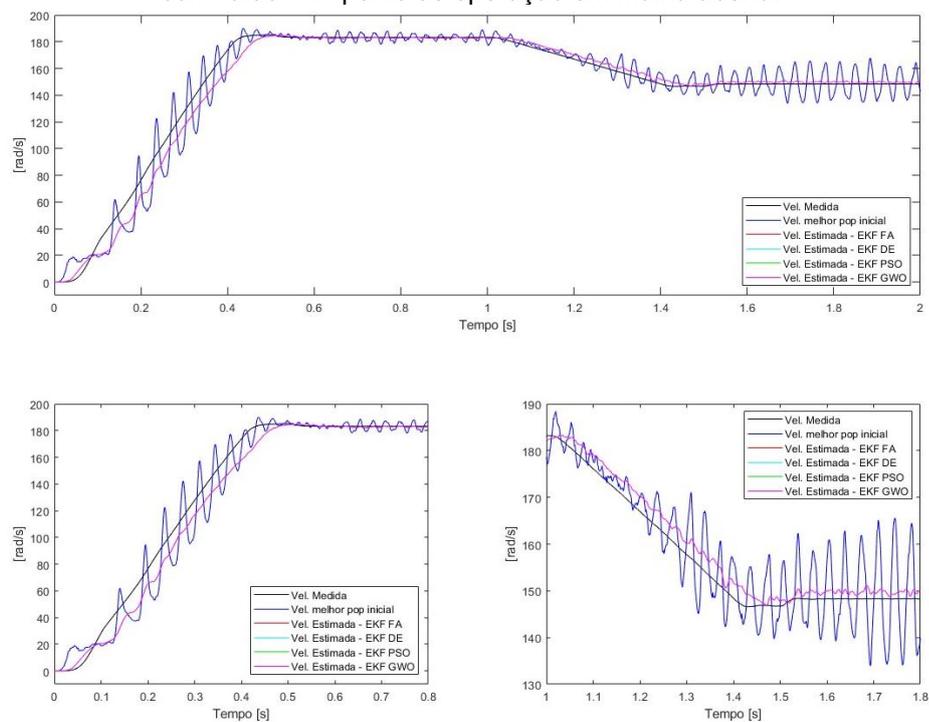
Fonte: Autoria própria.

Figura 24 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha aberta.



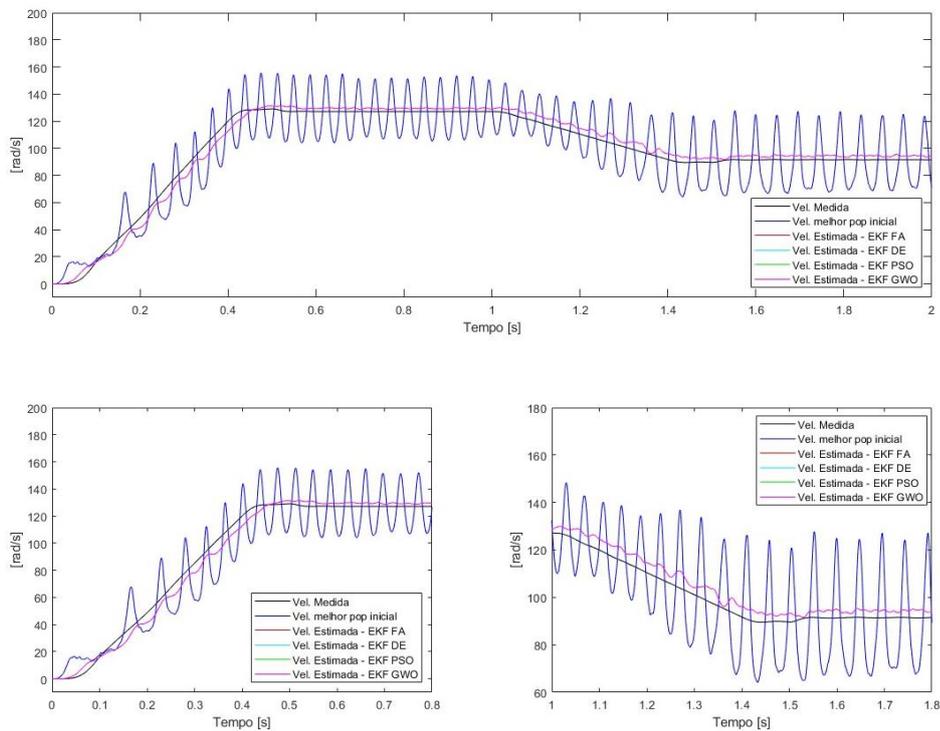
Fonte: Autoria própria.

Figura 25 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha aberta.



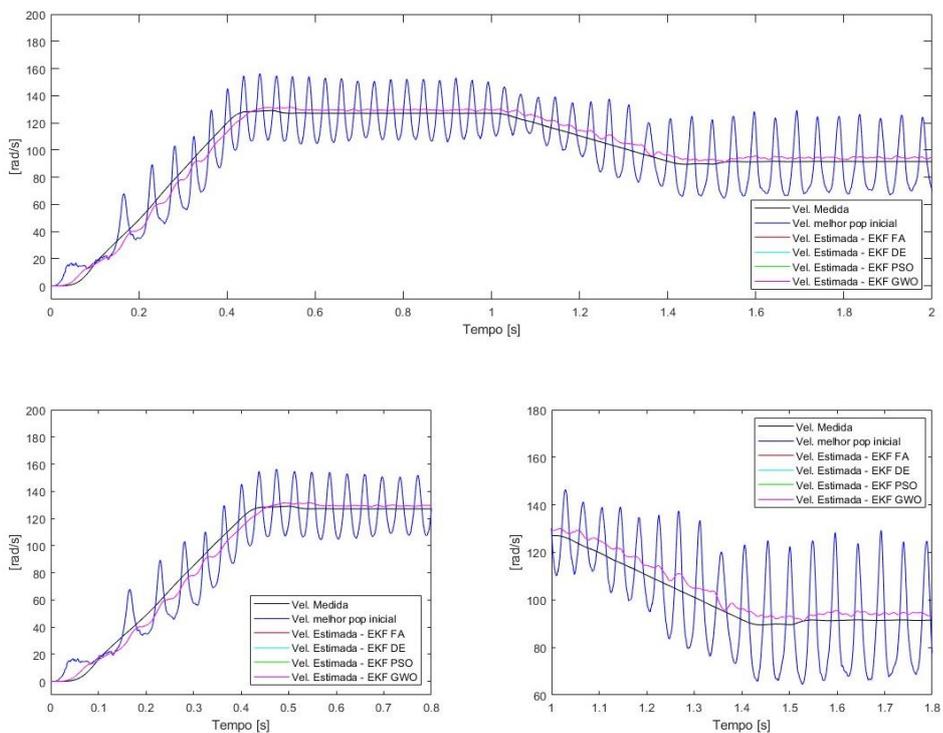
Fonte: Autoria própria.

Figura 26 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha aberta.



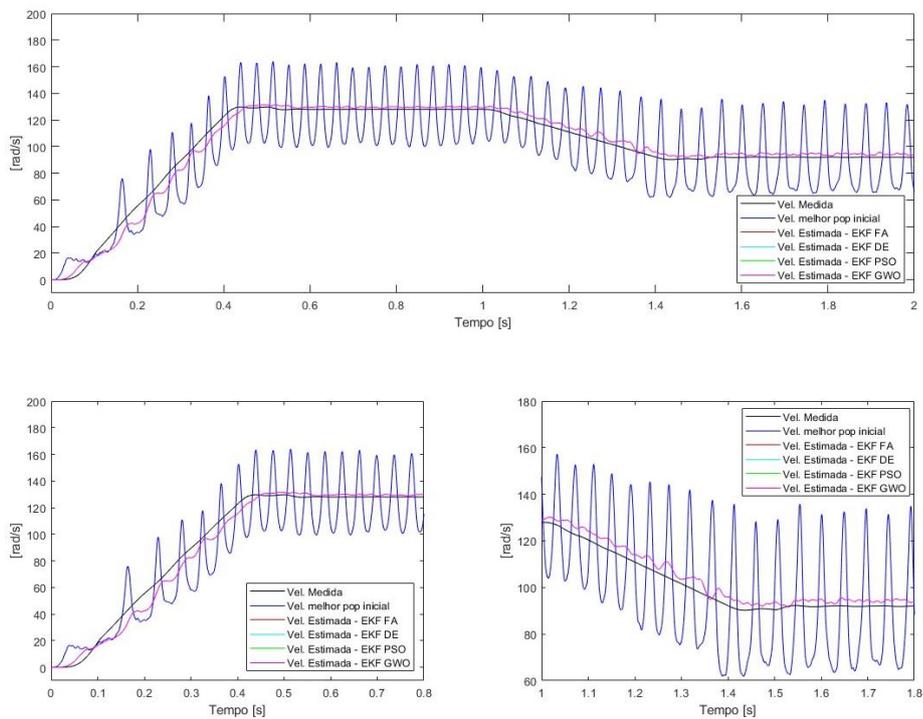
Fonte: Autoria própria.

Figura 27 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha aberta.



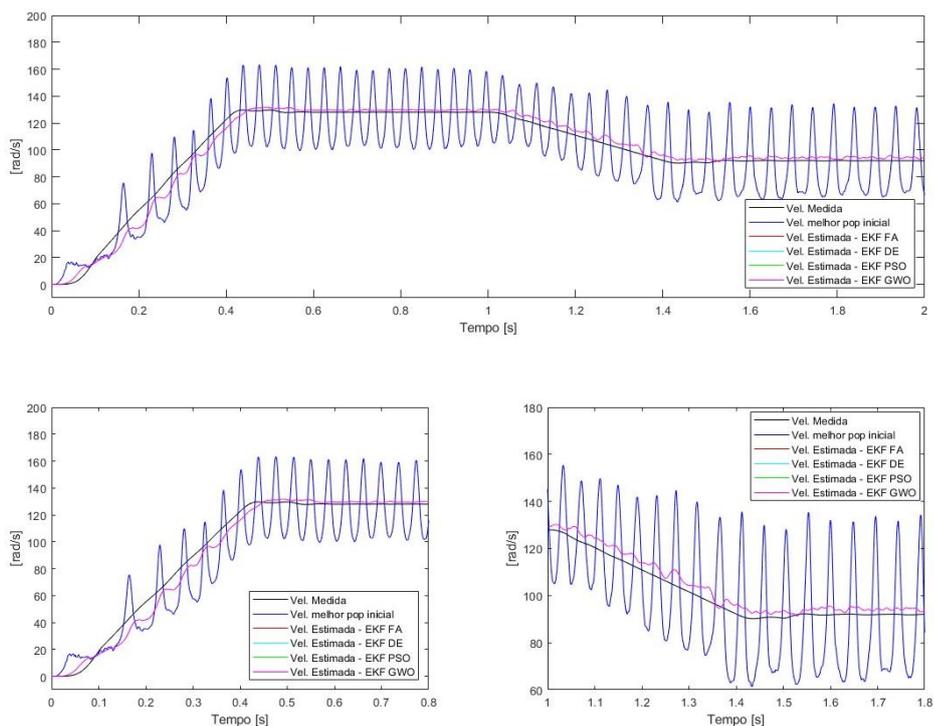
Fonte: Autoria própria.

Figura 28 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha aberta.



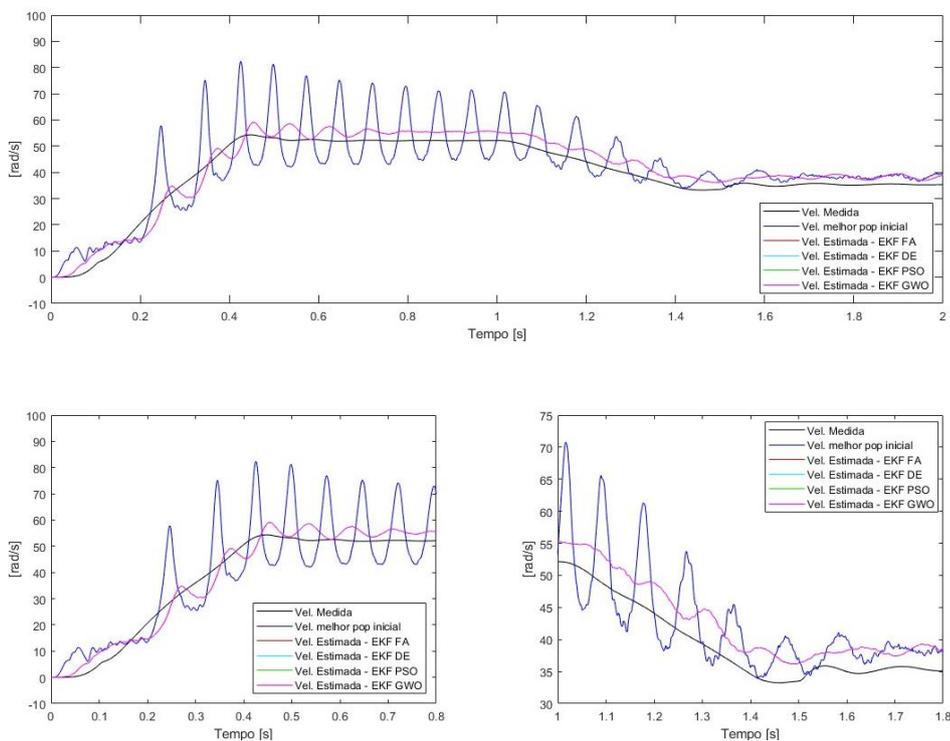
Fonte: Autoria própria.

Figura 29 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha aberta.



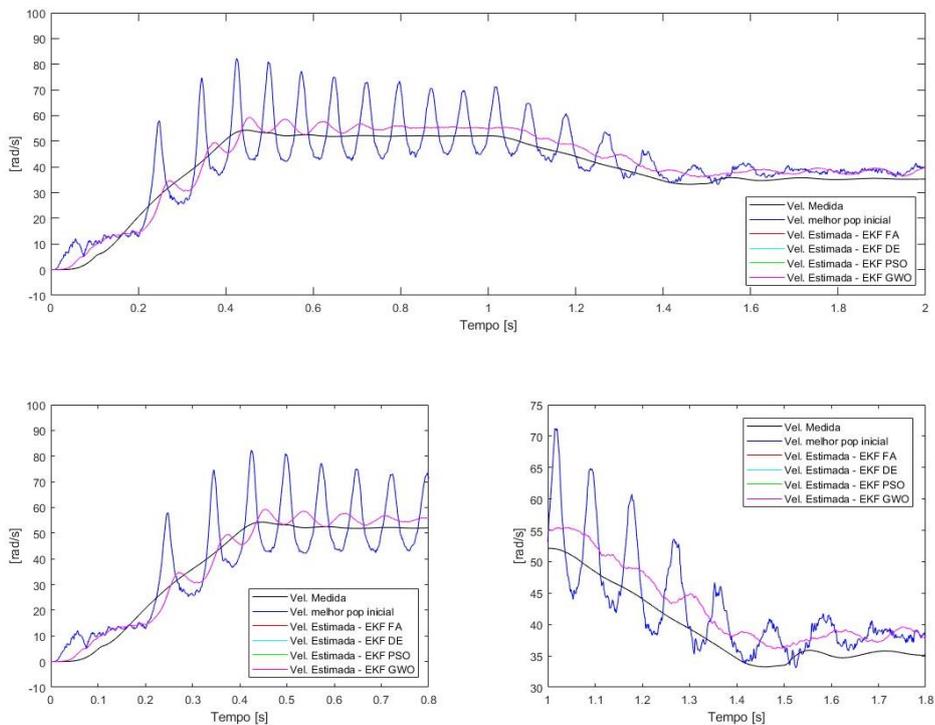
Fonte: Autoria própria.

Figura 30 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha aberta.



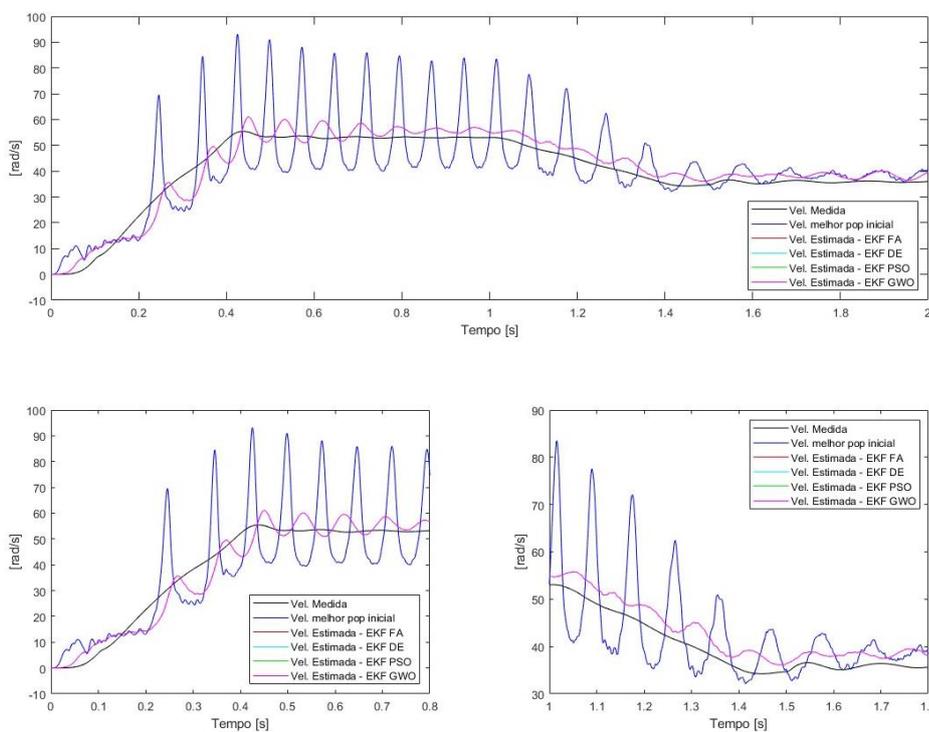
Fonte: Autoria própria.

Figura 31 - 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha aberta.



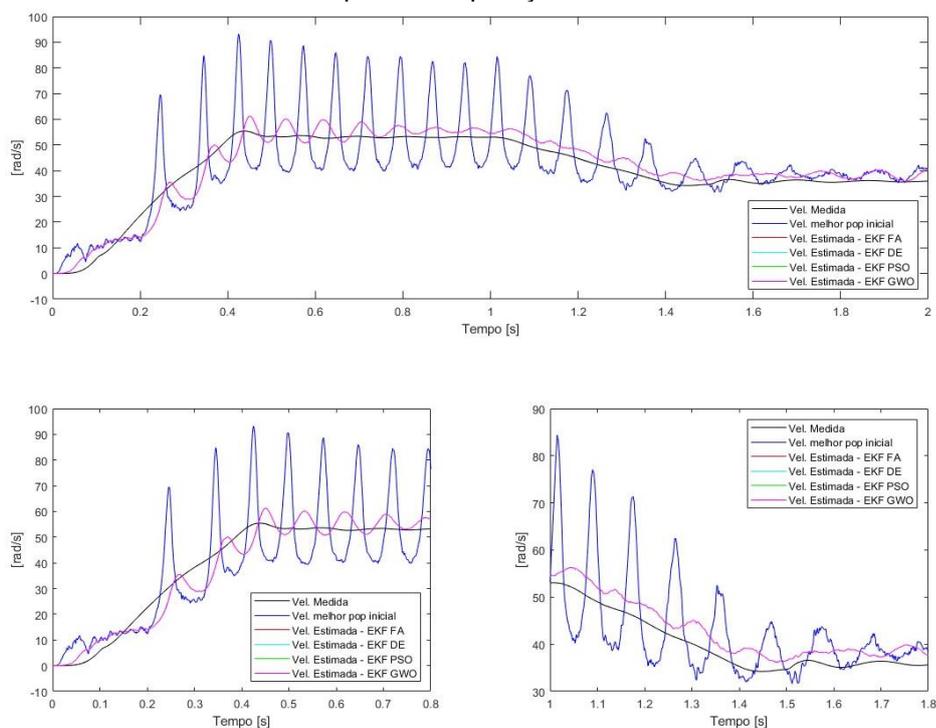
Fonte: Autoria própria.

Figura 32 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha aberta.



Fonte: Autoria própria.

Figura 33 – 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha aberta.



Fonte: Autoria própria.

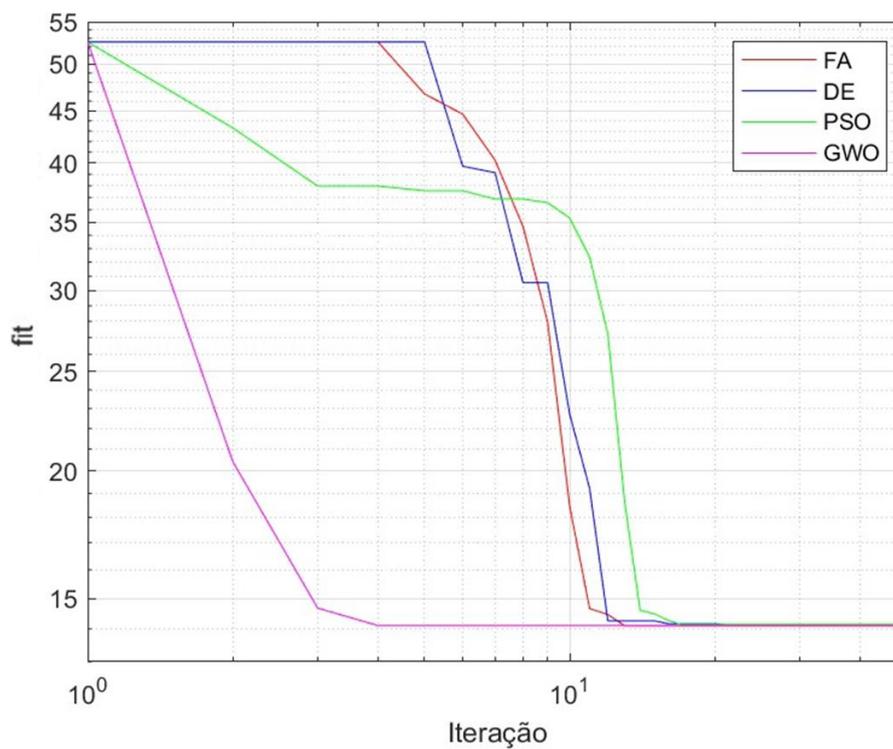
Observando a Figura 22, Figura 23, Figura 24, Figura 25, Figura 26, Figura 27, Figura 28, Figura 29, Figura 30, Figura 31, Figura 32 e Figura 33, percebe-se que a velocidade estimada pelo EKF otimizado retornou uma curva mais próxima à medida, desde o regime transitório, quando comparado ao EKF com o melhor indivíduo da população inicial. O mesmo comportamento foi observado para os testes com alteração de resistência e consideração dos ruídos dos medidores.

6.3 ALIMENTAÇÃO NÃO SENOIDAL COM CONTROLE EM MALHA FECHADA

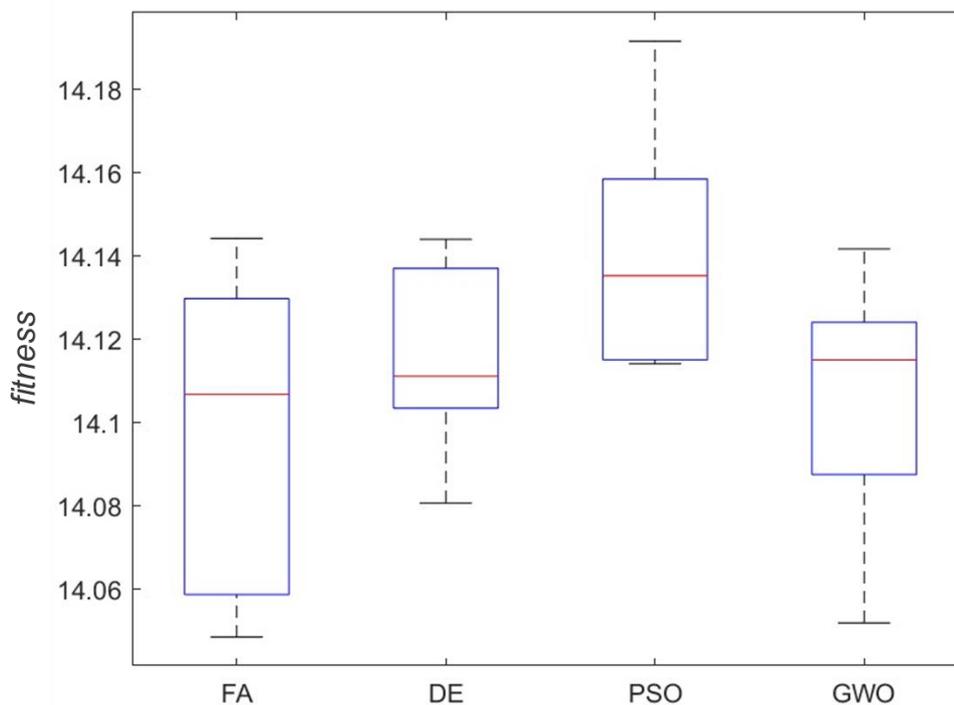
Uma nova otimização foi realizada para a alimentação não senoidal com controle escalar em malha fechada, onde a velocidade de referência foi mantida em 20% da nominal. Assim como em alimentação senoidal e malha aberta, foi verificado em malha fechada o comportamento do *fitness* durante as iterações. Para isso, aplicou-se a média dos *fitness* das dez execuções, a qual é exibida em função das iterações na Figura 34. Vale ressaltar que todos os otimizadores nas dez execuções partiram da mesma população inicial.

Como pode ser observado na Figura 34, os otimizadores iniciam seu processo de evolução ainda nas primeiras 5 iterações. Contudo, o GWO apresentou maior agilidade na busca pelo mínimo e o encontrou antes que o DE e o FA iniciassem o processo de convergência.

Para avaliar a distribuição dos *fitness* encontrados na iteração final das 10 execuções, utilizou-se a ferramenta *boxplot*, a qual tem seus resultados apresentados na Figura 35.

Figura 34 - Evolução do *fit* dos otimizadores – malha fechada.

Fonte: Autoria própria.

Figura 35 - *Boxplot* dos *fitness* dos algoritmos otimizadores – Execuções da etapa de otimização em malha fechada.

Fonte: Autoria própria.

Analisando apenas o *fitness* encontrado na última iteração das dez execuções, observa-se que o melhor desempenho foi obtido pelo FA e pelo GWO, pois tanto sua mediana, quanto seus valores mínimo e máximo foram menores do que os encontrados para a PSO e DE. Ainda, pode-se perceber que a mediana da distribuição do FA foi menor que do GWO, indicando que o primeiro e segundo quartil dos *fitness* encontrados pelo FA são melhores que do GWO.

Avaliando as dez execuções da etapa de otimização foi possível identificar os menores valores de *fitness* encontrados pelos algoritmos otimizadores, onde estes valores são apresentados na Tabela 10. Além disso, também foi incorporado na tabela em questão o valor de *fitness* encontrado para o EKF otimizado pelo conjunto do melhor indivíduo da população inicial.

Tabela 10 – Melhor *fitness* dos algoritmos otimizadores – Execuções da etapa de otimização em malha fechada.

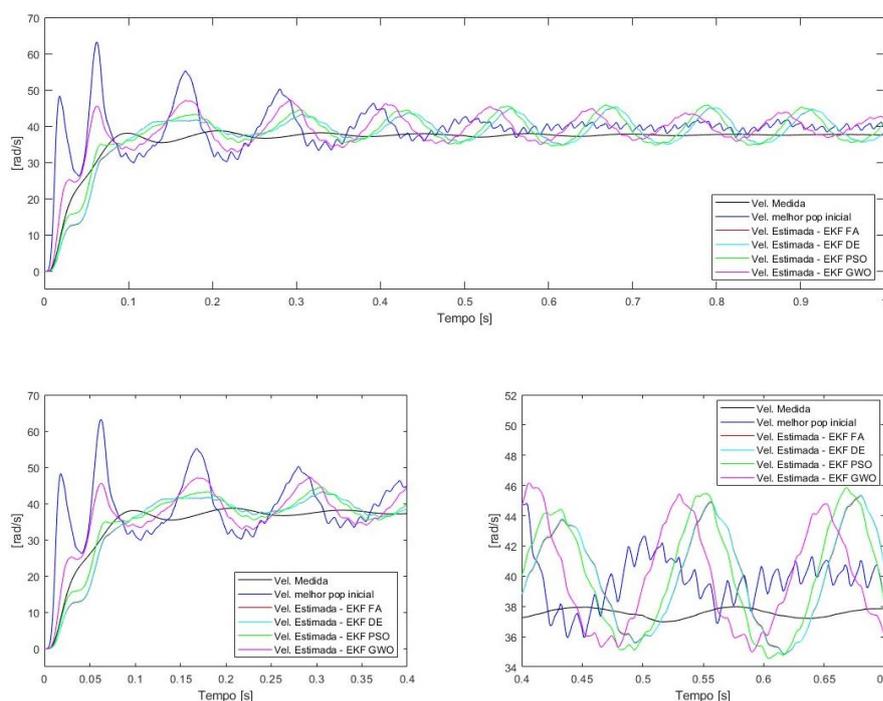
	INICIAL	FA	PSO	DE	GWO
Execução	-	8	9	1	9
<i>fitness</i>	52,55	14,05	14,09	14,16	14,05

Fonte: Autoria própria.

De maneira qualitativa, as curvas estimadas que resultaram no valor dos *fitness* da Tabela 7 podem ser observadas na Figura 36, onde pode-se perceber que as curvas estimadas pelo EKF otimizado se tornaram mais próximas a velocidade medida desde o regime transitório.

Vale ressaltar que no teste de otimização, a velocidade medida via *encoder* foi utilizada como realimentação para o controle em malha fechada, assim, o objetivo da etapa de otimização era tornar a velocidade estimada mais próxima da velocidade medida.

Figura 36 - Teste de otimização com alimentação não senoidal – malha fechada.



Fonte: Autoria própria.

Os parâmetros das matrizes de covariância do EKF que retornaram os valores de *fitness* da Tabela 10 estão apresentados na Tabela 11.

Tabela 11 – Parâmetros obtidos por meio dos otimizadores para o melhor *fitness* – malha fechada.

Parâmetro	Valor FA	Valor PSO	Valor DE	Valor GWO
p_{11}	$1,00 \cdot 10^{-5}$	$1,00 \cdot 10^{-5}$	$5,63 \cdot 10^{-6}$	$1,30 \cdot 10^{-6}$
q_{11}	$1,00 \cdot 10^{-10}$	$1,00 \cdot 10^{-2}$	$5,55 \cdot 10^{-3}$	$4,03 \cdot 10^{-5}$
q_{33}	$1,00 \cdot 10^{-11}$	$1,00 \cdot 10^{-3}$	$4,45 \cdot 10^{-4}$	$4,05 \cdot 10^{-4}$
q_{55}	$1,28 \cdot 10^{-1}$	$1,21 \cdot 10^0$	$9,04 \cdot 10^{-1}$	$1,85 \cdot 10^0$
r_{11}	$1,44 \cdot 10^3$	$1,00 \cdot 10^4$	$1,00 \cdot 10^4$	$6,78 \cdot 10^3$

Fonte: Autoria própria.

Ao analisar os parâmetros obtidos pelos otimizadores percebe-se que diferente da alimentação senoidal e não senoidal em malha aberta, em malha fechada não houve a convergência de todos os otimizadores de um parâmetro para o mesmo valor, ou seja, os otimizados encontraram valores diferentes para os parâmetros do EKF.

Os conjuntos de parâmetros que retornaram os melhores valores de *fitness* foram aplicados aos testes de validação. Este processo foi necessário para que a robustez do estimador otimizado fosse averiguada quando o MIT estivesse submetido

à variação do conjugado de carga e de suas resistências (rotor e estator), quando a máquina opera em outras faixas de velocidade.

Vale ressaltar que, diferente da etapa de otimização, na etapa de validação a realimentação do controle de velocidade do motor foi realizada por meio da velocidade estimada pelo filtro otimizado. Sendo assim, a estimação de velocidade passa a impactar diretamente no controle de velocidade da máquina, ou seja, a má estimação resultará no controle inadequado.

Os *fitness* provenientes dos testes de validação considerando o EKF com os parâmetros apresentados na Tabela 11 são exibidos na Tabela 12, onde também é apresentado os valores encontrados quando os ruídos dos medidores são incluídos na simulação.

Tabela 12 – *Fitness* dos algoritmos de otimização para os testes de validação em malha fechada.

Primeiro Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	4,02 ·10 ⁺³	4,03 ·10 ⁺³	92,51	93,36	93,98	94,18	92,92	93,67	92,60	92,72
2º teste	5,27 ·10 ⁺³	5,57 ·10 ⁺³	130,09	131,93	130,39	131,95	130,35	131,94	130,29	131,67
Segundo Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	125,31	138,11	76,03	78,52	76,00	79,98	76,84	81,46	88,77	90,94
2º teste	181,35	207,31	89,43	90,94	89,91	95,69	95,42	96,72	89,60	96,94
Terceiro Ponto de Operação										
Teste	INICIAL		FA		PSO		DE		GWO	
	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído	Sem ruído	Com ruído
1º teste	72,02	83,26	23,19	24,49	22,78	28,65	27,17	27,19	27,75	30,76
2º teste	154,41	162,85	42,09	50,69	49,29	49,78	50,72	50,98	53,70	54,88

Fonte: Autoria própria.

Observando a Tabela 12 pode-se perceber que o desempenho do EKF otimizado foi superior ao EKF com os ajustes paramétricos do melhor indivíduo da

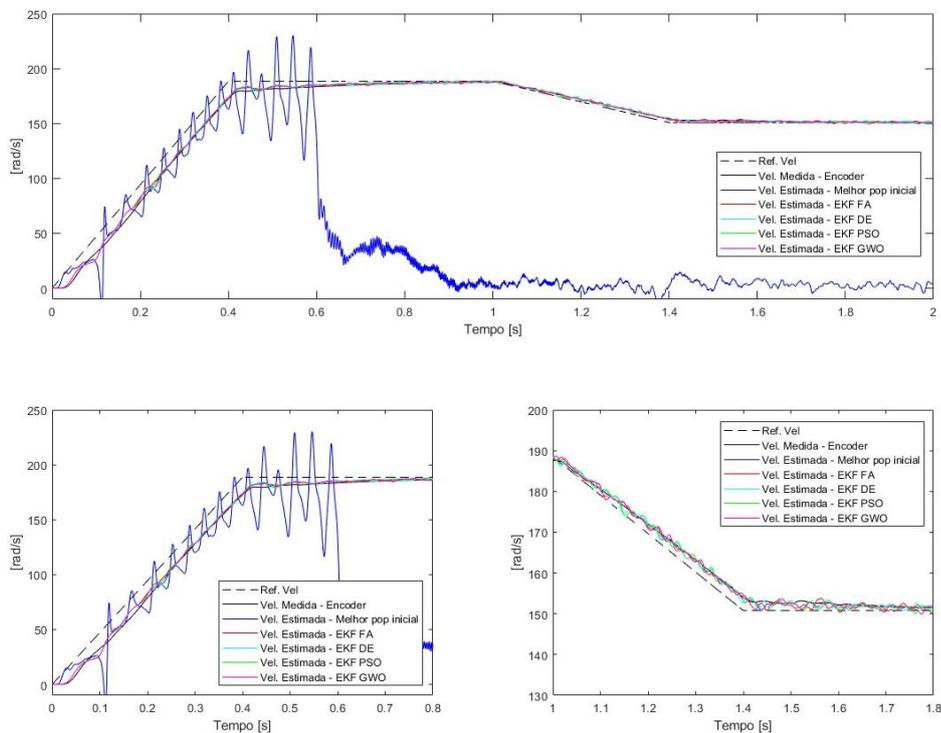
população inicial. Além disso, comparando os *fitness* provenientes dos algoritmos otimizadores, percebe-se a mesma tendência do teste de otimização para o primeiro ponto de operação, onde o FA possui os melhores valores de *fitness*. Ainda, percebe-se que assim como na alimentação senoidal, no primeiro ponto de operação em malha fechada há um aumento do *fitness* à medida que ocorre a variação paramétrica da máquina. Contudo, os ruídos provenientes dos medidores de tensão e corrente não afetaram de forma significativo a desempenho do estimador.

Diferente do primeiro ponto de operação, no segundo ponto, o EKF parametrizado com o melhor indivíduo da população inicial conseguiu estimar a velocidade do motor. Apesar disto, o desempenho do EKF otimizado ainda se manteve superior nos testes de validação, uma vez que o valor do *fitness* foi menor. Ainda, percebe-se que neste caso, o EKF otimizado via PSO se mostrou mais eficiente nos testes sem variação paramétrica do MIT, quando comparado aos demais otimizadores.

Semelhante ao primeiro segundo ponto de operação, no terceiro ponto, o EKF configurado com o melhor indivíduo da população inicial também foi capaz de estimar a velocidade do motor. No entanto, o desempenho global do EKF otimizado permaneceu superior nos testes de validação, pois o valor *fitness* foi menor. De forma geral, com base nos valores mais baixos de *fitness*, os métodos FA e PSO apresentaram um melhor desempenho, a depender do cenário analisado.

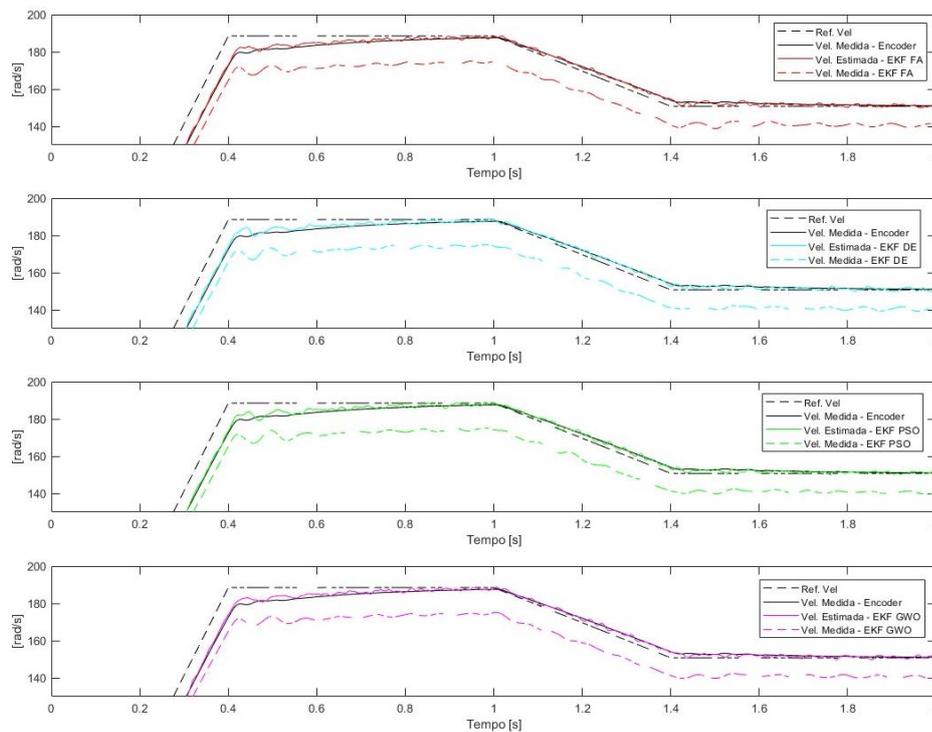
Estas análises são complementada ao se observar a Figura 37, Figura 39, Figura 41, Figura 43, Figura 45, Figura 47, Figura 49, Figura 51, Figura 53, Figura 55, Figura 57 e Figura 59, as quais apresentam as curvas de velocidade estimada pelo EKF otimizado, bem como a referência de velocidade imposta e a velocidade medida quando a realimentação do controle recebe a informação do *encoder*. Devido à velocidade estimada impactar diretamente no controle de velocidade, foi necessário que em malha fechada a análise fosse complementada pela Figura 38, Figura 40, Figura 42, Figura 44, Figura 46, Figura 48, Figura 50, Figura 52, Figura 54, Figura 56, Figura 58 e Figura 60, as quais exibem a velocidade estimada pelo EKF otimizado, as velocidades do MIT quando a saída do EKF é aplicada na realimentação do controle, a referência de velocidade imposta e a velocidade medida com a realimentação via *encoder*.

Figura 37 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha fechada.



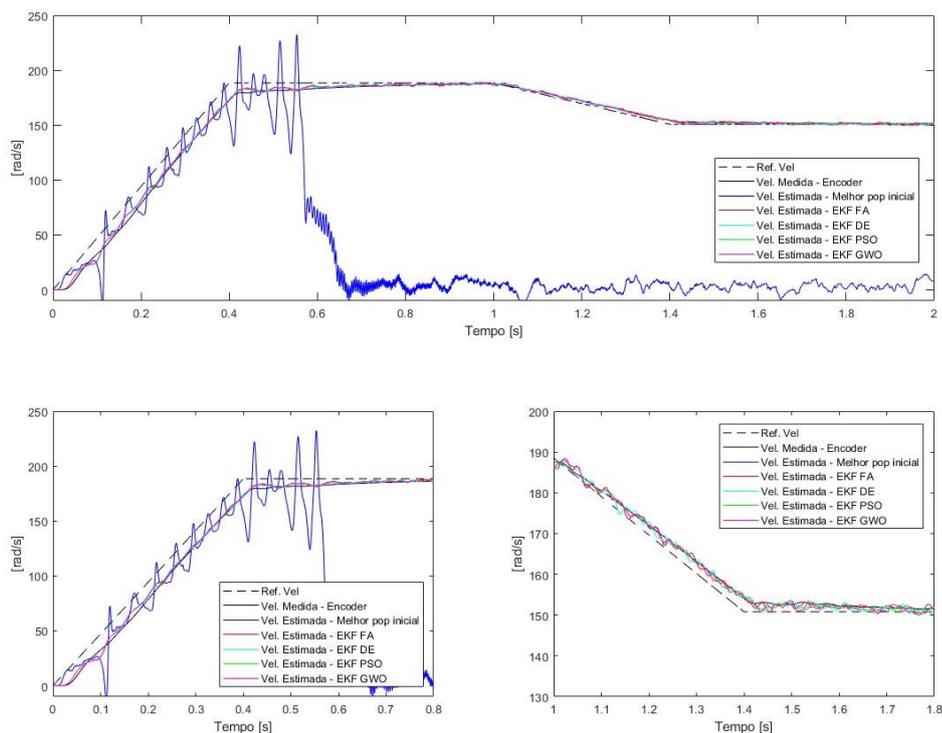
Fonte: Autoria própria.

Figura 38 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 1º ponto de operação em malha fechada.



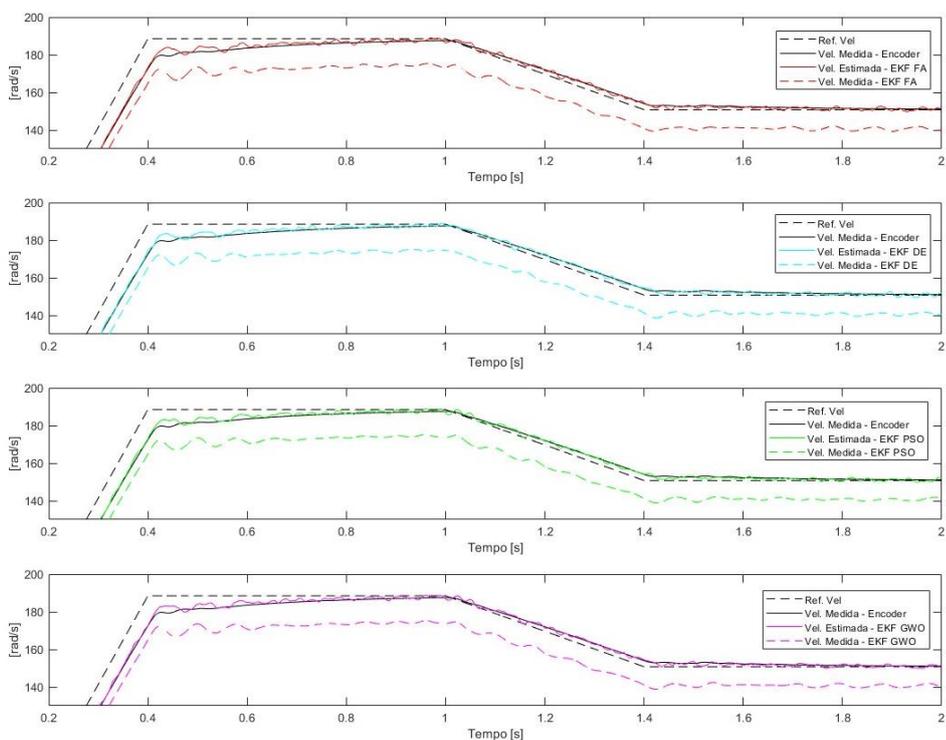
Fonte: Autoria própria.

Figura 39 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha fechada.



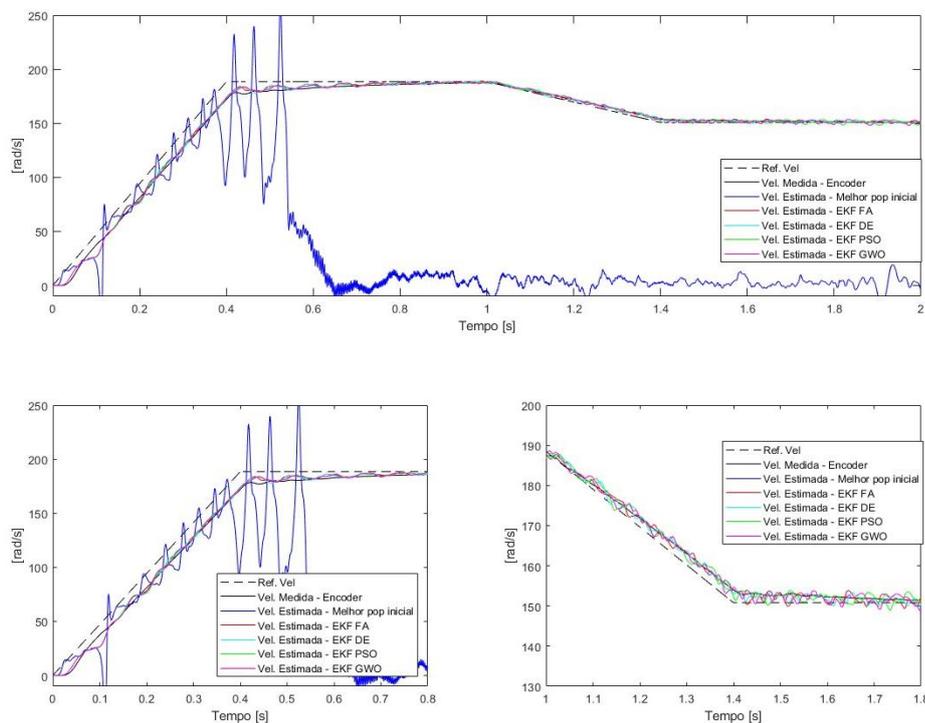
Fonte: Autoria própria.

Figura 40 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 1º ponto de operação em malha fechada.



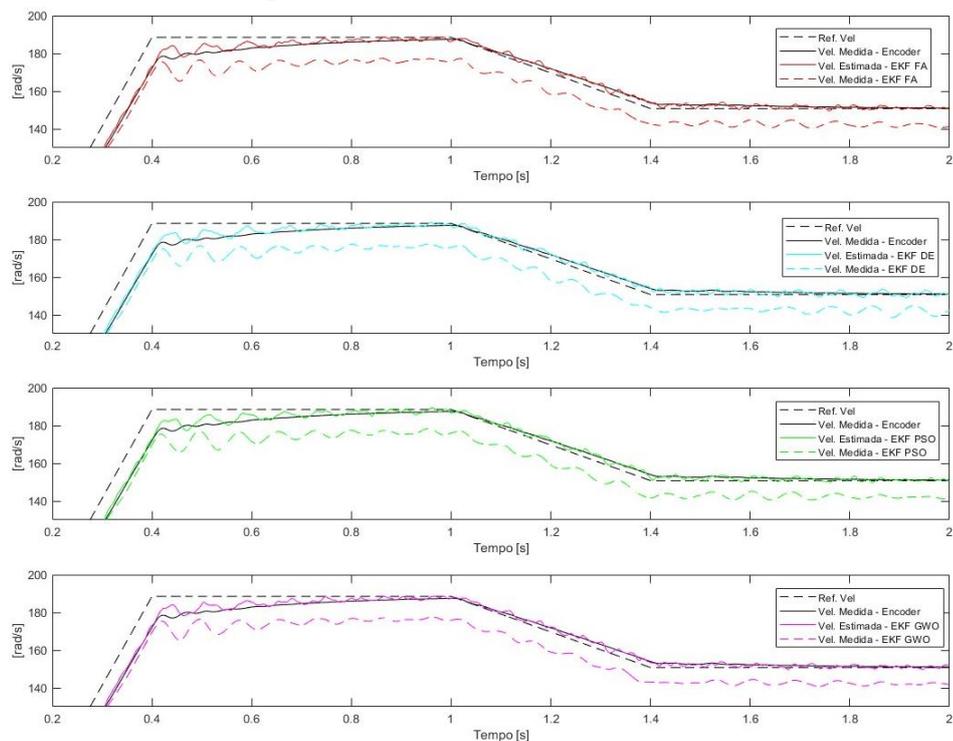
Fonte: Autoria própria.

Figura 41 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha fechada.



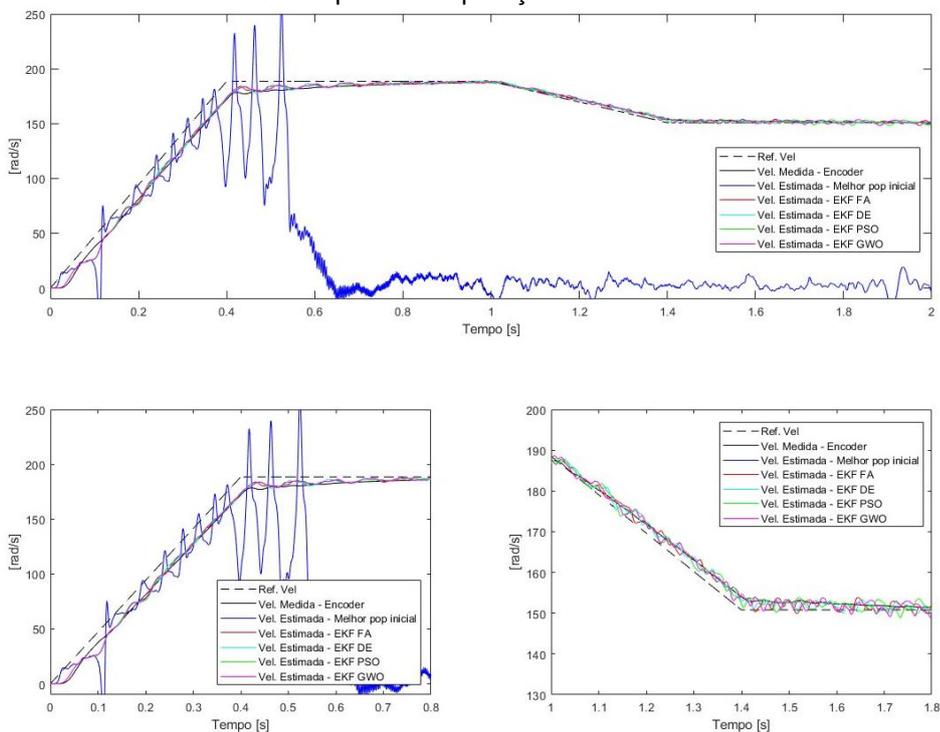
Fonte: Autoria própria.

Figura 42 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 1º ponto de operação em malha fechada.



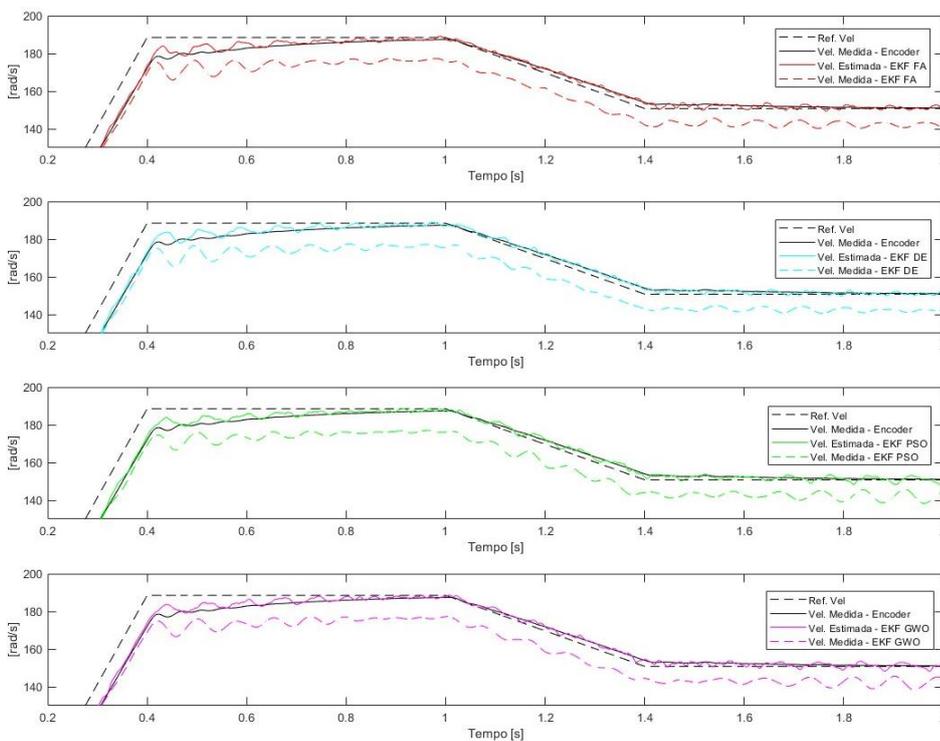
Fonte: Autoria própria.

Figura 43 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha fechada.



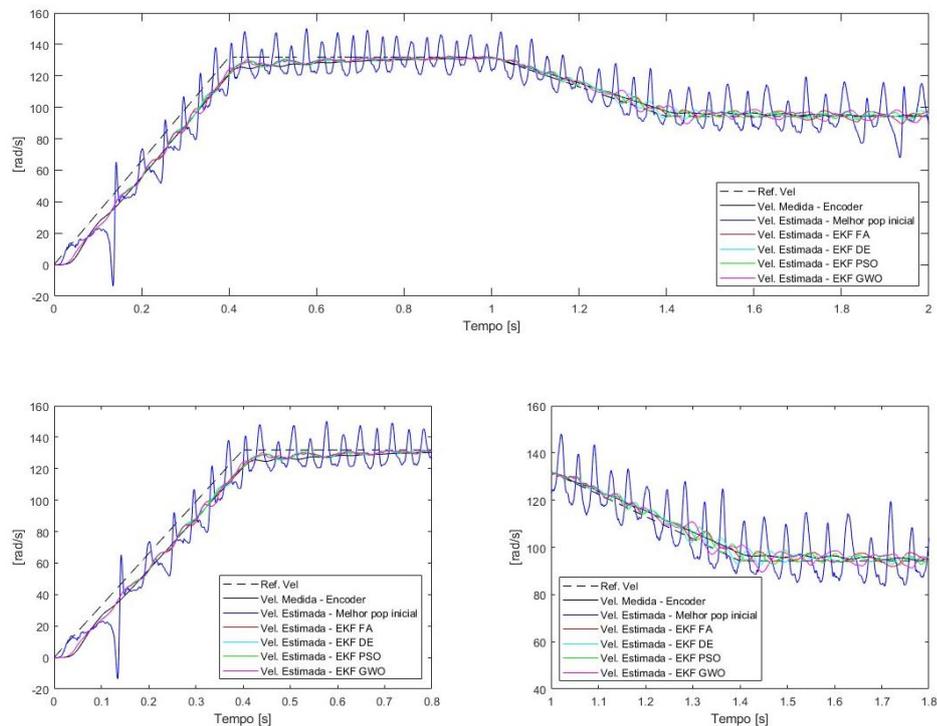
Fonte: Autoria própria.

Figura 44 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 1º ponto de operação em malha fechada.



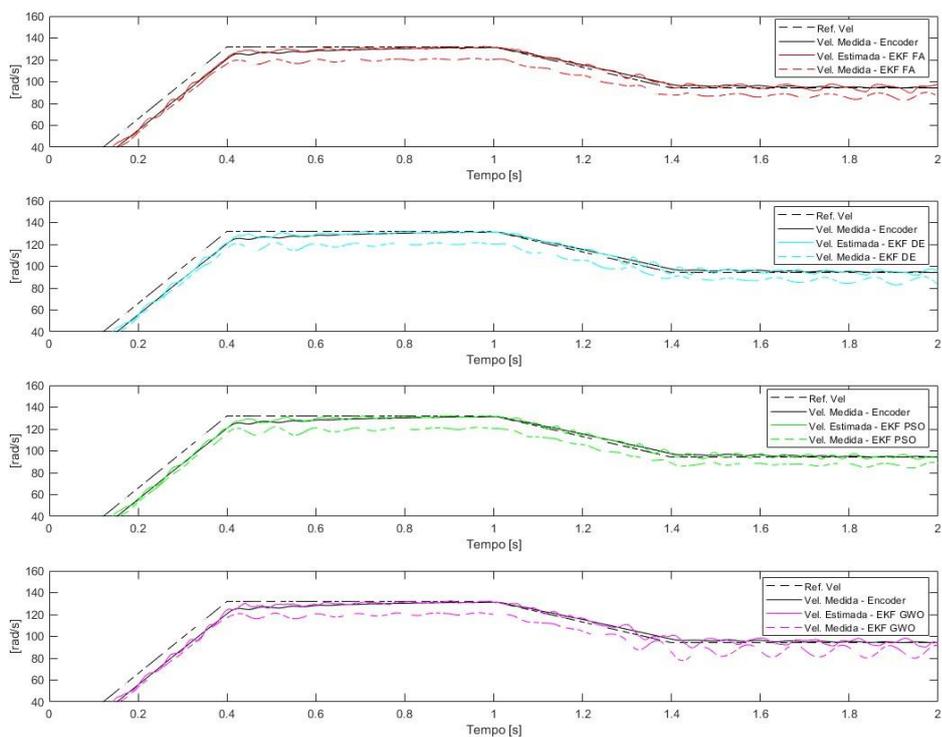
Fonte: Autoria própria.

Figura 45 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha fechada.



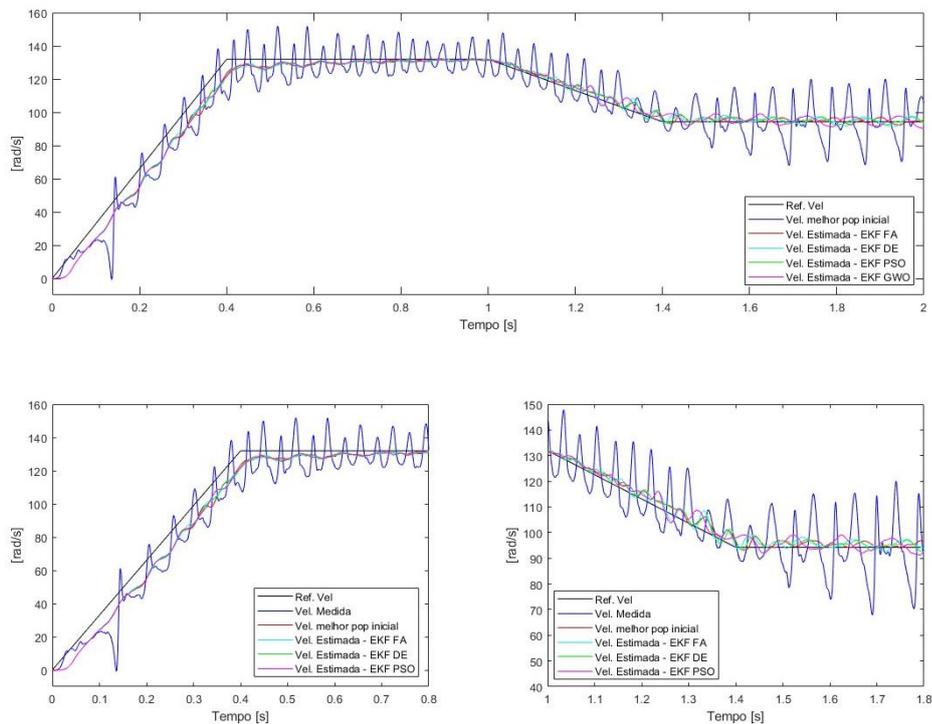
Fonte: Autoria própria.

Figura 46 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 2º ponto de operação em malha fechada.



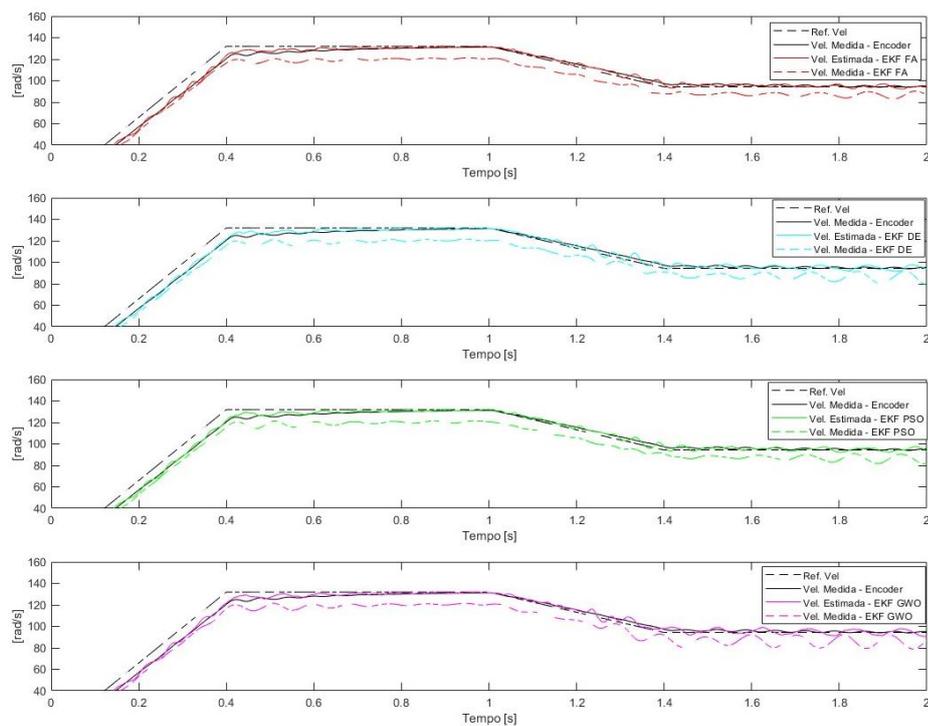
Fonte: Autoria própria.

Figura 47 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha fechada.



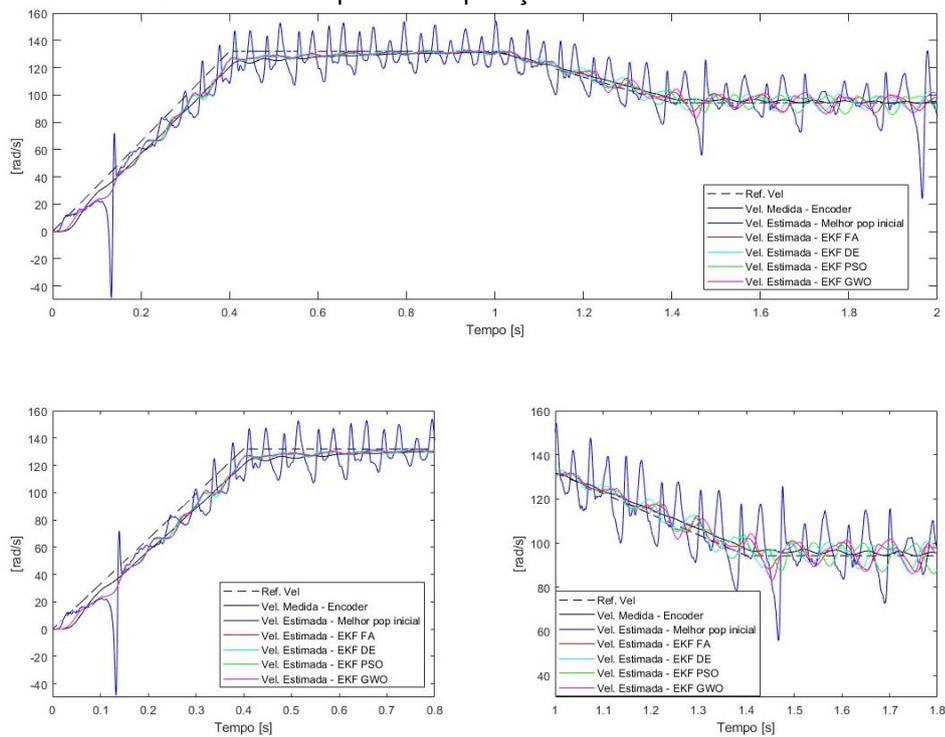
Fonte: Autoria própria.

Figura 48 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 2º ponto de operação em malha fechada.



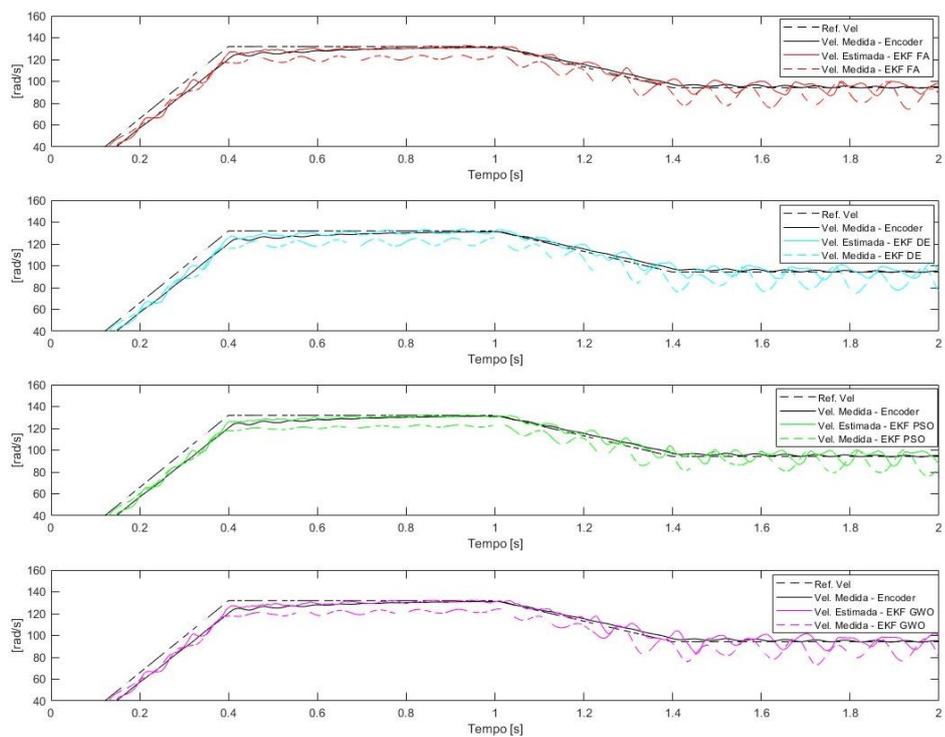
Fonte: Autoria própria.

Figura 49 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha fechada.



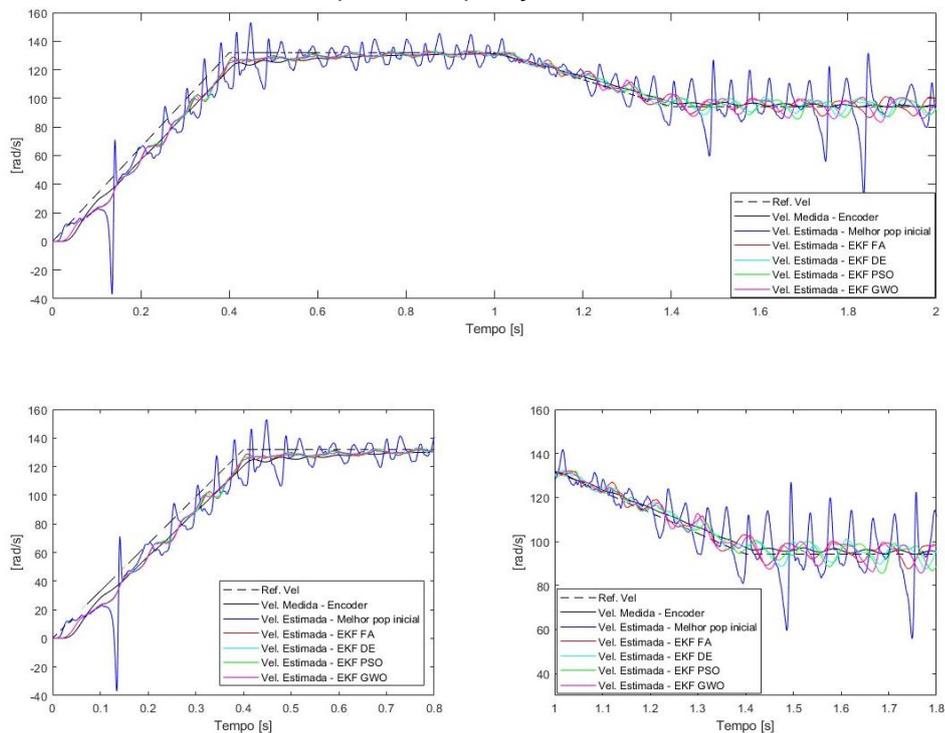
Fonte: Autoria própria.

Figura 50 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 2º ponto de operação em malha fechada.



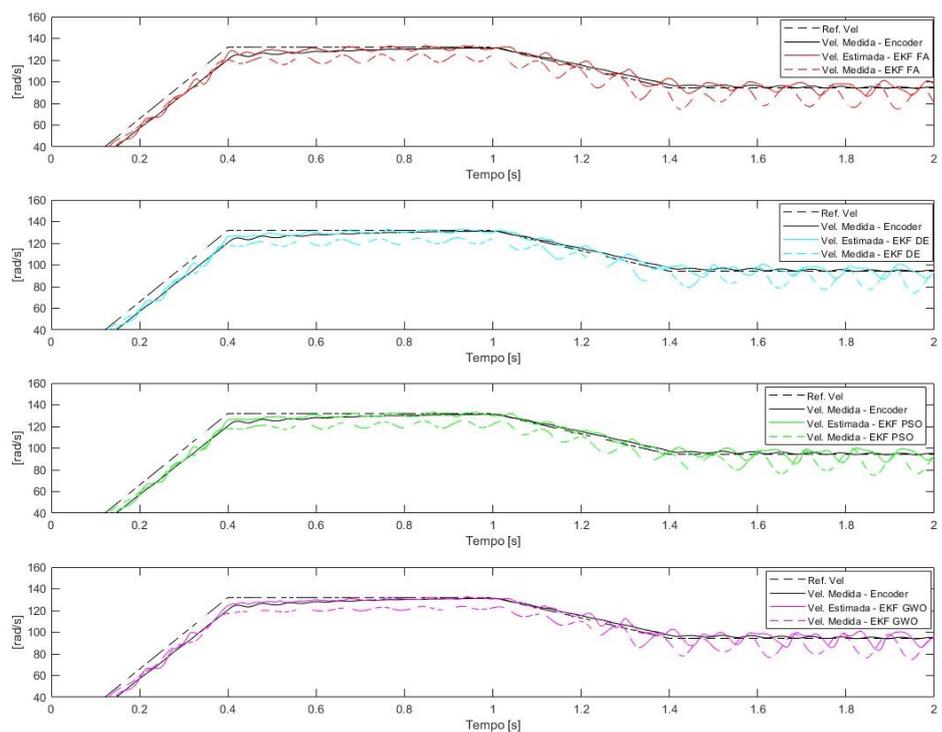
Fonte: Autoria própria.

Figura 51 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha fechada.



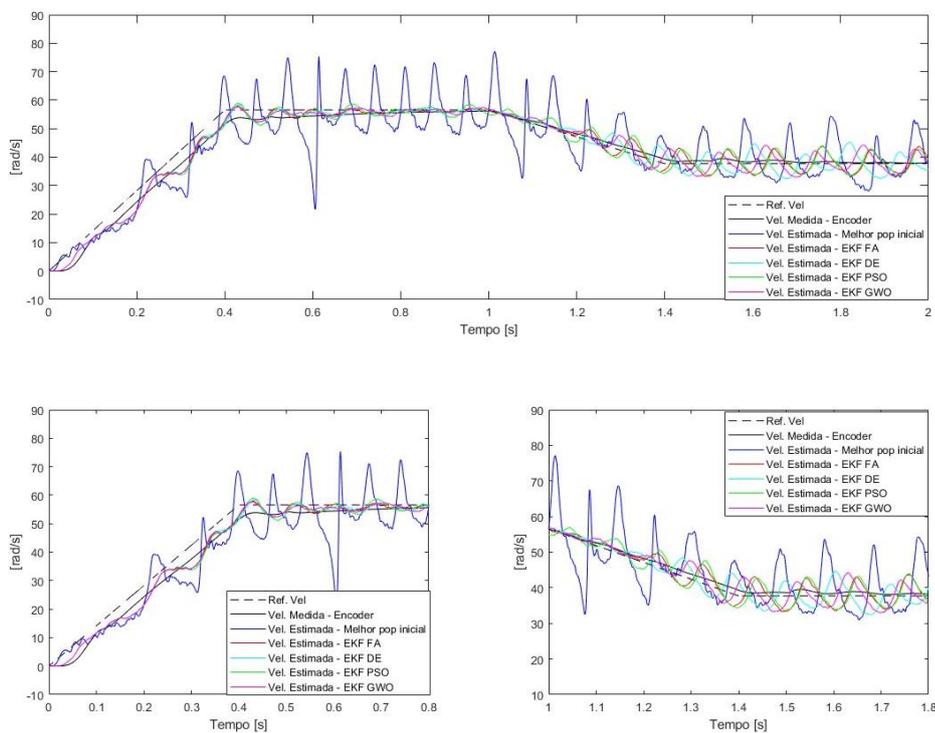
Fonte: Autoria própria.

Figura 52 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 2º ponto de operação em malha fechada.



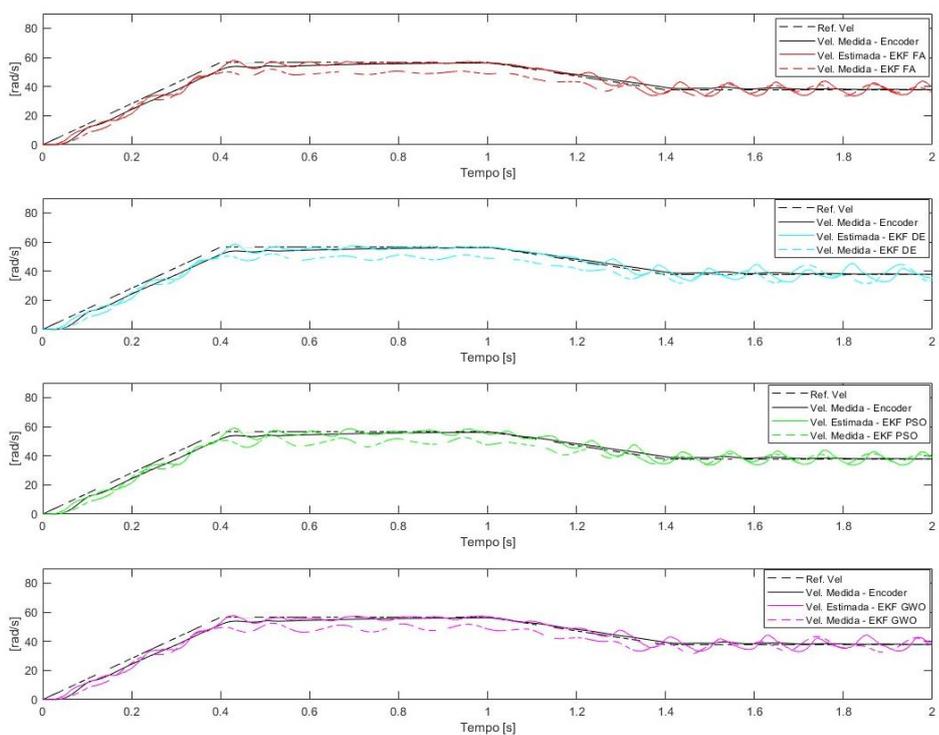
Fonte: Autoria própria.

Figura 53 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha fechada.



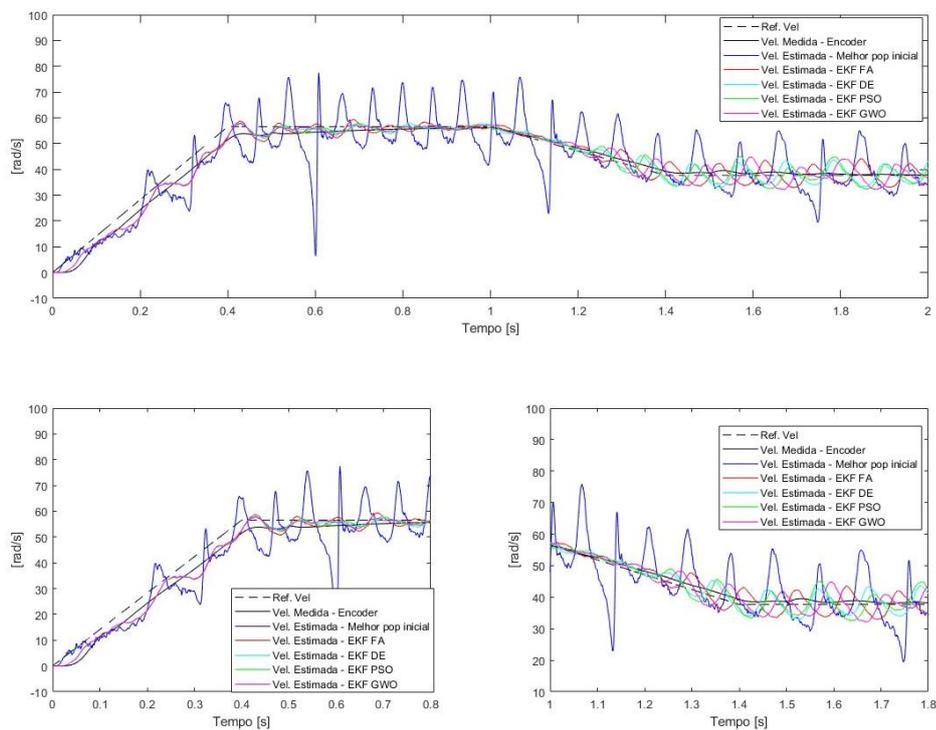
Fonte: Autoria própria.

Figura 54 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e sem ruído – 3º ponto de operação em malha fechada.



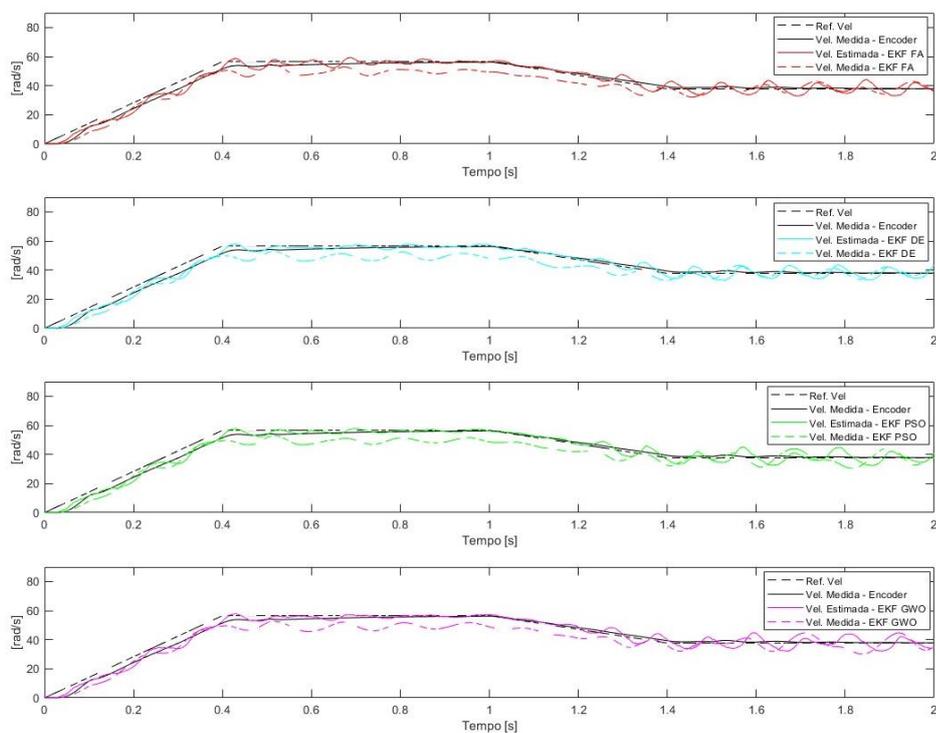
Fonte: Autoria própria.

Figura 55 – 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha fechada.



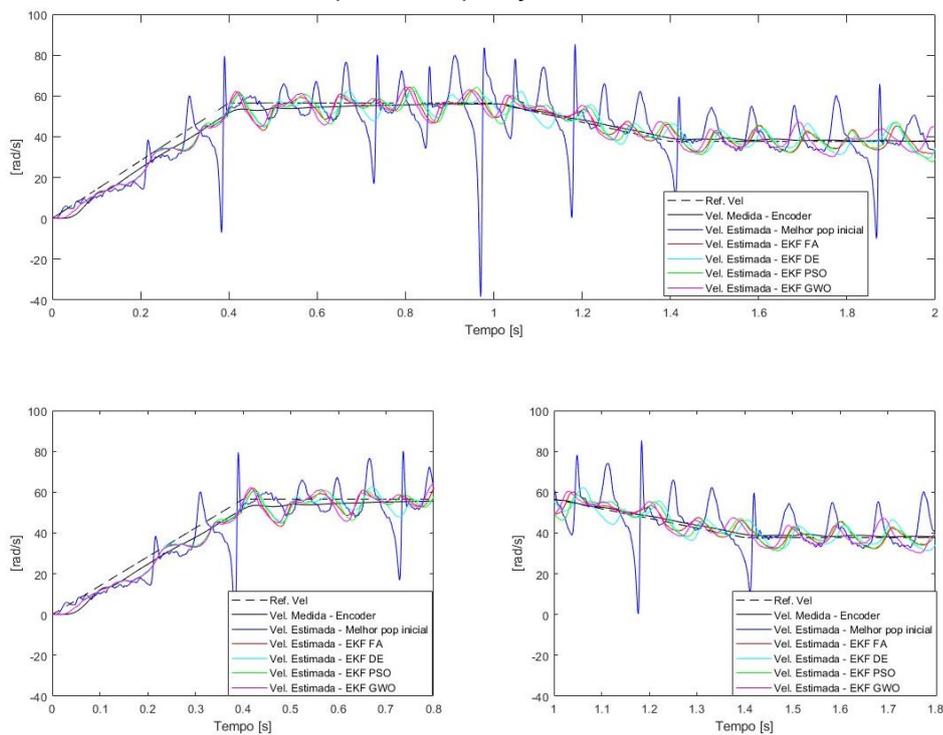
Fonte: Autoria própria.

Figura 56 – Velocidade medida e estimada no 1º teste da fase de validação com alimentação não senoidal, sem alteração de resistências e com ruído – 3º ponto de operação em malha fechada.



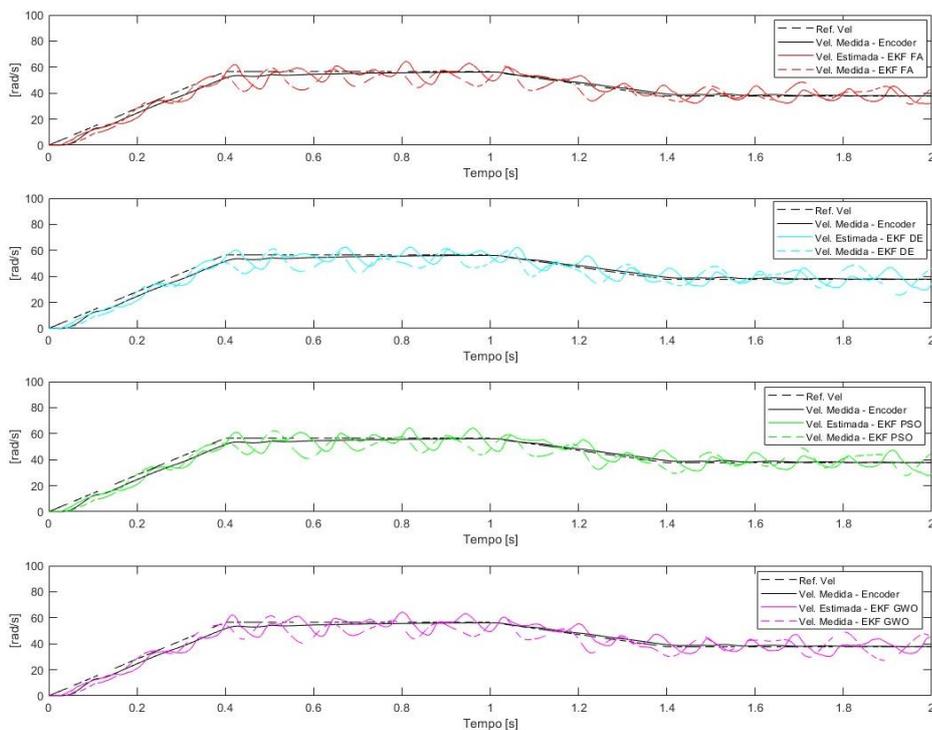
Fonte: Autoria própria.

Figura 57 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha fechada.



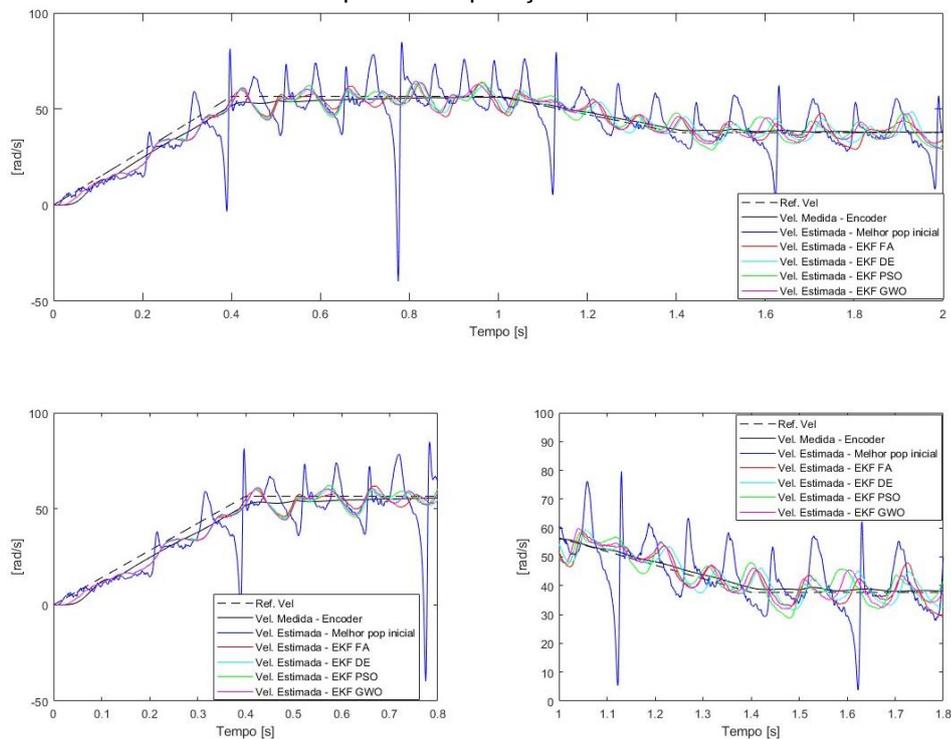
Fonte: Autoria própria.

Figura 58 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e sem ruído – 3º ponto de operação em malha fechada.



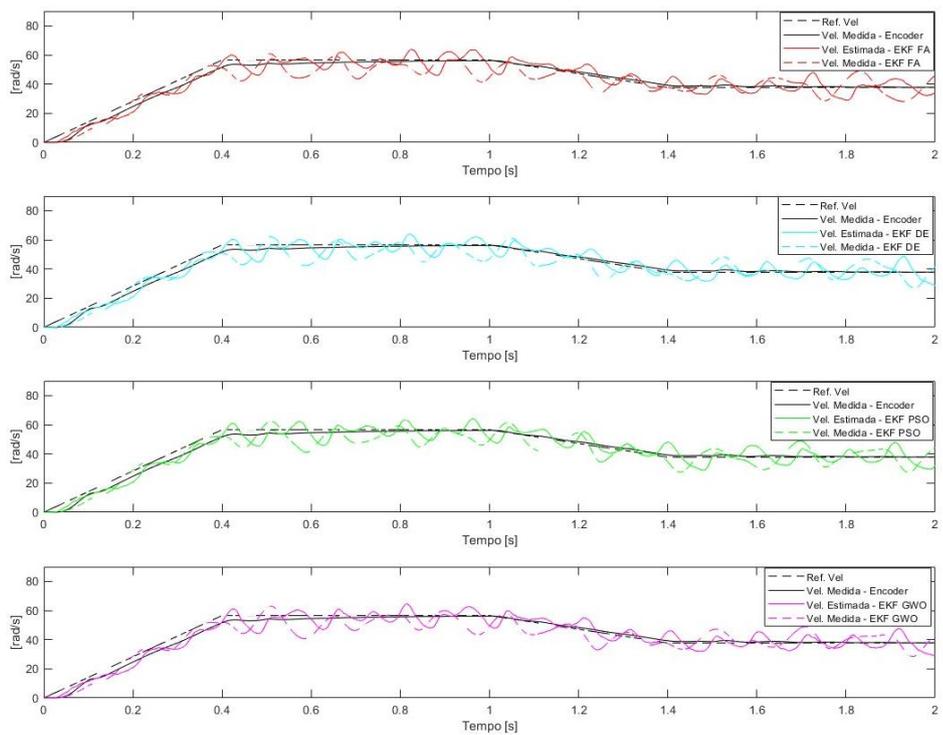
Fonte: Autoria própria.

Figura 59 - 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha fechada.



Fonte: Autoria própria.

Figura 60 – Velocidade medida e estimada no 2º teste da fase de validação com alimentação não senoidal com $R_1 + 20\%$ e $R_2 + 20\%$ e com ruído – 3º ponto de operação em malha fechada.



Fonte: Autoria própria.

Observando o primeiro ponto de operação por meio da Figura 37, Figura 39, Figura 41 e Figura 43 percebe-se que a velocidade estimada pelo EKF com o melhor indivíduo da população inicial não conseguiu estimar de forma satisfatória a velocidade do motor, o que ocasionou na perda do controle de velocidade. Contudo, ao se observar o segundo e terceiro ponto de operação por meio da Figura 45, Figura 47, Figura 49, Figura 51, Figura 53, Figura 55, Figura 57 e Figura 59, percebe-se que o EKF ajustado com o melhor indivíduo da população inicial conseguiu estimar a velocidade.

Em contrapartida, a velocidade estimada pelos EKF com os otimizadores conseguiu se aproximar da referência nos três pontos de operação, ainda que a resposta seja mais ruidosa quando comparado com o controle via *encoder*. O mesmo comportamento foi observado para os testes com alteração de resistência e consideração dos ruídos medidores.

Ainda, observando a Figura 38, Figura 40, Figura 42, Figura 44, Figura 46, Figura 48, Figura 50, Figura 52, Figura 54, Figura 56, Figura 58 e Figura 60, nota-se que a medida em que ocorre a variação paramétrica do MIT, a velocidade estimada pelo EKF otimizado se torna mais distante da velocidade real em que a máquina está girando. Além disso, é possível observar que no primeiro ponto de operação, a maior diferença entre a velocidade medida do MIT e a velocidade estimada pelo EKF otimizado em regime permanente foi de aproximadamente 8% da velocidade nominal. Já no segundo ponto de operação, a maior diferença entre a velocidade medida do MIT e a velocidade estimada pelo EKF otimizado em regime permanente foi registrada com referência de velocidade de 50% da nominal e seus valores foram de aproximadamente 23% para o FA e PSO, 23,2% para o DE e, 24,3% para o GWO. Contudo, no terceiro ponto de operação, a maior diferença entre a velocidade medida do MIT e a velocidade estimada pelo EKF otimizado em regime permanente, foi de 48,4% para o DE, enquanto que foi de 42,1%, 40,5% e 39,5% para o GWO, PSO e FA, respectivamente. Por sua vez, esta diferença foi registrada quando a referência de velocidade era de 20%.

Ou seja, de forma geral, para se utilizar a técnica nas velocidades dos pontos de operação abordados, o processo em que o MIT estará submetido deve-se admitir uma diferença de velocidade desta magnitude.

7 CONCLUSÃO

O presente trabalho propõe a implementação e comparação dos otimizadores FA, PSO, DE e GWO, quando aplicados na sintonização das matrizes de covariância e de predição do EKF, o qual é utilizado para estimar a velocidade do MIT. De forma geral, todos os estimadores de velocidade otimizados apresentaram desempenho superior ao EKF parametrizado com o melhor indivíduo da população inicial, o que evidencia a vantagem em se empregar otimizadores para parametrizar o EKF. Este desempenho é destacado ainda mais nos testes de malha fechada, nos quais o EKF, parametrizado com o melhor indivíduo da população inicial não obteve sucesso ao ser utilizado para controlar a velocidade do MIT.

Avaliando os testes em alimentação senoidal, tanto na etapa de otimização quanto nos testes de validação o EKF otimizado via FA garantiu desempenho superior aos demais otimizadores.

Para a otimização não senoidal em malha aberta, o EKF otimizado via FA também retornou melhor desempenho no teste aplicado na etapa de otimização. Contudo, no primeiro ponto de operação (velocidade alta) da etapa de validação, o EKF otimizado pelo GWO apresentou desempenho levemente superior ao otimizador FA quando os ruídos dos medidores eram considerados. Entretanto, este resultado não se manteve no teste com variação paramétrica do MIT, onde o EKF otimizado pelo FA voltou a apontar melhor desempenho, o que indica certa robustez neste ponto de operação. Todavia, para o segundo e terceiro ponto de operação em malha aberta, o EKF obteve desempenho similar, independente do otimizador empregado, da variação paramétrica do MIT ou, ainda, da consideração ou não dos ruídos provenientes dos medidores. Ainda, percebe-se que o refinamento do estimador garante o melhor desempenho do EKF na estimação de velocidade com alimentação não senoidal em malha aberta, independente da faixa de velocidade, indicando que este método é assertivo para substituir o *encoder* em determinadas aplicações.

Em malha fechada, a otimização pelo FA e GWO apresentou melhor desempenho na etapa de otimização. Contudo, o EKF otimizado pelo GWO não manteve o comportamento para os testes de validação, o que indica que o ponto encontrado pelo otimizador não era robusto o suficiente para suportar as variações de carga, parâmetros do MIT e velocidades impostas em tais testes. Um desempenho

similar ao obtido no primeiro ponto de operação foi identificado no segundo, onde o EKF otimizado pelo FA se manteve com os menores valores de *fitness*. Avaliando o terceiro ponto de operação da etapa de validação nota-se que o EKF otimizado via FA retornou melhor desempenho quando comparado aos demais otimizadores. Entretanto, a variação pontual entre velocidade estimada e velocidade medida com o otimizador aplicado ao controle, chegou a aproximadamente 50% da referência de velocidade, o que indica que para controle de velocidade em baixas velocidades o EKF pode não ter um desempenho satisfatório, uma vez que estimou uma velocidade muito diferente da real.

De forme geral, ainda que o FA apresente desempenho geral superior aos demais otimizadores, o EKF otimizado por DE, GWO e PSO também podem ser empregados na estimação de velocidade do MIT em alimentação senoidal e não senoidal em malha aberta, pois apresentaram resultados satisfatórios. Contudo, ao avaliar-se em malha fechada, os EKFs otimizados retornaram desempenho satisfatório apenas em altas velocidades (80% e 100% da nominal), o que indica que para operações em que o MIT opera com velocidades superiores a 80% da velocidade nominal, o *encoder* pode ser substituído pelo estimador otimizado. Já em médias e baixas velocidades, a utilização do estimador necessitará de maior atenção, pois nos casos em que a precisão da estimação de velocidade se faz necessária, o estimador EKF proposto pode não ser o mais adequado para se aplicar ao controle de velocidade. Já para as baixas velocidades, o estimador pode não ser o mais adequado a se utilizar na realimentação do controle de velocidade.

Vale ressaltar que o ideal é que a otimização do EKF seja feita na faixa de velocidade em que o motor irá operar. Contudo, não se tendo esta informação, recomenda-se que a sintonização do filtro seja feita em baixas velocidades, uma vez que as maiores complicações se encontram nesta faixa de operação e que os resultados demonstraram desempenho considerável em médias e altas velocidades.

Como sequência do trabalho pode-se sugerir uma representação mais completa do sistema de acionamento contendo motor e inversor, além de outras técnicas de controle como, por exemplo, o controle vetorial. Ainda, pode-se explorar técnicas de sintonia de parâmetros dos algoritmos de otimização empregados, além da aplicação de novos métodos. Por fim, a validação experimental seria interessante para testar a metodologia proposta em bancada.

REFERÊNCIAS

ALB, M. et al. Firefly algorithm for finding optimal shapes of electromagnetic devices. **IEEE transactions on magnetics**, v. 52, n. 3, p. 1-4, 2016.

BERNARDES, I. O. **Aplicação do algoritmo de evolução diferencial na estimação dos parâmetros elétricos de um MIT operando em regime permanente**. 2020. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

BOSE, B. K. **Prentice - Modern Power Electronics and AC Drives**. Upper Saddle River, NJ-USA: Prentice Hall, 2002.

CASTOLDI, M. F. **Protótipo virtual da estratégia DTC aplicada a motores de indução usando linguagem VHDL**. 2006. Dissertação de Mestrado. Universidade de São Paulo

CAVALI, T. D. S. **Controle de potência via algoritmo de enxame de vaga-lumes para atenuação dos efeitos da variação da temperatura ambiente em redes OCDMA**. 2017. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

EPE [Empresa de Pesquisa Energética] **Balanco Energético Nacional (BEN) 2021: Ano base 2020**. Disponível em < <https://ben.epe.gov.br> >. Acesso em out/2022.

FITZGERALD, A. E.; KINGSLEY JR, C.; UMANS, S. D. **Máquinas Elétricas:- Com Introdução à Eletrônica de Potência**. Bookman, 2006. ISBN 8577800482.

GRACIOLA, C. L. **Otimização da eficiência energética de um motor de indução trifásico acionado por um driver de controle escalar**. 2016. 102f, Dissertação. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2016.

GOEDEL, A. et al. Speed estimation for induction motor using neural networks method. **IEEE Latin America Transactions**, 2013. pp. 768-778

GOULART, Fillipe; CAMPELO, Felipe; RAMIREZ, Jaime A. **Estudo dos mecanismos de funcionamento do algoritmo de evolução diferencial**. X Congresso Brasileiro de Inteligência Computacional, 2011.

GUEDES, Jacqueline Jordan e cols. **Identificação de falhas de curto-circuito de estator em motores de indução trifásicos utilizando evolução diferencial**. 2016. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

GUEDES, J. J.; CASTOLDI, M. F.; GOEDEL, A. Temperature influence analysis on parameter estimation of induction motors using differential evolution. **IEEE Latin America Transactions**, v. 14, n. 9, p. 4097-4105, 2016.

KENNEDY, J. **Particle swarm optimization**. *Encyclopedia of machine learning*, Springer, p. 760–766, 2010.

KRAUSE, P. et al. **Analysis of electric machinery and drive systems**. John Wiley & Sons, 2013.

KRISHNAN, R. *Electric motor drives: modeling, analysis, and control*. Prentice Hall New Jersey, 2001.

KOSOW, I. L. **Máquinas elétricas e transformadores**. São Paulo: 2005. ISBN 8525002305.

LAATRA, Y.; LOTFI, H.; ABDELHANI, B. Speed sensorless vector control of induction machine with Luenberger observer and Kalman filter. **2017 4th International Conference on Control, Decision and Information Technologies (CoDIT)**, 2017. IEEE. p.0714-0720.

MANSON, K. et al. Enhanced fireworks algorithm to optimize extended Kalman filter speed estimation of an induction motor drive system. **2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), 2018**. pp. 267-273.

MASCHIO, K. A. F. **Estudo de estimadores de velocidade de motor de indução com observadores de estado e filtro de Kalman**. 2006. Dissertação de Mestrado. Universidade de São Paulo, São Carlos, 2006.

MIRJALILI, S.; MIRJALILI, M.; LEWIS, A. Grey wolf optimizer. **Advances in engineering software**, v. 69, p. 46-61, 2014.

MONADI, A. et al. Speed estimation of faulty three-phase induction motor using model reference adaptive system. **2015 IEEE Conference on Energy Conversion (CENCON)**, 2015. IEEE. p.368-372.

PILLA, Ramana; GORRIPOTU, Tulasichandra Sekhar; AZAR, Ahmad Taher. Tuning of extended Kalman filter using grey wolf optimisation for speed control of permanent magnet synchronous motor drive. **International Journal of Automation and Control**, v. 15, n. 4-5, p. 563-584, 2021.

PINHEIRO, H.; BOTTERÓN, F. Modulação *space vector* para inversores alimentados em tensão: Uma abordagem unificada. **Revista Controle e Automação**, v. 16, n. 1, p. 13–24, March 2005. ISSN 0278-0046.

PRICE, K.; STORN, R. M.; LAMPINEN, J. A. **Differential evolution: a practical approach to global optimization**. [S.l.]: Springer Science & Business Media, 2006.

RAYYAM, M.; ZAZI, M.. Particle Swarm optimization of a Non-Linear Kalman Filter for Sensorless Control of Induction Motors. **2018 7th International Conference on Renewable Energy Research and Applications (ICRERA)**, 2018. pp. 1016-1020.

RUTKOWSKI, L. **Computational intelligence: methods and techniques**. [S.l.]: Springer Science & Business Media, 2008.

SALVATORE, N. et al. Optimization of delayed-state Kalman-filter-based algorithm via differential evolution for sensorless control of induction motors. **IEEE Transactions on Industrial Electronics**, 2010. pp. 385-394

SANTOS, H. O. **Filtro de Kalman estendido otimizado por enxame de vagalumes utilizado na estimação de velocidade do motor trifásico**. 2020. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

SANTOS, H. O. et al. **Estimador de velocidade de um motor de indução trifásico utilizando filtro de Kalman estendido otimizado por algoritmo de enxame de vagalumes**. XXII Congresso Brasileiro de Automática: João Pessoa – PB, Brasil. 2019.

SANTOS, T. H. et al. An ANN strategy applied to induction motor speed estimator in closed-loop scalar control. **2012 XXth International Conference on Electrical Machines**, 2012. pp. 844-850.

SHE, Z. et al. Identification for PMSM rotor speed based on optimized extended kalman filter and load torque observer. **2020 IEEE International Conference on Applied Superconductivity and Electromagnetic Devices (ASEMD)**, 2020. pp. 1-2.

SHI, K. et al. Speed estimation of an induction motor drive using an optimized extended Kalman filter. **IEEE Transactions on Industrial Electronics**, 2002. pp. 124-133.

SMITH, A. N.; GADOUE, S. M.; FINCH, J. W. Improved rotor flux estimation at low speeds for torque MRAS-based sensorless induction motor drives. **2015 IEEE Transactions on Energy Conversion**, 2015. pp. 270-282.

SOUZA, D. F. et al. **An assessment of the impact of brazilian energy efficiency policies for electric motors**. Energy Nexus, v. 5, p. 100033, 2022.

TJAHJONO, A. et al. Adaptive modified firefly algorithm for optimal coordination of overcurrent relays. **IET Generation, Transmission & Distribution**, v. 11, n. 10, p. 2575-2585, 2017.

VAS, P. **Sensorless vector and direct torque control**. Oxford Univ. Press, 1998. ISBN 0198564651.

WEG Equipamentos Elétricos S/A - **Guia de especificação (Motores Elétricos)**. Jaraguá do Sul, 2021.

YANG, X.-S. **Nature-inspired metaheuristic algorithms**. Luniver press, 2010. ISBN 1905986289.

ZERDALI, E.; BARUT, M. The comparisons of optimized extended Kalman filters for speed-sensorless control of induction motors. **IEEE Transactions on industrial electronics**, 2017. pp. 4340-4351.

ZHAO L. et al. Second-Order Sliding-Mode Observer With Online Parameter Identification for Sensorless Induction Motor Drives. **2014 IEEE Transactions on Industrial Electronics**, 2014. pp. 5280-5289.