

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIA EXATAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Algoritmo Genético Aplicado à Identificação de Parâmetros de um Conversor Boost

João Gabriel Morais Costa

Trabalho de Conclusão de Curso

João Gabriel Morais Costa

Algoritmo Genético Aplicado à Identificação de Parâmetros de um Conversor Boost

Trabalho de Conclusão de Curso apresentado
como parte dos requisitos para obtenção do
título de Bacharel em Engenharia Elétrica
pela Universidade Federal de São Carlos.

Orientador: Prof. Dr. Amilcar Flamarion
Querubini Gonçalves

São Carlos
20 de outubro de 2025

Dedico este trabalho à minha família, alicerce inabalável de minha jornada que, com amor, paciência e incansável apoio, transformou sonhos em realizações e desafios em oportunidades de crescimento. Aos amigos que me acompanharam nesta caminhada, compartilhando momentos de vitória, superação e aprendizado, tornando cada instante mais leve e significativo. Ao meu orientador, que além de guiar este trabalho com sabedoria e dedicação, esteve sempre presente em minha formação acadêmica, compartilhando conhecimento, inspirando excelência e moldando não apenas o profissional, mas também o ser humano que me tornei. A vocês, minha eterna gratidão.

Agradecimentos

A realização deste trabalho não seria possível sem o apoio, incentivo e presença de pessoas fundamentais ao longo da minha trajetória acadêmica e pessoal.

À minha família, meu porto seguro e alicerce inabalável, agradeço por todo amor, paciência e apoio incondicional. Vocês estiveram ao meu lado em cada passo, celebrando conquistas e fortalecendo-me diante dos desafios. Foram fonte constante de motivação e equilíbrio, transformando obstáculos em oportunidades de crescimento.

Aos amigos que caminharam comigo nesta jornada, deixo minha gratidão por cada conversa, incentivo, momento de descontração e partilha sincera. Sua presença tornou o percurso mais leve e significativo, mesmo nos momentos mais exigentes.

Ao meu orientador, registro um agradecimento especial por sua dedicação, competência e presença constante ao longo da minha formação. Sua orientação atenta e inspiradora não apenas conduziu este trabalho com excelência, mas também deixou marcas profundas na minha construção como profissional e como ser humano.

A todos que, direta ou indiretamente, contribuíram para que este trabalho se concretizasse, o meu sincero muito obrigado.

“Vim, vi, venci.”
(Júlio César)

Resumo

Com o aumento da penetração de fontes renováveis na rede elétrica, particularmente a geração solar fotovoltaica, o uso de conversores CC-CC tornou-se uma parte fundamental para a integração eficiente desses sistemas a rede. Contudo, em diversas aplicações práticas, os parâmetros físicos e modelos precisos desses conversores não são completamente conhecidos, dificultando simulações rigorosas e o entendimento adequado do comportamento dinâmico desses sistemas. Nesse contexto, o presente trabalho propõe uma metodologia para identificação paramétrica de conversores Boost operando em modo de condução contínua, baseada na integração de modelagem por pequenos sinais, excitação por sinais pseudoaleatórios binários (PRBS) e algoritmos genéticos (AGs). Primeiramente, desenvolve-se a fundamentação teórica do conversor Boost, deduzindo analiticamente a função de transferência $G_{vg}(s)$ através do método da média no espaço de estados. Esta dedução estabelece a dependência entre os parâmetros físicos resistor (R), indutor (L), capacitor (C) e ciclo de trabalho (D), e a resposta dinâmica do conversor. Posteriormente, implementa-se a metodologia experimental no ambiente MATLAB/Simulink, introduzindo-se pequenas perturbações do tipo PRBS na tensão de entrada, o que possibilita obter experimentalmente a função de transferência por meio de análise espectral diferencial. O algoritmo genético é configurado com codificação real, sendo cada cromossomo responsável por estimar simultaneamente os quatro parâmetros do conversor, utilizando como função objetivo a minimização do erro quadrático médio normalizado entre as magnitudes das funções de transferência teórica e experimental. A robustez da técnica proposta é avaliada considerando três cenários progressivos de complexidade crescente: componentes ideais com limites estreitos de busca ($\pm 1\%$), inclusão de não-idealidades (resistências série equivalentes - ESR) e ampliação dos limites de busca para faixas maiores ($\pm 5\%$ e $\pm 10\%$). Os resultados obtidos demonstraram boa precisão na identificação paramétrica, com erros relativos dentro das faixas estabelecidas, validando a eficácia e a confiabilidade da metodologia proposta. Este estudo contribui para a área de identificação paramétrica aplicada à eletrônica de potência, oferecendo uma abordagem computacional robusta, versátil e replicável, com potencial para ser empregada no diagnóstico, na auto-sintonia de controladores e na manutenção preditiva de conversores CC-CC, podendo ainda ser estendida para outras topologias e contextos industriais.

Palavras-chave: conversor boost; algoritmos genéticos; identificação paramétrica; função de transferência; PRBS; eletrônica de potência.

Abstract

With the increased penetration of renewable sources in the electrical grid, particularly solar photovoltaic generation, the use of DC-DC converters has become a fundamental part of the efficient integration of these systems into the grid. However, in several practical applications, the physical parameters and accurate models of these converters are not completely known, hindering rigorous simulations and a proper understanding of the dynamic behavior of these systems. In this context, this work proposes a methodology for the parametric identification of Boost converters operating in continuous conduction mode, based on the integration of small-signal modeling, pseudo-random binary signal (PRBS) excitation, and genetic algorithms. First, the theoretical basis of the Boost converter is developed, analytically deducing the transfer function $G_{vg}(s)$ using the state space averaging method. This deduction establishes the dependence between the physical parameters resistor (R), inductor (L), capacitor (C) and duty cycle (D), and the dynamic response of the converter. Subsequently, the experimental methodology is implemented in the MATLAB/Simulink environment, introducing small PRBS-type disturbances in the input voltage, which makes it possible to obtain the transfer function experimentally through differential spectral analysis. The genetic algorithm is configured with real encoding, with each chromosome responsible for simultaneously estimating the four parameters of the converter, using as an objective function the minimization of the normalized mean square error between the magnitudes of the theoretical and experimental transfer functions. The robustness of the proposed technique is evaluated considering three progressive scenarios of increasing complexity: ideal components with narrow search limits ($\pm 1\%$), inclusion of non-idealities (equivalent series resistances - ESR), and expansion of search limits to larger ranges ($\pm 5\%$ and $\pm 10\%$). The results obtained demonstrated good accuracy in parametric identification, with relative errors within the established ranges, validating the effectiveness and reliability of the proposed methodology. This study contributes to the field of parametric identification applied to power electronics, offering a robust, versatile, and replicable computational approach with the potential to be used in diagnostics, controller self-tuning, and predictive maintenance of DC-DC converters, and can also be extended to other topologies and industrial contexts.

Keywords: boost converter; genetic algorithms; parametric identification; transfer function; PRBS; power electronics.

Lista de ilustrações

Figura 1 – Topologia do Conversor Boost	13
Figura 2 – Circuito equivalente em regime permanente: chave conduzindo e diodo bloqueado	15
Figura 3 – Circuito equivalente em regime permanente: chave bloqueada e diodo conduzindo	16
Figura 4 – Chaveamento PWM durante período ligado, $D \cdot T_s$, e desligado, $(1 - D) \cdot T_s$ e principais curvas do conversor Boost	18
Figura 5 – Modelo de pequenos sinais do conversor Boost para análise da função de transferência $G_{vg}(s)$	22
Figura 6 – Diagrama de Bode da função de transferência $G_{vg}(s)$ do conversor Boost.	27
Figura 7 – Metodologia proposta para a identificação dos parâmetros	37
Figura 8 – Modelo do conversor Boost no Simulink sem perturbação	39
Figura 9 – Modelo do conversor Boost no Simulink com perturbação PRBS	39
Figura 10 – Validação das tensões do conversor Boost	50
Figura 11 – Corrente no indutor - Validação do modo de condução contínua	51
Figura 12 – Validação da perturbação por pequenos sinais - Tensões com fonte PRBS ativa	52
Figura 13 – Comparação das funções de transferência $G_{vg}(s)$ - Limites $\pm 1\%$	54
Figura 14 – Convergência do algoritmo genético - Limites $\pm 1\%$	55
Figura 15 – Convergência do algoritmo genético - Limites $\pm 5\%$ com ESR	57
Figura 16 – Convergência do algoritmo genético - Limites $\pm 10\%$ com ESR	58

Lista de tabelas

Tabela 1 – Parâmetros da função de transferência $G_{vg}(s)$ para o conversor Boost. . .	24
Tabela 2 – Parâmetros de projeto do conversor Boost	38
Tabela 3 – Parâmetros calculados do conversor Boost com equações alinhadas . .	49
Tabela 4 – Comparação entre parâmetros reais e estimados - Limites $\pm 1\%$	53
Tabela 5 – Resultados com resistências parasitas - Limites $\pm 1\%$	56
Tabela 6 – Resultados com resistências parasitas - Limites $\pm 5\%$	57
Tabela 7 – Resultados com resistências parasitas - Limites $\pm 10\%$	58

Sumário

1	INTRODUÇÃO	10
1.1	Contextualização e motivação	10
1.2	Justificativa do Trabalho	10
1.3	Metodologia	11
1.4	Objetivos	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Conversor Boost	13
2.2	Modelagem Matemática do Conversor Boost	14
2.2.1	Modelo em Regime Permanente no Modo de Condução Contínua (MCC)	14
2.2.1.1	Estado 1: S1 conduzindo e D1 bloqueado	15
2.2.1.2	Estado 2: S1 bloqueada e D1 conduzindo	16
2.2.1.3	Ganho estático do conversor: $M(D)$	19
2.2.1.4	Projeto do ciclo de trabalho: D	19
2.2.1.5	Determinação da carga resistiva: R	19
2.2.1.6	Projeto do indutor: L	19
2.2.1.7	Projeto do capacitor: C	20
2.2.2	Modelagem por Pequenos Sinais do Conversor Boost e Dedução da Função de Transferência $G_{vg}(s)$	20
2.2.2.1	Equações de Estado do Conversor Boost	21
2.2.2.2	Aplicação do Método da Média no Espaço de Estados	21
2.2.2.3	Linearização em Torno do Ponto de Operação	21
2.2.2.4	Modelo de Pequenos Sinais do Conversor Boost	22
2.2.2.5	Dedução da Função de Transferência $G_{vg}(s)$	22
2.2.2.6	Interpretação Física dos Parâmetros	23
2.2.2.7	Limitações do Modelo de Pequenos Sinais e Considerações sobre Efeitos Não-Ideais no Conversor Boost	24
2.2.2.8	Resposta em Frequência	26
2.2.2.9	Implicações para o Projeto de Controle	27
2.2.2.10	Escolha de $G_{vg}(s)$ na Determinação dos Parâmetros do Conversor Boost	28
2.3	Identificação de Parâmetros em Circuitos Elétricos	28
2.3.1	Métodos Tradicionais vs. Métodos Computacionais	28
2.3.2	Identificação no Domínio da Frequência	29

2.3.3	Sinais de Excitação PRBS	30
2.4	Algoritmos Genéticos (GA)	31
2.4.1	Fundamentos Teóricos	31
2.4.2	Estrutura Básica do Algoritmo Genético	31
2.4.3	Operadores Genéticos	32
2.4.4	Aplicação em Identificação de Parâmetros	32
2.4.5	Critérios de Convergência	33
2.4.6	Avanços Recentes na Identificação Paramétrica com Algoritmos Genéticos	34
3	MATERIAIS E MÉTODOS	37
3.1	Descrição do Sistema	37
3.1.1	Especificações e Parâmetros do Conversor	37
3.1.2	Estrutura Física e Configuração no Simulink	38
3.2	Implementação do Modelo no Simulink	38
3.2.1	Componentes e Configuração do Sistema	39
3.2.2	Configuração da Fonte PRBS	40
3.2.3	Medição e Aquisição de Sinais	40
3.3	Estratégia Geral da Identificação	41
3.3.1	Justificativa da Escolha da Função $G_{vg}(s)$	41
3.3.2	Influência dos Parâmetros na Resposta do Sistema	41
3.4	Aquisição e Processamento dos Dados	42
3.4.1	Obtenção dos Dados Simulados	42
3.4.2	Pré-processamento e Análise Espectral	42
3.5	Detalhamento da Implementação do Algoritmo Genético	43
3.5.1	Codificação dos Parâmetros	43
3.5.2	Definição da Função Objetivo	43
3.5.3	Critérios de Convergência e Configuração do Algoritmo	44
3.6	Avaliação e Validação dos Resultados	46
3.6.1	Análise de Convergência do Algoritmo Genético	46
3.6.2	Comparação de Funções de Transferência	46
3.6.3	Análise com Componentes Não-Ideais	47
3.6.4	Metodologia de Análise do Erro Relativo Percentual	47
4	RESULTADOS OBTIDOS	48
4.1	Configuração Inicial do Estudo	48
4.1.1	Cálculo dos Parâmetros Reais do Conversor	48
4.1.2	Validação do Modelo do Conversor Boost	49
4.1.3	Validação da Perturbação por Pequenos Sinais	51

4.2	Resultados da Estimativa dos Parâmetros	52
4.2.1	Implementação do Algoritmo de Identificação	53
4.2.2	Resultados Comparativos dos Parâmetros	53
4.2.3	Análise das Funções de Transferência	53
4.3	Análise da Convergência do Algoritmo Genético	54
4.3.1	Comportamento da Função Objetivo	54
4.3.2	Influência dos Parâmetros do Algoritmo Genético	55
4.4	Análise da Robustez	56
4.4.1	Cenário 1: Introdução de Resistências Parasitas	56
4.4.2	Cenário 2: Limites de Busca $\pm 5\%$ com Resistências Parasitas	56
4.4.3	Cenário 3: Limites de Busca $\pm 10\%$ com Resistências Parasitas	58
4.5	Discussão Geral	59
4.5.1	Limitações do Método	59
4.5.2	Explicação das Discrepâncias Observadas	60
4.5.3	Validação da Abordagem Teórica	60
4.5.4	Sugestões para Melhorias Futuras	60
4.5.5	Contribuições do Trabalho	61
5	CONCLUSÃO	62
5.1	Contribuições do Trabalho	62
5.2	Trabalhos Futuros	63
	REFERÊNCIAS	64
6	ANEXO	66

1 INTRODUÇÃO

1.1 Contextualização e motivação

Os conversores CC–CC constituem a base da moderna eletrônica de potência e figuram como elos indispensáveis na interface entre fontes de energia e cargas eletrônicas (ERICKSON; MAKSIMOVÍĆ, 2020). Ao permitir a adaptação eficiente de níveis de tensão, corrente e potência, esses dispositivos viabilizam desde a operação de circuitos embarcados em equipamentos portáteis até a integração de sistemas de geração renovável e veículos elétricos à rede elétrica.

Entre as topologias mais difundidas destaca-se o conversor *Boost* (elevador), cuja principal característica é elevar a tensão de entrada para um valor superior na saída, preservando – dentro de limites práticos – a transferência de potência desejada (HART, 2011). Tal propriedade torna o *Boost* imprescindível em aplicações fotovoltaicas, correção do fator de potência, fontes de alimentação automotivas, sistemas de iluminação LED e acionamentos de motores em corrente contínua.

O desempenho de qualquer conversor depende diretamente do dimensionamento de seus componentes principais (resistor: R , indutor: L , capacitor: C) e do ciclo de trabalho: (D). Variações não previstas nesses parâmetros provocam degradação de eficiência, instabilidade de controle, aumento de distorções harmônicas e redução da vida útil dos componentes. Dessa forma, a identificação precisa dos parâmetros físicos não é apenas requisito para modelagem fiel, mas um passo essencial para a auto sintonização de controladores, diagnóstico de falhas e manutenção preditiva.

1.2 Justificativa do Trabalho

Os métodos tradicionais de identificação paramétrica – baseados em ensaios laboratoriais ou medições diretas – apresentam restrições práticas: requerem intervenção física no circuito, interrompem o serviço e nem sempre capturam efeitos dinâmicos sob condições reais de operação. Técnicas computacionais de otimização, por outro lado, possibilitam estimar parâmetros *in situ*, a partir de dados de tensão e corrente medidos durante a operação normal do conversor, minimizando custos e riscos de parada (GOLDBERG, 1989).

Entre essas técnicas, o Algoritmo Genético (GA) destaca-se pela capacidade de realizar busca global em espaços multimodais, dispensar informações de derivada e lidar com funções objetivo não lineares e ruidosas. Tais atributos são particularmente valiosos

quando se pretende ajustar simultaneamente vários parâmetros fortemente acoplados – como ocorre no *Boost* – e quando o modelo teórico, derivado por pequenos sinais, carece de ajuste fino para abranger perdas e parasitas.

1.3 Metodologia

Inicialmente, define-se um modelo ideal do conversor *Boost* no SIMULINK, empregando componentes do *Simscape Power Systems*. Em seguida, introduz-se uma perturbação PRBS de baixa amplitude na tensão de entrada, assegurando a validade da linearização por pequenos sinais. As tensões de entrada e saída são registradas e processadas via Transformada Rápida de Fourier (FFT) para obtenção experimental da Função de Transferência (FT) $G_{vg}(s)$.

O núcleo otimização consiste em um AG configurado com codificação real; cada cromossomo contém $[R, L, C, D]$. A função objetivo minimiza o erro quadrático médio normalizado entre as magnitudes das funções de transferência experimental e teórica. Diversos limites de busca ($\pm 1\%$, $\pm 5\%$, $\pm 10\%$) são avaliados a fim de estudar a sensibilidade da identificação. Por fim, os parâmetros estimados são comparados aos valores de projeto, e a robustez do método é avaliada com a inclusão de resistências série equivalentes nos componentes passivos.

1.4 Objetivos

Objetivo Geral

Estimar, por meio de algoritmos genéticos, os parâmetros R , L , C e o *duty cycle* D de um conversor *Boost*, utilizando como métrica de ajuste a função de transferência linha-saída $G_{vg}(s)$.

Objetivos Específicos

1. Modelar e simular o conversor *Boost* no ambiente MATLAB/Simulink, contemplando uma fonte de perturbação PRBS para excitação de pequenos sinais.
2. Deduzir analiticamente a função de transferência $G_{vg}(s)$ a partir do método da média no espaço de estados, estabelecendo a dependência explícita com R , L , C e D .
3. Aplicar a Transformada Rápida de Fourier (FFT) aos sinais simulados e construir a função de transferência experimental.

4. Executar o Algoritmo Genético para minimizar o erro entre $G_{vg}(s)$ teórica e experimental, estimando os parâmetros do circuito.
5. Avaliar a metodologia comparando os parâmetros identificados com os valores de referência adotados no projeto.

O texto está estruturado em cinco capítulos, além do anexo de código e referências:

- **Capítulo 2 – Fundamentação Teórica:** revisa os princípios de operação do conversor *Boost*, apresenta a modelagem em regime permanente, a dedução da função $G_{vg}(s)$ e discute as limitações do modelo de pequenos sinais.
- **Capítulo 3 – Materiais e Métodos:** descreve com detalhe a configuração do sistema, a implementação em SIMULINK, a geração do PRBS, o pré-processamento dos dados e a estrutura do Algoritmo Genético utilizado.
- **Capítulo 4 – Resultados Obtidos:** apresenta a validação do modelo, os resultados de identificação para diferentes limites de busca e a análise da robustez frente a componentes não ideais.
- **Capítulo 5 – Conclusão:** discute criticamente os objetivos alcançados, as contribuições metodológicas e sugestões para extensões futuras.

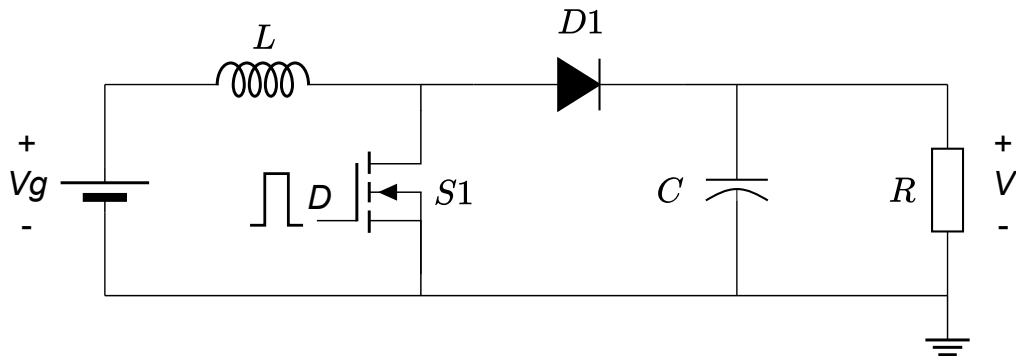
2 FUNDAMENTAÇÃO TEÓRICA

2.1 Conversor Boost

O conversor Boost, também conhecido como conversor elevador, constitui um dos circuitos fundamentais da eletrônica de potência, caracterizando-se por sua capacidade de produzir uma tensão de saída superior à tensão de entrada (ERICKSON; MAKSIMOVIĆ, 2020). Este conversor encontra ampla aplicação em sistemas que demandam elevação de tensão, incluindo sistemas fotovoltaicos, fontes de alimentação ininterrupta e conversores para veículos elétricos (HART, 2011).

A topologia básica do conversor Boost compreende um indutor (L), uma chave semicondutora ($S1$), um diodo ($D1$), um capacitor (C) e uma carga resistiva (R), conforme ilustrado na Figura 1. V , corresponde a tensão de saída elevada a partir da tensão de entrada, V_g . Estes parâmetros teóricos constituem a base para a modelagem desenvolvida nas seções subsequentes.

Figura 1 – Topologia do Conversor Boost



Fonte: Autoria própria

O princípio de funcionamento fundamenta-se no armazenamento temporário de energia no campo magnético do indutor durante o período de condução da chave, seguido pela transferência desta energia para a carga quando a chave é desligada (ERICKSON; MAKSIMOVIĆ, 2020).

A operação do conversor Boost subdivide-se em dois estados distintos, determinados pelo estado da chave semicondutora.

Para a construção do modelo do conversor em regime permanente, foram consideradas as seguintes hipóteses:

1. Todos os componentes do circuito são ideais.
2. O conversor opera em regime permanente.
3. O capacitor de saída do circuito apresenta capacitância suficientemente elevada para considerar a ondulação de tensão na saída aproximadamente constante, isto é:

$$v(t) = V + v_{ripple} \approx V$$

4. O conversor opera no Modo de Condução Contínuo (MCC), ou seja, a corrente no indutor nunca se anula.

2.2 Modelagem Matemática do Conversor Boost

Para determinar os parâmetros teóricos R, L, C e D apresentados na Figura 1, utiliza-se a modelagem em regime permanente do conversor boost, processo descrito na subseção 2.2.1.

A obtenção da função de transferência de linha para a saída, $G_{vg}(s)$, requer o desenvolvimento do modelo em pequenos sinais do conversor, procedimento detalhado na subseção 2.2.2.

2.2.1 Modelo em Regime Permanente no Modo de Condução Contínua (MCC)


A construção do modelo do conversor boost no MCC realiza-se através da análise do conversor em dois estados de operação durante um período completo de acionamento T_s , determinados pela posição da chave semicondutora acionada por meio de um sinal Modulado por Largura de Pulso (PWM). O Estado 1 corresponde a análise durante o semiciclo do PWM em nível alto, indo de zero até o período DT_s . O Estado 2 corresponde a análise do sinal durante o semiciclo em nível baixo, correspondente ao período de DT_s à T_s , conforme exhibe a Figura 4:

- **Estado 1 (Chave fechada, $0 \leq t \leq DT_s$):** Quando a chave encontra-se conduzindo, a corrente flui através do indutor, armazenando energia em seu campo magnético. O diodo permanece reversamente polarizado, isolando a carga do circuito de entrada.
- **Estado 2 (Chave aberta, $DT_s \leq t \leq T_s$):** Quando a chave é aberta, a energia armazenada no indutor é transferida para o capacitor e para a carga através do diodo, que passa a conduzir diretamente.

2.2.1.1 Estado1: S1 conduzindo e D1 bloqueado

A Figura 2 apresenta o modelo em regime permanente do conversor boost durante o primeiro estado.

Figura 2 – Circuito equivalente em regime permanente: chave conduzindo e diodo bloqueado



Fonte: Autoria própria

A análise em regime permanente do conversor Boost inicia-se com o ciclo de condução do interruptor, período no qual o sinal PWM assume nível alto, provocando a condução da chave semicondutora.

Durante este intervalo, o diodo encontra-se reversamente polarizado, impedindo a passagem de corrente para o estágio de saída. Conseqüentemente, a fonte de alimentação transfere energia diretamente para o indutor, provocando o incremento da corrente no indutor, i_L .

Simultaneamente, o capacitor de saída responsabiliza-se por sustentar a carga, fornecendo energia temporariamente, o que resulta em uma leve redução em sua tensão.

Nesta etapa, a tensão no indutor, $v_L(t)$, é expressa-se conforme a Equação 2.1.

$$v_L(t) = V_g = L \frac{di_L}{dt} \quad (2.1)$$

Isolando a corrente no indutor, i_L , na Equação 2.1, obtém-se a corrente no indutor, conforme apresentado na Equação 2.2.

$$i_L = \frac{1}{L} \int V_g dt = \left(\frac{V_g}{L} \right) t + I_{L,min} \quad (2.2)$$

Sendo $I_{L,min}$ a corrente média mínima no indutor.

A corrente no capacitor, $i_C(t)$, expressa-se através da Equação 2.3.

$$i_C(t) = -I_o = -\frac{V}{R} = -C \frac{dv_C}{dt} \quad (2.3)$$


Sendo I_o a corrente média de saída.

Durante esta primeira etapa, observa-se que a corrente na chave semicondutora é igual a corrente no indutor, $i_{S1} = i_L$, e a corrente no diodo é zero, $i_{D1} = 0$. Adicionalmente, a tensão na chave é zero, $v_{S1} = 0$, enquanto que a tensão no diodo é igual a tensão de saída, $v_{D1} = V$.

2.2.1.2 Estado 2: S1 bloqueada e D1 conduzindo

A Figura 3 ilustra o modelo em regime permanente do conversor boost durante o segundo estado.

Figura 3 – Circuito equivalente em regime permanente: chave bloqueada e diodo conduzindo



Fonte: Autoria própria

Na segunda etapa do ciclo de operação, o sinal PWM transita para nível baixo, provocando o bloqueio do interruptor $S1$. Com esta transição, o diodo $D1$ entra naturalmente em condução, assegurando a continuidade do fluxo de corrente proveniente do indutor.

Durante este intervalo, a energia previamente armazenada no indutor é transferida para o circuito. Esta energia flui simultaneamente para o capacitor e para a carga, promovendo o recarregamento do capacitor e mantendo o fornecimento de energia à carga. Como consequência, a corrente no indutor, i_L , apresenta comportamento decrescente ao longo desta etapa.

A tensão no indutor, $v_L(t)$, durante esta etapa expressa-se conforme a Equação 2.4.

$$v_L(t) = V_g - V = L \frac{di_L}{dt} \quad (2.4)$$

A corrente no indutor, i_L , obtida a partir da Equação 2.4, foi matematicamente descrita conforme exibe a Equação 2.5.

$$i_L = \frac{1}{L} \int (V_g - V) dt = \left(\frac{V_g - V}{L} \right) t + I_{L,max} \quad (2.5)$$

Sendo, $I_{L,max}$, a corrente máxima no indutor


A corrente no capacitor, $i_C(t)$, expressa-se através da Equação 2.6.

$$i_C(t) = i_L - I_o = i_L - \frac{V}{R} \quad (2.6)$$

Durante esta segunda etapa, verifica-se que a corrente na chave é zero, $i_{S1} = 0$ e a corrente no diodo é igual a corrente no indutor, $I_{D1} = i_L$. Além disso, a tensão na chave é igual a tensão de saída, $v_{S1} = V$ enquanto que a tensão no diodo é zero, $V_{D1} = 0$.

A Figura 4 apresenta as formas de onda do chaveamento PWM, corrente no indutor, i_L , tensão no indutor, V_L , tensão no capacitor, V_C , corrente no capacitor, i_C , corrente na chave, i_{S1} , corrente no diodo, i_{D1} , tensão no diodo, V_{D1} e corrente na chave, i_{S1} , durante um período de chaveamento completo, T_s , incluindo o período do pulso PWM ligado, $D \cdot T_s$, e desligado, $(1 - D) \cdot T_s$.

Figura 4 – Chaveamento PWM durante período ligado, $D \cdot T_s$, e desligado, $(1 - D) \cdot T_s$ e principais curvas do conversor Boost



Fonte: Autoria própria

2.2.1.3 Ganho estático do conversor: $M(D)$

Fundamentando-se no princípio da conservação de energia, em regime permanente, a tensão média no indutor é nula, $\langle v_L \rangle = 0$. Considerando que, durante a primeira etapa de operação, $D \cdot T_s$, a tensão no indutor equivale à tensão de entrada, V_g , e na segunda etapa, $(1 - D) \cdot T_s$, equivale a $V_g - V$.

A Equação 2.7 expressa a tensão média no indutor.

$$\langle v_L \rangle_{T_s} = V_L = \frac{1}{T_s} \int_0^{T_s} v_L(t) dt = 0 \quad (2.7)$$

Desenvolvendo a integral:

$$\frac{1}{T_s} \int_0^{T_s} v_L(t) dt = \frac{1}{T_s} \left(\int_0^{D \cdot T_s} V_g dt + \int_{D \cdot T_s}^{T_s} (V_g - V) dt \right) = V_g D - (V_g - V)(1 - D) = 0 \quad (2.8)$$

Assim, o ganho estático do conversor, $M(D)$, expressa-se conforme a Equação 2.9.

$$M(D) = \frac{V}{V_g} = \frac{1}{(1 - D)} \quad (2.9)$$

2.2.1.4 Projeto do ciclo de trabalho: D

Isolando D na Equação 2.9, o ciclo de trabalho define-se conforme a Equação 2.10.

$$D = 1 - \frac{V_g}{V} \quad (2.10)$$

2.2.1.5 Determinação da carga resistiva: R

Os parâmetros de potência dissipada na saída, P_o , e tensão de saída, V , constituem elementos necessários para determinar o valor nominal da carga resistiva, R .

A Equação 2.11 apresenta o cálculo do resistor, R .

$$R = \frac{V^2}{P_o} \quad (2.11)$$

2.2.1.6 Projeto do indutor: L

A Figura 4 ilustra as formas de onda da corrente no indutor, i_L , e tensão no indutor, V_L , para o período de chaveamento ligado, $D \cdot T_s$, e desligado, $(1 - D)T_s$.

A Equação 2.1 expressa a tensão no indutor durante a primeira etapa de chaveamento.

Considerando que a variação de corrente corresponde a ΔI_L e que o período de duração desta etapa é $D \cdot T_s$, então:

$$V_{in} = L \frac{di_L}{dt} = L \frac{\Delta I_L}{D \cdot T_s} \quad (2.12)$$

Portanto, a Equação 2.13 apresenta a fórmula para calcular o indutor, isolando L na Equação 2.12.

$$L = \frac{V_g \cdot D}{f_s \cdot \Delta I_L} = \frac{V_g \cdot D / I_L}{\left(\frac{\Delta I_L}{I_L}\right) \cdot f_s} \quad (2.13)$$

Sendo, $f_s = \frac{1}{T_s}$, a frequência de chaveamento da chave semicondutora

2.2.1.7 Projeto do capacitor: C

A Figura 4 ilustra as formas de onda da corrente no diodo, i_{D1} , corrente no capacitor, i_C , e tensão no capacitor, V_C , para o período de chaveamento ligado, $D \cdot T_s$, e desligado, $(1 - D)T_s$.

A Equação 2.3 expressa a corrente no capacitor durante a primeira etapa de chaveamento.

Considerando que a variação de tensão corresponde a ΔV_C e que o período de duração desta etapa é $D \cdot T_s$, então:

$$i_C = I_o = C \frac{dv_C}{dt} \implies \frac{V}{R} = C \frac{\Delta V_C}{D \cdot T_s} \implies \frac{V}{R} = C \frac{\Delta V}{D \cdot T_s} \quad (2.14)$$

Portanto, a Equação 2.15 apresenta a fórmula para calcular o capacitor, isolando C na Equação 2.14.

$$C = \frac{D}{R \cdot \left(\frac{\Delta V}{V}\right) \cdot f_s} \quad (2.15)$$

2.2.2 Modelagem por Pequenos Sinais do Conversor Boost e Dedução da Função de Transferência $G_{vg}(s)$

A modelagem por pequenos sinais constitui uma técnica fundamental para compreender o comportamento dinâmico do conversor Boost, permitindo analisar como variações na tensão de entrada afetam a tensão de saída. Esta abordagem, desenvolvida inicialmente por Middlebrook e Ćuk, (MIDDLEBROOK; ĆUK, 1976), mostra-se essencial para o projeto de sistemas de controle eficientes e para aplicações de identificação paramétrica como a proposta neste trabalho. Esta seção apresenta uma dedução detalhada da função de transferência de linha para saída $G_{vg}(s)$ do conversor Boost operando em modo de condução contínua (MCC).

2.2.2.1 Equações de Estado do Conversor Boost

Para iniciar a modelagem por pequenos sinais, torna-se necessário estabelecer as equações de estado para cada subintervalo de operação do conversor.

Estado 1 (Chave fechada):

$$L \frac{di_L(t)}{dt} = v_g(t) \quad (2.16)$$

$$C \frac{dv(t)}{dt} = -\frac{v(t)}{R} \quad (2.17)$$

Estado 2 (Chave aberta):

$$L \frac{di_L(t)}{dt} = v_g(t) - v(t) \quad (2.18)$$

$$C \frac{dv(t)}{dt} = i_L(t) - \frac{v(t)}{R} \quad (2.19)$$

2.2.2.2 Aplicação do Método da Média no Espaço de Estados

O método da média no espaço de estados (state-space averaging) permite obter um modelo contínuo que representa o comportamento médio do conversor durante um ciclo de comutação. Aplicando este método às equações de estado, obtêm-se:

$$L \frac{d\langle i_L(t) \rangle}{dt} = \langle v_g(t) \rangle - (1 - d(t))\langle v(t) \rangle \quad (2.20)$$

$$C \frac{d\langle v(t) \rangle}{dt} = (1 - d(t))\langle i_L(t) \rangle - \frac{\langle v(t) \rangle}{R} \quad (2.21)$$

onde $\langle x(t) \rangle$ representa o valor médio da variável $x(t)$ ao longo de um período de comutação T_s , e $d(t)$ constitui a razão cíclica instantânea.

2.2.2.3 Linearização em Torno do Ponto de Operação

Para obter o modelo de pequenos sinais, linearizam-se as equações médias em torno de um ponto de operação em regime permanente. Define-se:

$$\langle v_g(t) \rangle = V_g + \hat{v}_g(t) \quad (2.22)$$

$$\langle i_L(t) \rangle = I_L + \hat{i}_L(t) \quad (2.23)$$

$$\langle v(t) \rangle = V + \hat{v}(t) \quad (2.24)$$

$$d(t) = D + \hat{d}(t) \quad (2.25)$$

onde V_g , I_L , V e D representam os valores de regime permanente, e $\hat{v}_g(t)$, $\hat{i}_L(t)$, $\hat{v}(t)$ e $\hat{d}(t)$ constituem pequenas variações em torno desses valores.

Substituindo estas expressões nas equações médias e desprezando os termos de segunda ordem (produtos de pequenas variações), obtêm-se as equações linearizadas:


$$L \frac{d\hat{i}_L(t)}{dt} = \hat{v}_g(t) - (1 - D)\hat{v}(t) + V\hat{d}(t) \quad (2.26)$$

$$C \frac{d\hat{v}(t)}{dt} = (1 - D)\hat{i}_L(t) - \frac{\hat{v}(t)}{R} - I_L\hat{d}(t) \quad (2.27)$$

2.2.2.4 Modelo de Pequenos Sinais do Conversor Boost

A partir das equações linearizadas, constrói-se o modelo de pequenos sinais do conversor Boost, representado na Figura 5, considerando $D' = 1 - D$.

Figura 5 – Modelo de pequenos sinais do conversor Boost para análise da função de transferência $G_{vg}(s)$.



Fonte: Adaptado de (ERICKSON; MAKSIMOVIĆ, 2020)

Este modelo mostra-se particularmente útil para analisar como pequenas variações na tensão de entrada $\hat{v}_g(t)$ afetam a tensão de saída $\hat{v}(t)$, que constitui precisamente o que a função de transferência $G_{vg}(s)$ descreve.

2.2.2.5 Dedução da Função de Transferência $G_{vg}(s)$

Para deduzir a função de transferência $G_{vg}(s)$, considera-se apenas o efeito de variações na tensão de entrada, fazendo $\hat{d}(s) = 0$. Aplicando a transformada de Laplace às equações linearizadas, obtêm-se:

$$sL\hat{i}_L(s) = \hat{v}_g(s) - (1 - D)\hat{v}(s) \quad (2.28)$$

$$sC\hat{v}(s) = (1 - D)\hat{i}_L(s) - \frac{\hat{v}(s)}{R} \quad (2.29)$$

Isolando $\hat{i}_L(s)$ na primeira equação:

$$\hat{i}_L(s) = \frac{\hat{v}_g(s) - (1 - D)\hat{v}(s)}{sL} \quad (2.30)$$

Substituindo na segunda equação:

$$sC\hat{v}(s) = (1 - D)\frac{\hat{v}_g(s) - (1 - D)\hat{v}(s)}{sL} - \frac{\hat{v}(s)}{R} \quad (2.31)$$

Reorganizando os termos:

$$sC\hat{v}(s) + \frac{\hat{v}(s)}{R} + \frac{(1 - D)^2\hat{v}(s)}{sL} = \frac{(1 - D)\hat{v}_g(s)}{sL} \quad (2.32)$$

Multiplicando todos os termos por sL :

$$s^2LC\hat{v}(s) + \frac{sL\hat{v}(s)}{R} + (1 - D)^2\hat{v}(s) = (1 - D)\hat{v}_g(s) \quad (2.33)$$

Isolando a razão $\hat{v}(s)/\hat{v}_g(s)$, que define $G_{vg}(s)$:

$$G_{vg}(s) = \frac{\hat{v}(s)}{\hat{v}_g(s)} = \frac{(1 - D)}{s^2LC + \frac{sL}{R} + (1 - D)^2} \quad (2.34)$$

Dividindo numerador e denominador por $(1 - D)^2$:

$$G_{vg}(s) = \frac{1}{(1 - D)} \cdot \frac{1}{\frac{s^2LC}{(1 - D)^2} + \frac{sL}{R(1 - D)^2} + 1} \quad (2.35)$$

Esta expressão pode ser reescrita na forma padrão:

$$G_{vg}(s) = G_{g0} \cdot \frac{1}{1 + \frac{s}{Q\omega_0} + \left(\frac{s}{\omega_0}\right)^2} \quad (2.36)$$

onde:

$$G_{g0} = \frac{1}{1 - D} \quad (2.37)$$

$$\omega_0 = \frac{1 - D}{\sqrt{LC}} \quad (2.38)$$

$$Q = (1 - D)R\sqrt{\frac{C}{L}} \quad (2.39)$$

2.2.2.6 Interpretação Física dos Parâmetros

Os parâmetros da função de transferência $G_{vg}(s)$ possuem interpretações físicas importantes:

- **Ganho DC (G_{g0}):** Representa a relação de conversão do conversor Boost em regime permanente. Como esperado, o ganho corresponde a $1/(1 - D)$, que constitui a conhecida relação de conversão do Boost.

- **Frequência de ressonância (ω_0):** Representa a frequência natural do sistema. Observa-se que esta frequência é modulada pelo ciclo de trabalho $(1-D)$, significando que a resposta dinâmica do conversor varia com o ponto de operação.
- **Fator de qualidade (Q):** Determina o amortecimento da resposta. Um valor elevado de Q indica um sistema subamortecido, que pode apresentar sobressinal significativo na resposta transitória.

A Tabela 1 resume os parâmetros da função de transferência $G_{vg}(s)$ para o conversor Boost.

Tabela 1 – Parâmetros da função de transferência $G_{vg}(s)$ para o conversor Boost.

Conversor	G_{g0}	ω_o	Q
Boost	$\frac{1}{(1-D)}$	$\frac{(1-D)}{\sqrt{LC}}$	$(1-D)R\sqrt{\frac{C}{L}}$

Fonte: Adaptado de (ERICKSON; MAKSIMOVIĆ, 2020)

2.2.2.7 Limitações do Modelo de Pequenos Sinais e Considerações sobre Efeitos Não-Ideais no Conversor Boost

A análise do conversor Boost por meio da modelagem em pequenos sinais, embora amplamente adotada no projeto de controladores e na análise dinâmica, apresenta limitações quando confrontada com fenômenos reais e não-lineares presentes nos sistemas de potência. Com base na literatura especializada e nos avanços contemporâneos em modelagem de conversores, as principais limitações e efeitos não-ideais podem ser classificados em categorias distintas, conforme descrito a seguir.

- **Limitações Fundamentais do State-Space Averaging**

O método de *state-space averaging* opera como um filtro passa-baixas natural, com frequência de corte tipicamente entre $f_s/3$ e $f_s/2$, onde f_s é a frequência de chaveamento, (BIOLKOVÁ; KOLKA; BIOLEK, 2010). Acima deste limite, a acurácia do modelo decresce de forma acentuada, violando as hipóteses de variações lentas das variáveis de estado.

Além disso, o modelo supõe pequenas ondulações nas correntes dos indutores e nas tensões dos capacitores, o que exige que $\Delta i_L/I_L \ll 1$ e $\Delta v_C/V_C \ll 1$, (BAI; BAE, 2024). Essa condição nem sempre é satisfeita, especialmente em aplicações de alta corrente ou com baixa frequência de chaveamento. A linearização do modelo em

torno do ponto de operação também limita sua validade a pequenas perturbações, sendo inadequada para mudanças significativas de regime, (OMIDI; JAMIL, 2022).

- **Efeitos Parasitas em Componentes Passivos**

Os componentes passivos introduzem resistências série equivalentes (ESR) que impactam diretamente o comportamento dinâmico e a eficiência do conversor. A ESR do capacitor, por exemplo, afeta a ondulação da tensão de saída e adiciona zeros à função de transferência. A ESR do indutor reduz a eficiência e altera a resposta transitória. Além disso, capacitâncias e indutâncias parasitas, como aquelas presentes entre camadas de enrolamentos ou nas trilhas do PCB, provocam ressonâncias, EMI e perdas adicionais, (CHOUDHURY; NAYAK, 2016).

- **Não-Linearidades dos Componentes Magnéticos**

A saturação magnética impõe um comportamento não-linear, com variação da permeabilidade e perda de indutância em altos níveis de corrente. Esses efeitos não são contemplados em modelos lineares. Perdas no núcleo, como as de histerese e por correntes parasitas, são fortemente dependentes da frequência e da temperatura, exigindo consideração cuidadosa na modelagem térmica e magnética do sistema, (RAVERA et al., 2024).

- **Limitações dos Dispositivos Semicondutores**

Os semicondutores empregados apresentam características não ideais, como tempos de comutação finitos, resistência de condução dependente da temperatura e capacitâncias parasitas que afetam a estabilidade em alta frequência. Diodos, por sua vez, introduzem quedas de tensão direta, perdas por recuperação reversa e capacitâncias de junção que interferem na resposta dinâmica do sistema, (KO et al., 2023).

- **Efeitos Térmicos e Ambientais**

A temperatura exerce influência direta sobre praticamente todos os parâmetros do sistema. A resistência dos condutores aumenta com o aquecimento ($\sim 0,4\%/^{\circ}\text{C}$ para cobre), enquanto a performance de semicondutores e propriedades magnéticas também se degradam com o tempo e o uso. Envelhecimento de capacitores eletrolíticos, por exemplo, acarreta aumento de ESR e redução da capacitância ao longo do tempo, (REN; GONG; ZHAO, 2019).

- **Limitações de Modo de Condução**

O modelo de pequenos sinais é rigorosamente válido apenas em regime de Condução Contínua (CCM). Na proximidade da transição para Condução Descontínua (DCM),

ocorrem alterações significativas na ordem do sistema e nas funções de transferência. A não-linearidade inerente à fronteira entre CCM e DCM torna o modelo tradicional ineficaz nesses regimes híbridos, (CHOUDHURY; NAYAK, 2016).

- **Efeitos de Alta Frequência**

Em altas frequências, efeitos como o *skin effect* e o efeito de proximidade aumentam a resistência efetiva dos condutores, provocando perdas AC adicionais. Além disso, a interferência eletromagnética (EMI), tanto conduzida quanto irradiada, surge como resultado de acoplamentos parasitas e rápidas transições de chaveamento, e não é capturada pelos modelos lineares tradicionais, (KUNSTBERGS et al., 2024).

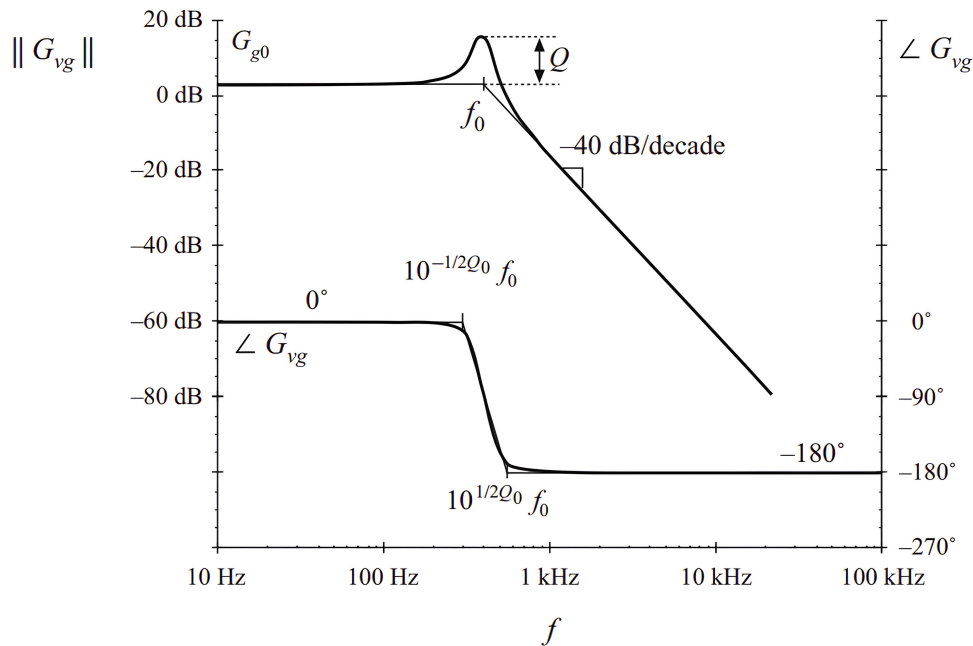
- **Considerações para Modelagem Avançada**

Para mitigar as limitações supracitadas, abordagens mais robustas têm sido propostas, como o uso de modelos de ordem superior que incluem explicitamente elementos parasitas e não-linearidades magnéticas, além de modelos adaptativos capazes de ajustar seus parâmetros em tempo real. Estratégias de controle robusto também são adotadas para compensar incertezas paramétricas e variações ambientais, garantindo maior fidelidade no desempenho do conversor em aplicações reais, (ELMA; GOLI; TIDA, 2025).

2.2.2.8 Resposta em Frequência

A resposta em frequência de $G_{vg}(s)$ caracteriza-se por um diagrama de Bode conforme apresentado na Figura 6.

Figura 6 – Diagrama de Bode da função de transferência $G_{vg}(s)$ do conversor Boost.



Fonte: Adaptado de (ERICKSON; MAKSIMOVIC, 2020)

O diagrama de Bode apresenta características importantes:

- **Baixas frequências** ($f \ll f_0$): O ganho mantém-se constante e igual a $G_{g0} = 1/(1 - D)$, com fase próxima de 0° .
- **Frequência de ressonância** ($f = f_0$): Ocorre um pico de magnitude se $Q > 1/\sqrt{2}$, com valor $|G_{vg}(j\omega_0)| = G_{g0} \cdot Q$. A fase equivale a -90° .
- **Altas frequências** ($f \gg f_0$): O ganho decresce com uma inclinação de -40 dB/década, e a fase aproxima-se de -180° .

2.2.2.9 Implicações para o Projeto de Controle

A função de transferência $G_{vg}(s)$ apresenta implicações importantes para o projeto de sistemas de controle:

- A presença de dois polos complexos conjugados pode conduzir a ressonâncias indesejáveis se não forem adequadamente amortecidas.
- O ganho DC aumenta com o ciclo de trabalho D , significando que o sistema torna-se mais sensível a perturbações na entrada à medida que D se aproxima de 1.
- A frequência de ressonância ω_0 diminui com o aumento de D , o que pode limitar a largura de banda do sistema de controle em pontos de operação com alto ganho.

Estas características devem ser consideradas ao projetar compensadores para sistemas de controle que utilizam o conversor Boost, especialmente quando se deseja rejeição de perturbações na tensão de entrada.

2.2.2.10 Escolha de $G_{vg}(s)$ na Determinação dos Parâmetros do Conversor Boost

A função de transferência $G_{vg}(s)$ do conversor Boost constitui uma ferramenta para compreender como perturbações na tensão de entrada afetam a tensão de saída. Sua forma de segunda ordem revela a natureza dinâmica do conversor e fornece ideias para o projeto de sistemas de controle robustos.

A dedução apresentada nesta seção demonstra como o método da média no espaço de estados, seguido de linearização, permite obter um modelo matemático preciso que captura o comportamento dinâmico do conversor Boost em torno de um ponto de operação.

Esta função de transferência constitui a base teórica para a metodologia de identificação paramétrica proposta neste trabalho, uma vez que envolve todos os parâmetros do circuito.

2.3 Identificação de Parâmetros em Circuitos Elétricos

A identificação de parâmetros em sistemas de eletrônica de potência constitui uma área de crescente importância devido à necessidade de modelos precisos para simulação, controle e diagnóstico de conversores (ERICKSON; MAKSIMOVÍĆ, 2020). Este processo consiste na determinação dos valores dos componentes do circuito a partir de medições experimentais ou simuladas, dispensando a necessidade de acesso físico direto aos elementos do sistema.

2.3.1 Métodos Tradicionais vs. Métodos Computacionais

Os métodos tradicionais de identificação de parâmetros em circuitos elétricos compreendem técnicas como:

- **Medição direta:** Utilização de instrumentos de medição (multímetros, ponte de impedância, analisadores de espectro) para determinar diretamente os valores dos componentes;
- **Análise de resposta ao degrau:** Aplicação de sinais degrau e análise da resposta temporal para extrair parâmetros do sistema;
- **Análise harmônica:** Injeção de sinais senoidais de diferentes frequências e análise da resposta em amplitude e fase.

Embora eficazes, estes métodos apresentam limitações, especialmente quando aplicados a sistemas complexos ou em operação (HART, 2011). As principais desvantagens incluem:

- Necessidade de acesso físico aos componentes do circuito;
- Possibilidade de interferência na operação normal do sistema;
- Dificuldade em isolar o efeito de componentes específicos em topologias complexas;
- Limitações na presença de não-linearidades e elementos parasitas.

Como alternativa, os métodos computacionais de identificação de parâmetros têm conquistado destaque devido às suas vantagens, (GERBER; MWANIKI; VERMEULEN, 2023):

- **Não-invasividade:** Capacidade de identificar parâmetros sem interferir na operação normal do sistema;
- **Robustez:** Habilidade de lidar com ruído e incertezas nas medições;
- **Flexibilidade:** Aplicabilidade a diferentes topologias e condições de operação;
- **Precisão:** Potencial para alcançar alta precisão na estimativa dos parâmetros.

2.3.2 Identificação no Domínio da Frequência

A identificação no domínio da frequência constitui uma abordagem que utiliza a resposta em frequência do sistema para estimar seus parâmetros (GERBER; MWANIKI; VERMEULEN, 2023). Esta técnica fundamenta-se na aplicação de sinais de excitação com amplo conteúdo espectral, como sequências pseudoaleatórias binárias (PRBS), seguida pela análise da resposta do sistema através de técnicas de processamento de sinais.

O processo de identificação no domínio da frequência pode ser resumido nas seguintes etapas:

1. **Excitação do sistema:** Aplicação de um sinal de entrada com características espectrais adequadas;
2. **Aquisição de dados:** Registro simultâneo dos sinais de entrada e saída do sistema;
3. **Análise espectral:** Cálculo das transformadas de Fourier dos sinais adquiridos;
4. **Estimação da função de transferência:** Determinação da função de transferência experimental através da razão entre os espectros de saída e entrada;

5. **Identificação paramétrica:** Ajuste dos parâmetros do modelo teórico para minimizar a diferença entre as funções de transferência experimental e teórica.

A utilização da Transformada Rápida de Fourier (FFT) permite o cálculo eficiente da função de transferência experimental:

$$G_{exp}(j\omega) = \frac{Y(j\omega)}{X(j\omega)} \quad (2.40)$$

onde $X(j\omega)$ e $Y(j\omega)$ representam as transformadas de Fourier dos sinais de entrada e saída, respectivamente.

2.3.3 Sinais de Excitação PRBS

As sequências pseudoaleatórias binárias (PRBS) constituem sinais determinísticos que apresentam propriedades espectrais similares às do ruído branco, tornando-as ideais para a identificação de sistemas (GERBER; MWANIKI; VERMEULEN, 2023). As principais características dos sinais PRBS incluem:

- **Ampla conteúdo espectral:** Energia distribuída uniformemente em uma ampla faixa de frequências;
- **Propriedades de autocorrelação:** Função de autocorrelação próxima à de um impulso;
- **Amplitude constante:** Evita a saturação de componentes do sistema;
- **Facilidade de implementação:** Pode ser facilmente gerada por registradores de deslocamento com realimentação linear.

A sequência PRBS de comprimento $N = 2^n - 1$ é gerada por um registrador de deslocamento de n estágios com realimentação apropriada. A densidade espectral de potência de uma sequência PRBS ideal expressa-se por:

$$S_{PRBS}(\omega) = \frac{A^2}{N} \sum_{k=1}^{N-1} \left[\frac{\sin(\omega T_b k/2)}{\omega T_b k/2} \right]^2 \quad (2.41)$$

onde A representa a amplitude do sinal, T_b constitui a duração de cada bit e N corresponde ao comprimento da sequência.

2.4 Algoritmos Genéticos (GA)

Os Algoritmos Genéticos (GA) representam uma classe de técnicas de otimização bioinspiradas, fundamentadas nos princípios da evolução natural e da genética (GOLDBERG, 1989). Desenvolvidos por John Holland na década de 1970, os GAs têm sido amplamente aplicados em problemas de otimização complexos, incluindo a identificação de parâmetros em sistemas de eletrônica de potência.

2.4.1 Fundamentos Teóricos

Os algoritmos genéticos operam sobre uma população de soluções candidatas, denominadas indivíduos ou cromossomos, que evoluem ao longo de gerações sucessivas através de operadores inspirados nos mecanismos de reprodução, mutação e seleção natural. Cada indivíduo representa uma possível solução para o problema de otimização e é avaliado por uma função objetivo que quantifica sua qualidade ou *fitness*.

O processo evolutivo dos GAs pode ser descrito matematicamente como:

$$P_{t+1} = \mathcal{O}(P_t) \quad (2.42)$$

onde P_t representa a população na geração t , P_{t+1} constitui a população na geração seguinte, e \mathcal{O} representa o operador de evolução que combina seleção, cruzamento e mutação.

2.4.2 Estrutura Básica do Algoritmo Genético

Neste trabalho, foi adotada a seguinte estrutura do algoritmo genético para identificar os parâmetros do conversor boost:

1. **Inicialização:** Geração de uma população inicial P_0 de N indivíduos, tipicamente de forma aleatória dentro do espaço de busca definido;
2. **Avaliação:** Cálculo da função objetivo $f(x_i)$ para cada indivíduo x_i da população;
3. **Seleção por ranqueamento:** Escolha de indivíduos para reprodução com base em sua aptidão (*fitness*);
4. **Cruzamento (*Crossover*):** Fração percentual fixa da combinação de pares de indivíduos selecionados para gerar descendentes;
5. **Mutação:** Aplicação de pequenas alterações aleatórias nos descendentes de forma adaptativa;

6. **Substituição:** Formação da nova população substituindo indivíduos da geração anterior;
7. **Critério de parada:** Verifica se os critérios de convergência foram atendidos ou se o número máximo de gerações definida foi atingida.

2.4.3 Operadores Genéticos

Seleção: O operador de seleção determina quais indivíduos terão maior probabilidade de reprodução. Métodos comuns incluem:

- **Seleção por roleta:** A probabilidade de seleção é proporcional ao fitness do indivíduo;
- **Seleção por torneio:** Competição entre um subconjunto aleatório de indivíduos;
- **Seleção por ranqueamento:** Baseada na ordenação dos indivíduos por fitness.

Cruzamento: O operador de cruzamento combina informações genéticas de dois indivíduos pais para gerar descendentes. Para codificação real, operadores típicos incluem:

$$x_1^{new} = \alpha x_1^{old} + (1 - \alpha)x_2^{old} \quad (2.43)$$

$$x_2^{new} = (1 - \alpha)x_1^{old} + \alpha x_2^{old} \quad (2.44)$$

onde α constitui um parâmetro de mistura, frequentemente escolhido aleatoriamente no intervalo $[0, 1]$.

Mutação: A mutação introduz diversidade genética na população, prevenindo a convergência prematura. Para codificação real, a mutação gaussiana é comumente utilizada:

$$x^{new} = x^{old} + \sigma \cdot \mathcal{N}(0, 1) \quad (2.45)$$

onde σ representa o desvio padrão da mutação e $\mathcal{N}(0, 1)$ constitui uma variável aleatória com distribuição normal padrão.

2.4.4 Aplicação em Identificação de Parâmetros

Na aplicação dos AGs para identificação de parâmetros em conversores de potência, cada indivíduo da população representa um conjunto de valores para os parâmetros a serem estimados. Para o conversor Boost, um cromossomo típico seria:

$$\mathbf{x} = [R, L, C, D]^T \quad (2.46)$$

A função objetivo é formulada para minimizar a diferença entre o comportamento observado do sistema e o previsto pelo modelo teórico. Uma formulação típica para a identificação baseada na função de transferência é:

$$f(\mathbf{x}) = \sum_{i=1}^{N_f} w_i |G_{exp}(j\omega_i) - G_{teo}(j\omega_i, \mathbf{x})|^2 \quad (2.47)$$

onde $G_{exp}(j\omega_i)$ representa a função de transferência experimental, $G_{teo}(j\omega_i, \mathbf{x})$ constitui a função de transferência teórica parametrizada pelo vetor \mathbf{x} , N_f corresponde ao número de pontos de frequência, e w_i representam pesos que podem ser utilizados para enfatizar certas faixas de frequência.

Para garantir soluções fisicamente viáveis, restrições são incorporadas através de funções de penalização:

$$f_{penalizada}(\mathbf{x}) = f(\mathbf{x}) + \sum_j \lambda_j \max(0, g_j(\mathbf{x})) \quad (2.48)$$

onde $g_j(\mathbf{x})$ representam as restrições de desigualdade (por exemplo, $R, L, C > 0$ e $0 < D < 1$) e λ_j constituem os fatores de penalização.

2.4.5 Critérios de Convergência

A convergência do algoritmo genético pode ser avaliada através de diferentes critérios:

- **Número máximo de gerações:** Critério simples baseado em um limite pré-definido;
- **Estagnação do fitness:** Parada quando não há melhora significativa por um número determinado de gerações;
- **Convergência da população:** Quando a diversidade genética cai abaixo de um limiar estabelecido;
- **Precisão desejada:** Quando o melhor fitness atinge um valor objetivo pré-definido.

A taxa de convergência pode ser quantificada através do parâmetro:

$$\gamma_t = \frac{f_{best}(t) - f_{best}(t-1)}{f_{best}(t-1)} \quad (2.49)$$

onde $f_{best}(t)$ representa o melhor fitness na geração t .

2.4.6 Avanços Recentes na Identificação Paramétrica com Algoritmos Genéticos

Os algoritmos genéticos (GA) têm se consolidado como uma ferramenta na identificação paramétrica de sistemas dinâmicos, especialmente em contextos nos quais os modelos analíticos são não-lineares, incertos ou não disponíveis de forma explícita, (GOLDBERG, 1989). A sua natureza estocástica, aliada à capacidade de explorar eficientemente espaços de busca complexos, tem promovido aplicações cada vez mais robustas e inovadoras em eletrônica de potência, sistemas de armazenamento de energia e controle de acionamentos elétricos.

1. Inversores Conectados à Rede com Filtros LCL

O trabalho de (GERBER; MWANIKI; VERMEULEN, 2023), propõe-se uma metodologia em duas etapas para estimar os parâmetros de controle e filtragem de um inversor monofásico conectado à rede por meio da análise da impedância de saída. Inicialmente, utiliza-se um algoritmo genético para minimizar o erro quadrático médio entre a impedância experimental, obtida via perturbações pseudoaleatórias *in situ*, e a resposta de um modelo paramétrico ajustável. Esse modelo é estruturado com sete parâmetros a serem estimados: os ganhos proporcional e ressonante do controlador de corrente (k_p , k_i), as frequências de sintonia (ω_{pr} , ω_g), e os componentes do filtro LCL (C_f , L_f , L_g). A função-objetivo também incorpora o coeficiente de correlação escalado para garantir consistência espectral.

Após a convergência inicial com o AG, os parâmetros são refinados por meio de um algoritmo de enxame de partículas, com foco na minimização do erro entre as formas de onda de tensão e corrente obtidas do modelo e do sistema real. Essa abordagem híbrida demonstrou elevada precisão, com erros inferiores a 0,05% em todos os parâmetros estimados ao final do processo.

Os resultados evidenciam que algoritmos genéticos, quando combinados com fontes de excitação adequadas (como PRBS ou PRIS) e técnicas de sensibilidade em frequência, podem viabilizar a identificação confiável de modelos dinâmicos mesmo em estruturas comerciais opacas. Essa capacidade fortalece o uso de AGs como ferramenta prática e robusta para engenharia de controle e modelagem de sistemas eletrônicos de potência conectados à rede.

2. Sistemas de Armazenamento com Baterias de Íons de Lítio

Os algoritmos genéticos (GA) têm se destacado como ferramentas robustas na estimação de parâmetros em modelos fracionários, conforme discutido por (GUO et al., 2023).

No estudo, os autores propõem um modelo de ordem fracionária (FOM) baseado na definição de Grünwald-Letnikov, o qual é derivado de dados experimentais de espectroscopia de impedância eletroquímica. O modelo incorpora elementos do tipo ZARC e componentes do tipo Warburg para representar com maior fidelidade os efeitos de difusão e dispersão associados ao comportamento eletroquímico da bateria.

A estratégia de identificação paramétrica combina um filtro de Kalman Unscented (UKF), responsável pela estimação dos estados internos do modelo, com um algoritmo genético adaptativo (AGA), projetado para identificar online os parâmetros do FOM. O vetor de parâmetros estimado inclui resistências ôhmicas, capacitâncias fracionárias e a ordem fracionária associada aos elementos de dispersão. A função-objetivo do GA é definida como o erro quadrático médio (RMSE) entre a tensão terminal estimada e a medida, permitindo monitoramento contínuo da acurácia do modelo.

A metodologia foi validada experimentalmente utilizando uma bateria ternária de 113 Ah, sob diferentes temperaturas (0°C e 45°C). Os resultados demonstraram elevada precisão na previsão da tensão terminal, com erro reduzido mesmo em ambientes operacionais adversos. Além disso, a estratégia demonstrou ser eficaz na mitigação dos efeitos da explosão de dados históricos, empregando uma janela deslizante com memória limitada.

O uso combinado de UKF e AG adaptativo permitiu capturar, com elevada fidelidade, a dinâmica não linear e fracionária do sistema, superando as limitações dos modelos de circuitos equivalentes tradicionais. Esta abordagem se apresenta como promissora para aplicações em Sistema de Gerenciamento de Bateria BMS avançados, com potencial para operação em tempo real e adaptação a condições variáveis de carga e temperatura.

3. Identificação Paramétrica em Motores Síncronos

A identificação precisa de parâmetros em motores síncronos de ímã permanente de rotor interno (IPMSM) é essencial para o desempenho robusto de estratégias de controle vetorial. Em cenários práticos, as características do motor sofrem variações com o tempo e com as condições de operação, prejudicando a eficácia de técnicas tradicionais de desacoplamento entre os eixos d e q . Diante desse desafio, o uso de algoritmos genéticos (GA) tem se mostrado promissor como uma abordagem adaptativa e eficaz para a estimação online desses parâmetros.

A proposta investigada por (PAN et al., 2021) introduz uma arquitetura de controle com compensação por alimentação direta (*feedforward*) baseada na identificação de parâmetros via algoritmo genético. A estratégia utiliza um modelo discreto do IPMSM, cujos coeficientes associados às indutâncias, resistência e fluxo de rotor são mapeados para cromossomos binários no GA. A função-objetivo é definida como o erro quadrático entre as correntes reais e previstas dos eixos d e q , sendo minimizada ao longo das gerações.

A implementação considera uma população de 20 indivíduos, codificados em 10 bits por parâmetro, abrangendo os intervalos: $R \in [0, 0,01] \Omega$, $L_d \in [50, 100] \mu\text{H}$, $L_q \in [150, 200] \mu\text{H}$ e $\psi_f \in [0, 0,05] \text{Wb}$. Com taxa de cruzamento de 60% e mutação de 1%, o algoritmo mostrou convergência estável em aproximadamente 50 gerações, atingindo erro inferior a 3% para todos os parâmetros.

A atualização dos parâmetros estimados ocorre em tempo real, com ciclo de controle de 0,1 ms, permitindo a injeção de tensões compensatórias u_d e u_q ajustadas às condições instantâneas do motor. Os resultados experimentais demonstraram melhora significativa no desacoplamento entre os eixos, com redução expressiva no sobresinal das correntes frente a variações de carga.


Dessa forma, a aplicação de algoritmos genéticos à identificação paramétrica em IPMSMs representa uma alternativa robusta, adaptativa e eficiente para aprimorar o desempenho dinâmico de sistemas de acionamento modernos, superando as limitações dos métodos convencionais frente às incertezas paramétricas.

3 MATERIAIS E MÉTODOS

Este capítulo apresenta a metodologia desenvolvida para identificação paramétrica do conversor Boost utilizando algoritmos genéticos.

A Figura 7 exibe o fluxograma da metodologia proposta para a identificação dos parâmetros do conversor boost.

Figura 7 – Metodologia proposta para a identificação dos parâmetros



Fonte: Autoria própria

A abordagem proposta fundamenta-se na análise da função de transferência de linha para saída $G_{vg}(s)$, obtida através de simulações computacionais com sinais de excitação pseudoaleatória binária (PRBS). O processo metodológico compreende desde a definição dos parâmetros do sistema até a validação dos resultados obtidos através de técnicas de otimização metaheurística.

3.1 Descrição do Sistema

O conversor Boost analisado neste trabalho foi dimensionado para atender especificações típicas de aplicações industriais, considerando requisitos de potência, tensão e qualidade dos sinais de saída. A definição dos parâmetros do sistema constitui etapa fundamental para estabelecer os valores de referência que serão posteriormente identificados pelo algoritmo genético.

3.1.1 Especificações e Parâmetros do Conversor

Os parâmetros do conversor Boost foram definidos considerando uma aplicação de elevação de tensão com características representativas de sistemas industriais. A Tabela 2 apresenta as especificações adotadas para o dimensionamento do sistema.

Tabela 2 – Parâmetros de projeto do conversor Boost

Parâmetro	Símbolo	Valor
Tensão de entrada	V_g	50 V
Tensão de saída	V	100 V
Potência de saída	P_o	750 W
Frequência de chaveamento	f_s	20 kHz
Ondulação relativa da corrente no indutor	$\frac{\Delta I_L}{I_L}$	10% (0,1)
Ondulação relativa da tensão de saída	$\frac{\Delta V}{V}$	5% (0,05)

Fonte: Autoria própria

A partir das especificações apresentadas na Tabela 2, os valores teóricos dos componentes do conversor foram calculados utilizando as equações de projeto desenvolvidas no Capítulo 2. O ciclo de trabalho foi determinado através da relação fundamental $D = 1 - \frac{V_g}{V}$, resultando em $D = 0,5$. O resistor de carga foi dimensionado pela relação $R = \frac{V^2}{P_o}$, obtendo-se $R = 13,33 \Omega$. O indutor foi calculado considerando a ondulação de corrente especificada, resultando em $L = 822 \mu\text{H}$. O capacitor foi dimensionado para atender a especificação de ondulação de tensão, obtendo-se $C = 40 \mu\text{F}$.

3.1.2 Estrutura Física e Configuração no Simulink

A implementação do conversor Boost foi realizada utilizando o ambiente de simulação MATLAB/Simulink (The MathWorks Inc., 2024b), que oferece bibliotecas especializadas para modelagem de sistemas de eletrônica de potência. O modelo utilizado baseou-se na configuração padrão disponibilizada pela MathWorks (The MathWorks Inc., 2024a), adaptada para as especificações do presente trabalho.

A escolha do MATLAB/Simulink justifica-se pela disponibilidade de toolboxes especializados em eletrônica de potência, incluindo o Simscape Power Systems, que permite modelagem precisa de componentes semicondutores e elementos passivos. Adicionalmente, o ambiente integra ferramentas de processamento de sinais essenciais para a análise espectral requerida pela metodologia de identificação proposta.

3.2 Implementação do Modelo no Simulink

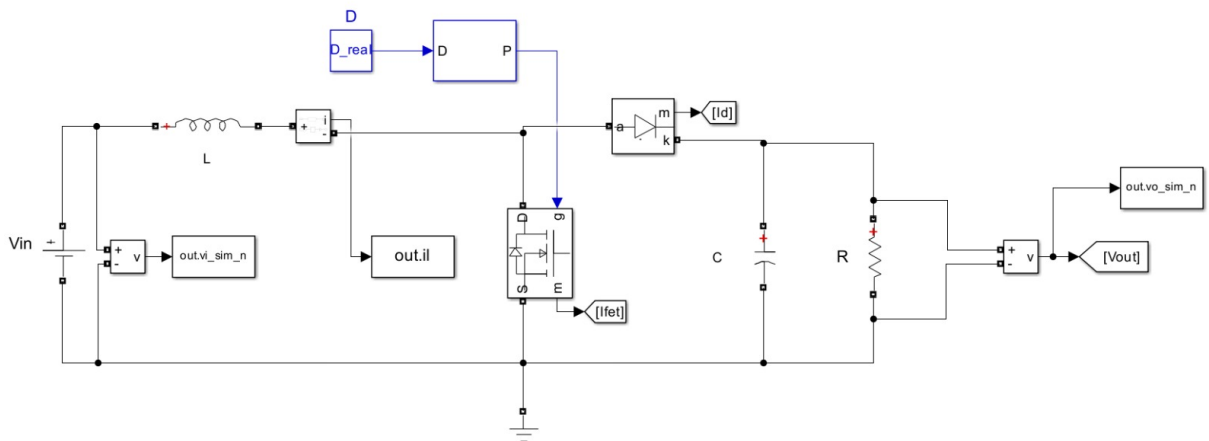
A implementação computacional do conversor Boost foi desenvolvida considerando dois cenários operacionais: operação em regime permanente e operação com perturbação controlada na tensão de entrada. Esta abordagem dual permite a extração da função de transferência experimental através da análise comparativa dos sinais de saída.

3.2.1 Componentes e Configuração do Sistema

O modelo do conversor foi implementado utilizando componentes da biblioteca Simscape Power Systems, que oferece representações físicas precisas dos elementos de circuito. A configuração inclui fonte de tensão controlada, elementos passivos (indutor e capacitor), chave semicondutora ideal, diodo de roda livre e carga resistiva.

A Figura 8 apresenta o modelo básico do conversor Boost implementado no Simulink, configurado para operação em regime permanente. Este modelo serve como referência para a obtenção dos sinais não perturbados necessários ao cálculo da função de transferência experimental.

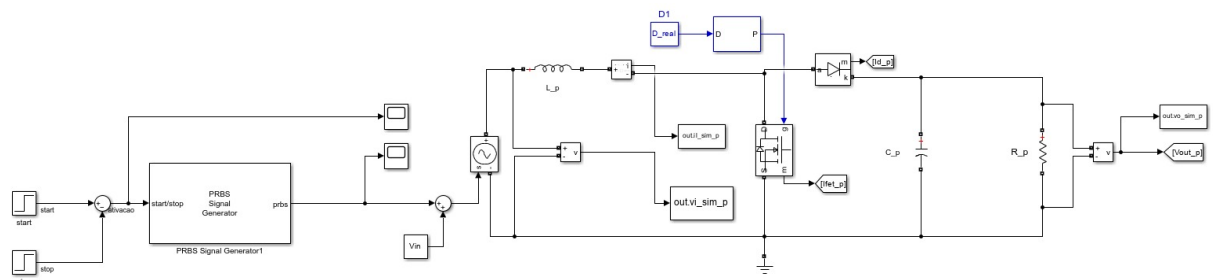
Figura 8 – Modelo do conversor Boost no Simulink sem perturbação



Fonte: Autoria própria

Para a identificação paramétrica, foi desenvolvida uma versão modificada do modelo incorporando fonte de perturbação PRBS na tensão de entrada, conforme ilustrado na Figura 9. Esta configuração permite a excitação do sistema em ampla faixa espectral, viabilizando a identificação através da análise da resposta em frequência.

Figura 9 – Modelo do conversor Boost no Simulink com perturbação PRBS



Fonte: Autoria própria

3.2.2 Configuração da Fonte PRBS

A implementação da fonte de excitação PRBS seguiu as especificações técnicas da MathWorks (The MathWorks Inc., 2024c), utilizando o bloco PRBS Generator disponível na biblioteca Simulink Control Design. A configuração da fonte PRBS constitui aspecto crítico da metodologia, uma vez que as características espectrais do sinal de excitação influenciam diretamente a qualidade da identificação paramétrica.

Os parâmetros da fonte PRBS foram configurados para otimizar a excitação do sistema na faixa de frequências de interesse. O tempo de amostragem foi estabelecido em $T_s = 5 \times 10^{-6}$ s, garantindo resolução temporal adequada para capturar a dinâmica do conversor operando a 20 kHz. A fonte foi configurada para gerar perturbação em torno de 20 kHz, abrangendo desde componentes de baixa frequência até próximo à frequência de chaveamento.

A ordem do sinal foi definida como 4, resultando em sequência pseudoaleatória de comprimento $2^4 - 1 = 15$ bits. O número de períodos foi configurado como 1, proporcionando duração suficiente para análise espectral com resolução adequada. A amplitude de tensão configurada foi de 2 V, correspondendo a 4% do valor da tensão de entrada de 50V. Estas configurações resultam em um sinal de excitação com características espectrais próximas ao ruído branco na faixa de frequências especificada, atendendo aos requisitos de identificação de sistemas lineares.

3.2.3 Medição e Aquisição de Sinais

O sistema de aquisição de dados foi configurado para registrar simultaneamente as tensões de entrada e saída do conversor em ambas as condições operacionais: com e sem perturbação. Esta abordagem permite o cálculo da função de transferência experimental através da análise diferencial dos sinais, conforme estabelecido pela teoria de identificação de sistemas.

Os sinais adquiridos compreendem:

- $v_{i,n}(t)$: tensão de entrada não perturbada
- $v_{o,n}(t)$: tensão de saída correspondente à entrada não perturbada
- $v_{i,p}(t)$: tensão de entrada perturbada (incluindo PRBS)
- $v_{o,p}(t)$: tensão de saída correspondente à entrada perturbada

A frequência de amostragem foi estabelecida em 2 MHz ($t_s = 5 \times 10^{-7}$), garantindo critério de Nyquist para componentes espectrais até 1 MHz, superior à frequência de chaveamento do conversor. O tempo de simulação foi configurado em 2 s, para proporcionar

resolução espectral adequada na análise por transformada de Fourier. A fonte PRBS foi configurada para aplicar a perturbação no circuito entre $[0,1, 1,6]$ s.

3.3 Estratégia Geral da Identificação

A metodologia de identificação paramétrica desenvolvida fundamenta-se na análise da função de transferência de linha para saída $G_{vg}(s)$, que relaciona variações na tensão de entrada com variações na tensão de saída do conversor. Esta escolha metodológica justifica-se pela dependência explícita desta função de transferência com todos os parâmetros do conversor.

3.3.1 Justificativa da Escolha da Função $G_{vg}(s)$

A função de transferência de linha para saída $G_{vg}(s)$ foi selecionada como base para a identificação paramétrica devido a suas características favoráveis para aplicação de técnicas de otimização. Conforme demonstrado no Capítulo 2, esta função expressa-se analiticamente como:

$$G_{vg}(s) = \frac{1}{1-D} \cdot \frac{1}{\frac{s^2 LC}{(1-D)^2} + \frac{sL}{R(1-D)^2} + 1} \quad (3.1)$$

A dependência explícita de $G_{vg}(s)$ com os parâmetros R , L , C e D permite a formulação de problema de otimização onde a função objetivo quantifica a discrepância entre a resposta experimental e a resposta teórica parametrizada. Esta abordagem contrasta com métodos alternativos que requerem identificação sequencial ou utilizam múltiplas funções de transferência.

Adicionalmente, a função $G_{vg}(s)$ apresenta características espectrais ricas, incluindo comportamento de segunda ordem com frequência natural e fator de qualidade dependentes dos parâmetros físicos. Estas características facilitam a identificação única dos parâmetros, minimizando problemas de ambiguidade comuns em técnicas de identificação paramétrica.

3.3.2 Influência dos Parâmetros na Resposta do Sistema

A análise da influência individual dos parâmetros na resposta em frequência de $G_{vg}(s)$ revela características específicas que orientam o processo de identificação. O parâmetro D (ciclo de trabalho) influencia diretamente o ganho CC da função de transferência, dado por $G_{g0} = \frac{1}{1-D}$. Variações em D resultam em alterações proporcionais da magnitude em baixas frequências.

Os parâmetros L e C determinam a frequência natural do sistema, expressa por $\omega_0 = \frac{1-D}{\sqrt{LC}}$. O indutor L influencia tanto a frequência natural quanto o amortecimento do sistema, enquanto o capacitor C afeta principalmente a frequência natural e o comportamento em altas frequências.

O resistor de carga R determina o fator de qualidade do sistema, dado por $Q = (1-D)R\sqrt{\frac{C}{L}}$. Variações em R resultam em alterações do amortecimento, manifestando-se como mudanças na magnitude do pico de ressonância e na largura de banda do sistema.

3.4 Aquisição e Processamento dos Dados

O processamento dos dados adquiridos nas simulações constitui uma etapa para obtenção da função de transferência experimental utilizada como referência no processo de identificação. A metodologia desenvolvida emprega técnicas de análise espectral para extrair informações de magnitude e fase na faixa de frequências de interesse.

3.4.1 Obtenção dos Dados Simulados

A extração da função de transferência experimental baseia-se na análise diferencial dos sinais adquiridos nas duas condições operacionais. A função de transferência $G_{vg}(s)$ experimental é calculada através da relação:

$$G_{vg,exp}(j\omega) = \frac{V_{o,p}(\omega) - V_{o,n}(\omega)}{V_{i,p}(\omega) - V_{i,n}(\omega)} \quad (3.2)$$

onde $V_{i,p}(\omega)$, $V_{i,n}(\omega)$, $V_{o,p}(\omega)$ e $V_{o,n}(\omega)$ representam as transformadas de Fourier dos sinais de tensão de entrada e saída nas condições perturbada e não perturbada, respectivamente.

A aplicação da Transformada Rápida de Fourier (FFT) aos sinais temporais permite a obtenção do conteúdo espectral com resolução adequada para análise. A resolução em frequência é determinada pela duração da simulação e pela frequência de amostragem, sendo otimizada para capturar adequadamente as características dinâmicas do conversor.

3.4.2 Pré-processamento e Análise Espectral

O pré-processamento dos sinais inclui remoção da componente CC e aplicação de janelamento para redução de vazamento espectral. A componente CC é removida através da exclusão da frequência zero da análise, concentrando o processo de identificação nas características dinâmicas do sistema.

A análise espectral é realizada utilizando o vetor de frequências angulares $\omega = 2\pi f$, onde f representa o vetor de frequências discretas obtido da FFT. A função de transferência experimental é calculada apenas para frequências não nulas, evitando singularidades numéricas e concentrando a análise na resposta AC do sistema.

A qualidade da identificação é verificada através da análise qualitativa da coerência entre os sinais de entrada e saída, garantindo relação causal adequada na faixa de frequências considerada. Frequências com baixa coerência são excluídas da análise, assegurando robustez do processo de identificação.

3.5 Detalhamento da Implementação do Algoritmo Genético

A implementação do algoritmo genético para identificação paramétrica foi desenvolvida utilizando as ferramentas de otimização do MATLAB, especificamente a função `ga` da Global Optimization Toolbox. A configuração dos parâmetros do algoritmo foi otimizada para garantir convergência robusta e precisão adequada na estimação dos parâmetros.

3.5.1 Codificação dos Parâmetros

A codificação dos parâmetros utiliza representação real (ponto flutuante), onde cada indivíduo da população é representado por um vetor $\mathbf{x} = [R, L, C, D]^T$ contendo os valores dos quatro parâmetros a serem identificados. Esta representação oferece vantagens em termos de precisão e simplicidade de implementação quando comparada à codificação binária.

Os limites de busca foram estabelecidos com base nos valores teóricos dos parâmetros, considerando uma faixa de variação de $\pm 1\%$ em torno dos valores nominais. Esta configuração garante convergência eficiente enquanto permite flexibilidade suficiente para acomodar variações paramétricas e incertezas de modelagem.

Os limites inferior e superior são definidos como:

$$\mathbf{x}_{min} = [R_{real}, L_{real}, C_{real}, D_{real}] / 1,01 \quad (3.3)$$

$$\mathbf{x}_{max} = [R_{real}, L_{real}, C_{real}, D_{real}] \times 1,01 \quad (3.4)$$

Esta configuração concentra a busca em região próxima aos valores esperados, melhorando a eficiência computacional sem comprometer a capacidade de identificação.

3.5.2 Definição da Função Objetivo

A função objetivo foi formulada para quantificar a discrepância entre a magnitude da função de transferência experimental e a magnitude da função de transferência teó-

rica parametrizada. A escolha de considerar apenas a magnitude justifica-se pela maior robustez a ruído e facilidade de implementação, mantendo informação suficiente para identificação única dos parâmetros.

A função objetivo é expressa como:

$$f(R, L, C, D) = \frac{1}{N} \sum_{k=1}^N \left(\frac{|G_{vg}^{\text{simulado}}(j\omega_k)| - |G_{vg}^{\text{teórico}}(j\omega_k; R, L, C, D)|}{\max_k |G_{vg}^{\text{simulado}}(j\omega_k)|} \right)^2 \quad (3.5)$$

Sendo:

- $f(R, L, C, D)$: valor da função objetivo a ser minimizada;
- $G_{vg}^{\text{simulado}}(j\omega_k)$: valor simulado da função de transferência (obtida por FFT dos sinais com perturbação PRBS);
- $G_{vg}^{\text{teórico}}(j\omega_k; R, L, C, D)$: valor modelado teoricamente da função de transferência com os parâmetros candidatos;
- ω_k : frequência angular no ponto k da análise espectral;
- N : número total de amostras (tamanho do vetor frequências da simulação);
- $\max |G_{vg}^{\text{simulado}}(j\omega_k)|$: fator de normalização (módulo máximo da função simulada).

A normalização pela magnitude máxima da resposta experimental garante que a função objetivo seja adimensional e robusta a variações de escala. Adicionalmente, foram implementadas restrições que garantissem valores fisicamente viáveis dos parâmetros, incluindo $R, L, C > 0$ e $0 < D < 1$.

3.5.3 Critérios de Convergência e Configuração do Algoritmo

A configuração do algoritmo genético foi otimizada através de estudos preliminares para balancear velocidade de convergência e qualidade da solução. O tamanho da população foi estabelecido em 200 indivíduos, proporcionando diversidade adequada para exploração eficiente do espaço de busca.

O número máximo de gerações foi limitado a 100, critério que se mostrou suficiente para convergência na maioria dos casos analisados. A fração de cruzamento fixa foi configurada em 0,8, favorecendo a exploração através da recombinação genética.

A implementação da mutação adaptativa no algoritmo genético foi realizada utilizando a função `mutationadaptfeasible`, disponível no ambiente MATLAB. Essa função

é especialmente adequada para problemas de otimização com restrições lineares, pois assegura que todos os indivíduos mutantes permaneçam dentro da região viável definida pelas restrições impostas ao problema.

O princípio de funcionamento da `mutationadaptfeasible` pode ser descrito em etapas. Inicialmente, são fornecidos como entradas os indivíduos selecionados para mutação, as opções configuradas no algoritmo, o comprimento do genoma, a função objetivo (fitness), o estado atual do processo evolutivo e a população corrente.

A partir dessas informações, a função realiza um ajuste adaptativo do tamanho do passo de mutação (*StepSize*), levando em consideração o histórico recente do desempenho do algoritmo. Se o progresso na busca melhora, indicando aumento da diversidade ou do desempenho populacional, o passo é aumentado, favorecendo uma exploração mais ampla do espaço de busca. Caso contrário, o tamanho do passo é reduzido, incentivando uma exploração local mais detalhada.

Posteriormente, identifica-se o tipo específico de restrição presente no problema de otimização: ausência de restrições, restrições somente em limites superiores e inferiores (*bound constraints*), ou restrições lineares gerais. Com base nessa classificação, a função gera um conjunto de direções viáveis para mutação, respeitando explicitamente as restrições definidas. Em problemas sem restrições, são consideradas todas as direções possíveis; em problemas com restrições de limites, as direções geradas respeitam explicitamente esses limites; enquanto para restrições lineares gerais, as direções são determinadas a partir das equações lineares que definem o espaço viável.

Após a geração dessas direções, uma delas é selecionada de forma aleatória para promover a mutação do indivíduo. Antes de concluir a operação, a viabilidade do novo indivíduo é verificada novamente quanto ao atendimento das restrições lineares. Caso o indivíduo resultante da mutação não atenda a essas condições, ele é descartado, mantendo-se então o indivíduo original não mutado.

Dessa maneira, a aplicação da função `mutationadaptfeasible` garante que todos os indivíduos gerados por mutação estejam dentro dos limites estabelecidos pelas restrições lineares do problema, contribuindo para a eficácia e robustez da metodologia proposta neste trabalho.

Critérios adicionais incluem monitoramento da estagnação da função objetivo e verificação da convergência da população. O algoritmo incorpora paralelização para redução do tempo computacional, aproveitando arquiteturas multicore disponíveis.

A função de saída personalizada (`gaoutfun`) registra o histórico de evolução da melhor solução, permitindo análise posterior da convergência e identificação de possíveis problemas de otimização.

3.6 Avaliação e Validação dos Resultados

A análise da metodologia proposta compreende análise quantitativa e qualitativa dos resultados obtidos, incluindo avaliação da convergência do algoritmo genético, comparação entre funções de transferência teóricas e experimentais, e análise dos erros de estimação dos parâmetros.

3.6.1 Análise de Convergência do Algoritmo Genético

A análise da convergência é realizada através da análise do histórico de evolução da função objetivo ao longo das gerações. O registro da melhor solução a cada geração permite identificar características do processo de otimização, incluindo velocidade de convergência inicial, presença de *plateaus* e estabilidade da solução final.

Critérios quantitativos de convergência incluem taxa de melhoria da função objetivo entre gerações consecutivas e variância da população. A convergência é considerada satisfatória quando a taxa de melhoria torna-se inferior a 10^{-6} por um número especificado de gerações consecutivas.

A análise inclui verificação da diversidade populacional para identificar possível convergência prematura. Métricas de diversidade baseadas na dispersão dos indivíduos no espaço de parâmetros auxiliam na avaliação da qualidade da exploração realizada pelo algoritmo.

3.6.2 Comparação de Funções de Transferência

A análise da identificação paramétrica é realizada através da comparação quantitativa entre as funções de transferência $G_{vg}(s)$ experimental, teórica com parâmetros reais e teórica com parâmetros estimados. Esta análise é conduzida tanto no domínio da frequência quanto através de métricas estatísticas de aderência.

A comparação visual é realizada através de diagramas de Bode apresentando magnitude e fase das três funções de transferência simultaneamente. A sobreposição das curvas indica qualidade da identificação, enquanto desvios sistemáticos podem revelar limitações da metodologia ou presença de dinâmicas não modeladas.

Métricas quantitativas incluem o erro quadrático médio normalizado (NRMSE). Estas métricas proporcionam avaliação objetiva da qualidade da identificação.

3.6.3 Análise com Componentes Não-Ideais

Para analisar a robustez da metodologia, análises adicionais são conduzidas considerando componentes com perdas. Resistências série equivalentes (ESR) são incorporadas ao indutor e capacitor, simulando condições mais realistas de operação.

A configuração com perdas inclui resistência série do indutor ($R_L = 0,1 \Omega$) e resistência série do capacitor ($R_C = 0,05 \Omega$), valores representativos de componentes comerciais na faixa de potência considerada. Esta análise permite avaliar a capacidade da metodologia em identificar parâmetros na presença de dinâmicas não modeladas explicitamente.

3.6.4 Metodologia de Análise do Erro Relativo Percentual

A avaliação quantitativa da precisão da identificação é realizada através do cálculo do erro percentual para cada parâmetro estimado:

$$\varepsilon_p = \frac{|P_{estimado} - P_{real}|}{|P_{real}|} \times 100\% \quad (3.6)$$

onde P representa cada um dos parâmetros R , L , C ou D .

A análise estatística para o cálculo do erro relativo foi realizada a partir da média dos parâmetros obtidos após 10 simulações.

4 RESULTADOS OBTIDOS

Este capítulo apresenta os resultados obtidos através da aplicação da metodologia de identificação paramétrica desenvolvida no Capítulo 3. A análise compreende desde a validação inicial do modelo do conversor Boost até a avaliação da robustez do algoritmo genético frente a diferentes condições operacionais. Os resultados demonstram a eficácia da abordagem proposta e fornecem conclusões sobre as limitações e potencialidades da técnica desenvolvida. O código completo implementado em MATLAB/Simulink encontra-se disponível no Anexo deste trabalho.

4.1 Configuração Inicial do Estudo

A configuração inicial do estudo fundamenta-se na definição dos parâmetros do conversor Boost e na validação do modelo desenvolvido no ambiente Simulink. Esta etapa constitui base para garantir a confiabilidade dos resultados subsequentes da identificação paramétrica.

4.1.1 Cálculo dos Parâmetros Reais do Conversor

Com base nas especificações de projeto apresentadas na Tabela 2 do Capítulo 3, procedeu-se ao cálculo dos parâmetros reais do conversor utilizando as equações de projeto derivadas no Capítulo 2. A Tabela 3 apresenta os valores calculados que serviram como referência para todo o processo de identificação.

Tabela 3 – Parâmetros calculados do conversor Boost com equações alinhadas

Parâmetro	Cálculo
Ciclo de trabalho (D)	$D = 1 - \frac{V_g}{V} = 1 - \frac{50}{100} = 0,5$
Resistência de carga (R)	$R = \frac{V^2}{P_o} = \frac{100^2}{750} = 13,3 \Omega$ (comercial)
Indutor (L)	$L = \frac{V_g \cdot D / I_L}{\left(\frac{\Delta I_L}{I_L}\right) \cdot f_s} = \frac{50 \cdot 0,5 / 15}{0,1 \cdot 20000} = 833,3 \mu\text{H} \approx 822 \mu\text{H}$ (comercial)
Capacitor (C)	$C = \frac{D}{R \cdot \left(\frac{\Delta V}{V}\right) \cdot f_s} = \frac{0,5}{13,3 \cdot 0,05 \cdot 20000} = 37,51 \mu\text{F} \approx 40 \mu\text{F}$ (comercial)

Fonte: Autoria própria


Para os cálculos apresentados, considerou-se a corrente média no indutor $I_L = \frac{I_o}{1-D} = \frac{P_o}{V} = \frac{7,5}{0,5} = 15 \text{ A}$.

É importante observar que, devido a limitações de componentes comerciais disponíveis no Simulink e para facilitar a análise, os valores utilizados nas simulações foram ajustados para $L = 822 \mu\text{H}$ e $C = 40 \mu\text{F}$, mantendo-se as mesmas ordens de grandeza dos valores calculados teoricamente.

4.1.2 Validação do Modelo do Conversor Boost

A validação do modelo implementado no Simulink foi realizada através da análise das formas de onda características do conversor operando em regime permanente. A Figura 10 apresenta as tensões de entrada e saída do conversor, confirmando a relação de conversão esperada.

Figura 10 – Validação das tensões do conversor Boost




Fonte: Autoria própria

A análise da Figura 10 confirma que o conversor apresenta tensão de entrada estabilizada em 50 V e tensão de saída próxima a 100 V (já que a simulação foi realizada com os valores dos componentes comerciais, conforme exibe a Tabela 3), resultando na relação de conversão $M = \frac{V_o}{V_{in}} = \frac{100}{50} = 2$, que corresponde ao valor teórico $M = \frac{1}{1-D} = \frac{1}{1-0,5} = 2$.

A validação do modo de condução contínua (MCC) foi verificada através da análise da corrente no indutor, conforme apresentado na Figura 11.

Figura 11 – Corrente no indutor - Validação do modo de condução contínua



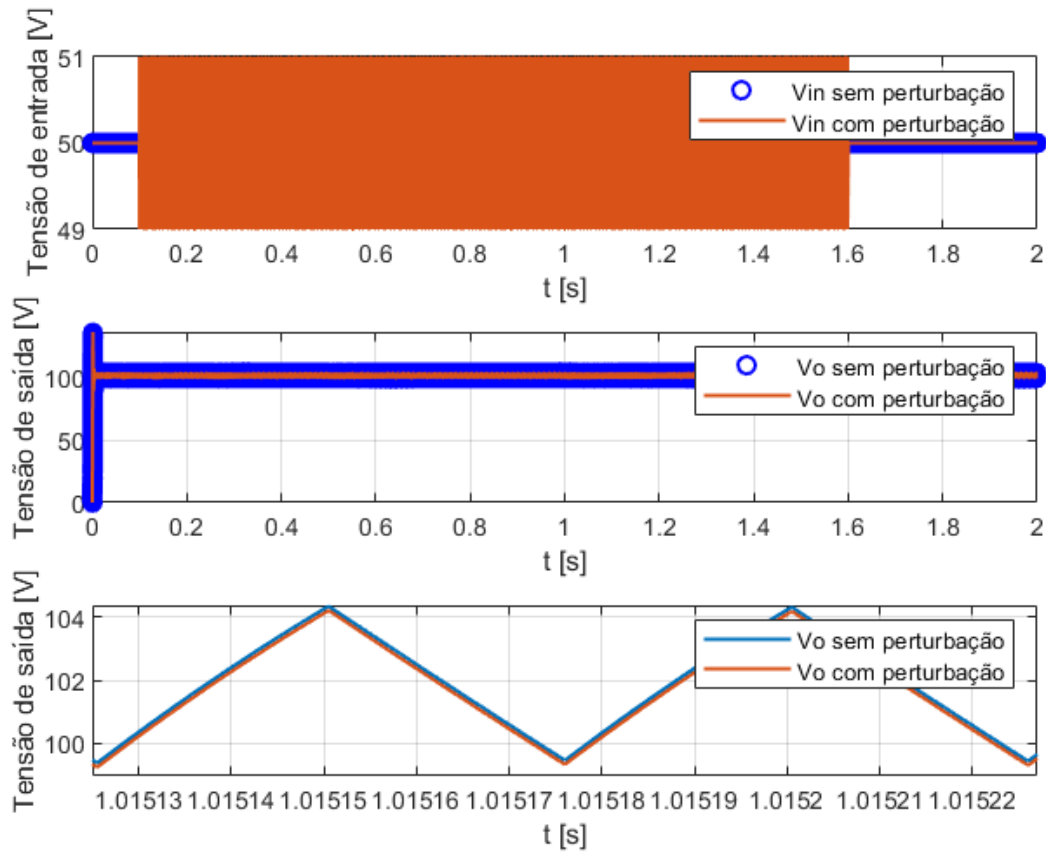
Fonte: Autoria própria

A Figura 11 demonstra que a corrente no indutor nunca se anula durante o período de chaveamento, confirmando a operação no modo de condução contínua. A corrente média observada é de aproximadamente 15 A, valor consistente com o calculado teoricamente através da relação $I_L = \frac{I_o}{1-D} = \frac{7,5}{0,5} = 15$ A.

4.1.3 Validação da Perturbação por Pequenos Sinais

Para verificar que a perturbação PRBS aplicada constitui efetivamente uma excitação de pequenos sinais, analisou-se o comportamento das tensões de entrada e saída do sistema com a fonte de perturbação ativa. A Figura 12 apresenta esta análise.

Figura 12 – Validação da perturbação por pequenos sinais - Tensões com fonte PRBS ativa



Fonte: Autoria própria

O subíndice n refere-se a forma de onda do sistema não perturbado, enquanto p refere-se ao sistema perturbado com a fonte PRBS.

A análise da Figura 12 confirma que, embora o sistema seja perturbado pela fonte PRBS, as variações permanecem dentro dos limites de pequenos sinais. A amplitude das perturbações na tensão de entrada é inferior a 4% do valor nominal da fonte de entrada, e as correspondentes variações na tensão de saída são inferiores a 2%, validando a aplicabilidade da teoria de pequenos sinais desenvolvida no Capítulo 2.

4.2 Resultados da Estimativa dos Parâmetros

Esta seção apresenta os resultados obtidos através da aplicação do algoritmo genético para identificação dos parâmetros R , L , C e D do conversor Boost, considerando inicialmente limites de busca de $\pm 1\%$ em torno dos valores reais.

4.2.1 Implementação do Algoritmo de Identificação

A implementação do algoritmo genético seguiu a estrutura apresentada no Capítulo 3, com configuração otimizada para o problema específico de identificação paramétrica. O código completo implementado é exibido no Anexo.

4.2.2 Resultados Comparativos dos Parâmetros

A Tabela 4 apresenta a média da comparação entre os parâmetros reais e estimados para o caso com limites de busca de $\pm 1\%$ após 10 simulações.

Tabela 4 – Comparação entre parâmetros reais e estimados - Limites $\pm 1\%$

Parâmetro	Valor Real	Valor Estimado	Erro Relativo	Erro (%)
R [Ω]	13,30	13,2661	0,0025	0,25
L [μH]	822,0	830,2200	0,0100	1
C [μF]	40,0	40,3860	0,0096	0,96
D	0,50	0,5050	0,0100	1

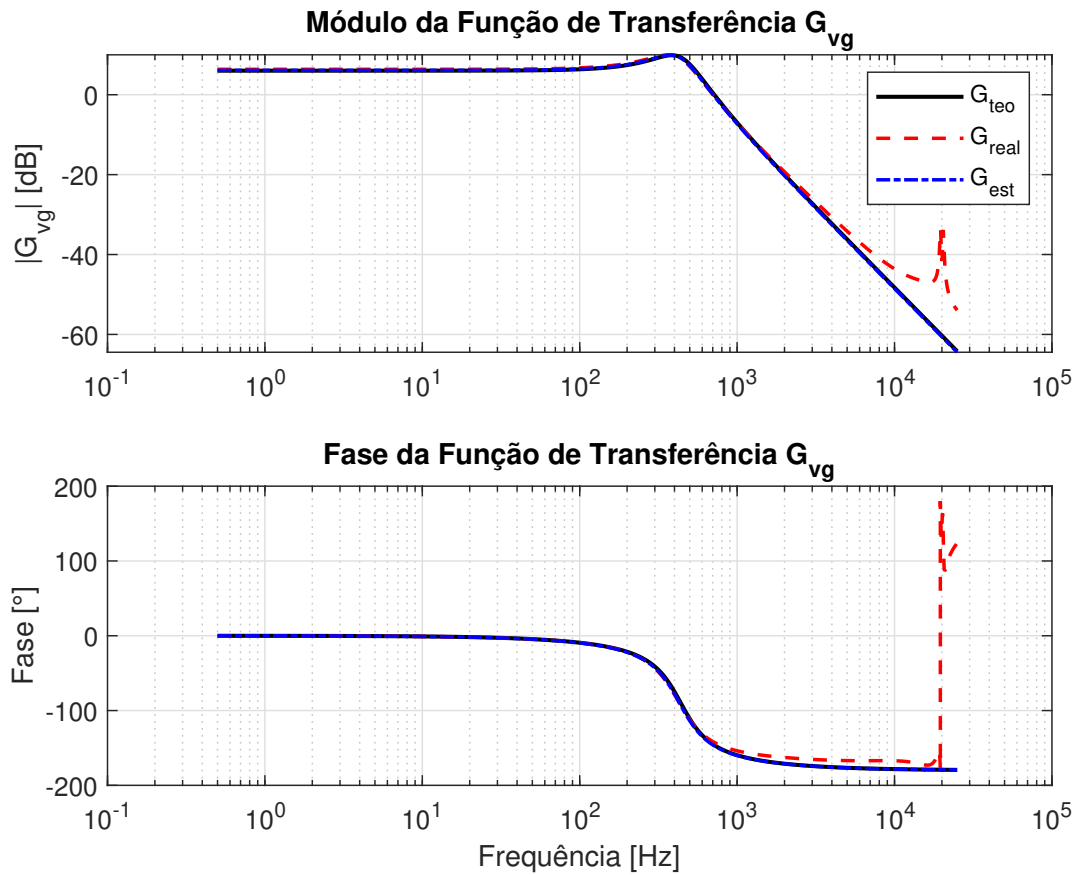
Fonte: Autoria própria

Os resultados demonstram boa precisão na identificação paramétrica, com erro percentual máximo de 1% para o ciclo de trabalho D e indutor L . Esta precisão deve-se à combinação da faixa restrita de busca com a robustez do algoritmo genético implementado.

4.2.3 Análise das Funções de Transferência

A validação da identificação paramétrica foi realizada através da comparação entre as funções de transferência $G_{vg}(s)$ real (obtida via simulação), teórica (calculada com parâmetros reais) e estimada (calculada com parâmetros identificados). A Figura 13 apresenta os diagramas de Bode correspondentes.

Figura 13 – Comparação das funções de transferência $G_{vg}(s)$ - Limites $\pm 1\%$



Fonte: Autoria própria

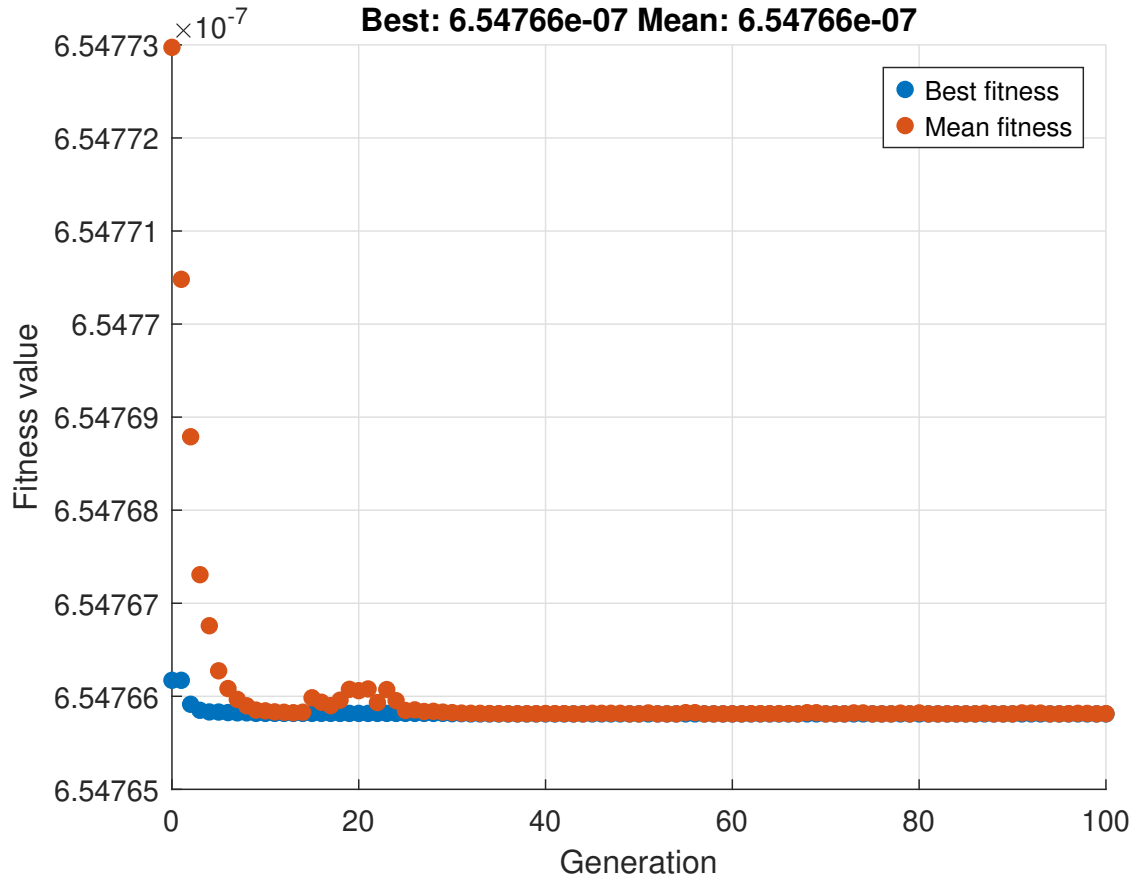
A análise da Figura 13 revela a concordância entre as três funções de transferência. O ganho CC ($G_{g0} = \frac{1}{1-D} = 2$ ou 6,02 dB) é identificado, assim como a frequência natural do sistema ($f_0 = \frac{1-D}{2\pi\sqrt{LC}} \approx 438,86Hz$) e o comportamento em altas frequências com declividade de -40 dB/década.

4.3 Análise da Convergência do Algoritmo Genético

A análise da convergência do algoritmo genético estabelece a eficácia da metodologia proposta e a adequação dos parâmetros de configuração utilizados.

4.3.1 Comportamento da Função Objetivo

A Figura 14 apresenta a evolução da função objetivo ao longo das gerações para o caso com limites de $\pm 1\%$.

Figura 14 – Convergência do algoritmo genético - Limites $\pm 1\%$ 

Fonte: Autoria própria

A análise da convergência revela o comportamento típico de algoritmos genéticos bem configurados: convergência rápida inicial seguida por refinamento gradual. O algoritmo atinge valores próximos ao ótimo global nas primeiras 30 gerações.

4.3.2 Influência dos Parâmetros do Algoritmo Genético

A configuração utilizada demonstrou-se apropriada para o problema de identificação paramétrica:

- **Tamanho da População (200):** Proporcionou diversidade adequada sem penalizar excessivamente o tempo computacional
- **Fração de Cruzamento (0,8):** Favoreceu a exploração através de recombinação genética
- **Mutação Adaptativa:** Manteve diversidade populacional e evitou convergência prematura

- **Número de Gerações (100):** Garantiu convergência completa com margem de segurança

4.4 Análise da Robustez

A análise da robustez foi conduzida através de três cenários progressivamente mais desafiadores: introdução de resistências parasitas e ampliação dos limites de busca para $\pm 5\%$ e $\pm 10\%$.

4.4.1 Cenário 1: Introdução de Resistências Parasitas

Para avaliar a robustez da metodologia frente a não-idealidades, foram introduzidas resistências série equivalentes (ESR) de $R_L = 0,1 \Omega$ no indutor e $R_C = 0,05 \Omega$ no capacitor, simulando condições mais realistas de operação.

A Tabela 5 apresenta a média dos resultados obtidos com resistências parasitas e limites de $\pm 1\%$ após 10 simulações.

Tabela 5 – Resultados com resistências parasitas - Limites $\pm 1\%$

Parâmetro	Valor Real	Valor Estimado	Erro Relativo	Erro (%)
$R [\Omega]$	13,30	13,1683	0,0099	0,99
$L [\mu\text{H}]$	822,0	830,2200	0,0100	1
$C [\mu\text{F}]$	40,0	39,6040	0,0099	0,99
D	0,50	0,5050	0,0100	1

Fonte: Autoria própria

Nota-se que, com a inserção de resistências parasitas, ocorreu um aumento do erro relativo para a resistência e o capacitor na estimativa dos parâmetros, embora ainda estejam dentro dos limites de busca de $\pm 1\%$ especificado.

4.4.2 Cenário 2: Limites de Busca $\pm 5\%$ com Resistências Parasitas

A ampliação dos limites de busca para $\pm 5\%$ testa a capacidade do algoritmo em espaços de busca maiores. A Tabela 6 apresenta os valores médios dos resultados obtidos para cada parâmetro após 10 simulações.

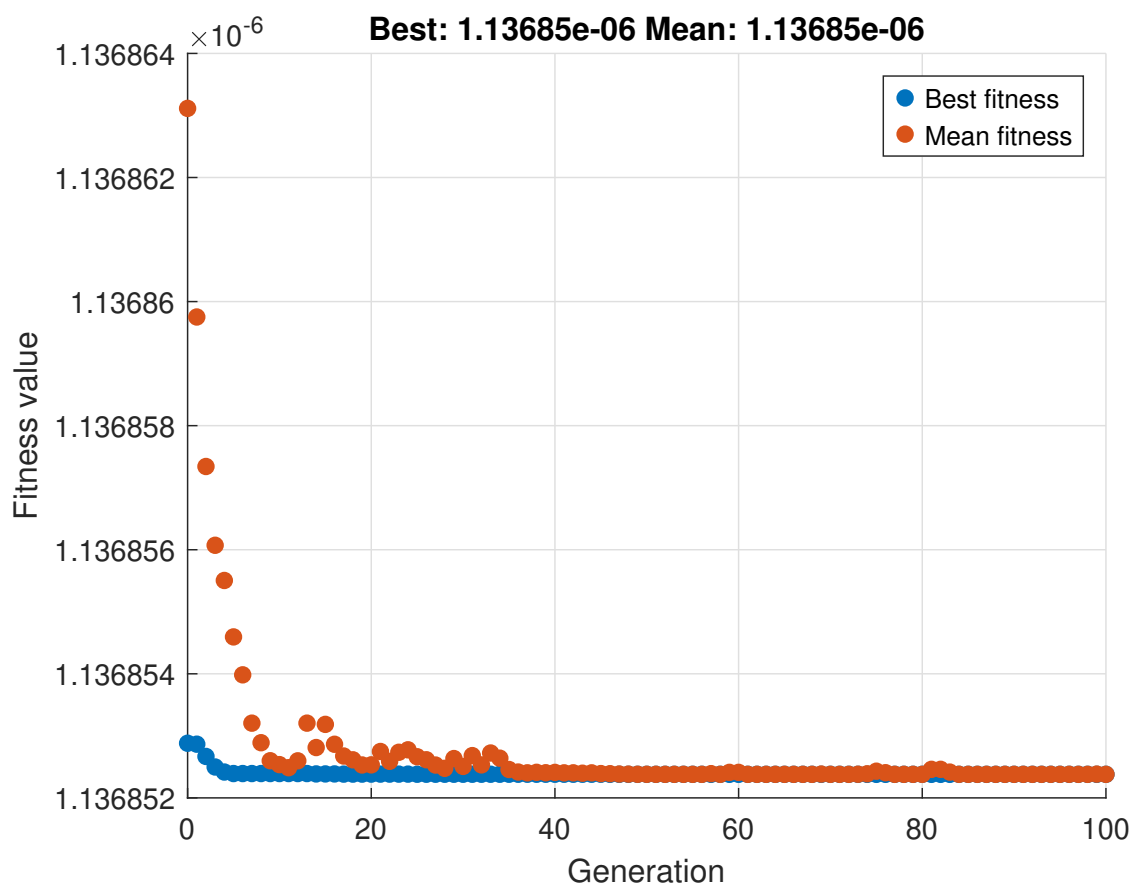
Tabela 6 – Resultados com resistências parasitas - Limites $\pm 5\%$

Parâmetro	Valor Real	Valor Estimado	Erro Absoluto	Erro (%)
R [Ω]	13,30	12,6667	0,0476	4,76
L [μH]	822,0	863,0900	0,0500	5,00
C [μF]	40,0	38,9940	0,0252	2,52
D	0,50	0,4967	0,0066	0,66

Fonte: Autoria própria

A Figura 15 ilustra o comportamento de convergência para este cenário.

Figura 15 – Convergência do algoritmo genético - Limites $\pm 5\%$ com ESR



Fonte: Autoria própria

Observa-se uma convergência mais demorada devido ao espaço de busca ampliado, mas ainda com resultados satisfatórios para o limite de busca ajustado de $\pm 5\%$ com ESR.

4.4.3 Cenário 3: Limites de Busca $\pm 10\%$ com Resistências Parasitas

Foi avaliado o cenário com limites de $\pm 10\%$, maior limite de busca avaliado. A Tabela 7 apresenta os resultados da média dos valores para cada parâmetro identificado após 10 simulações.

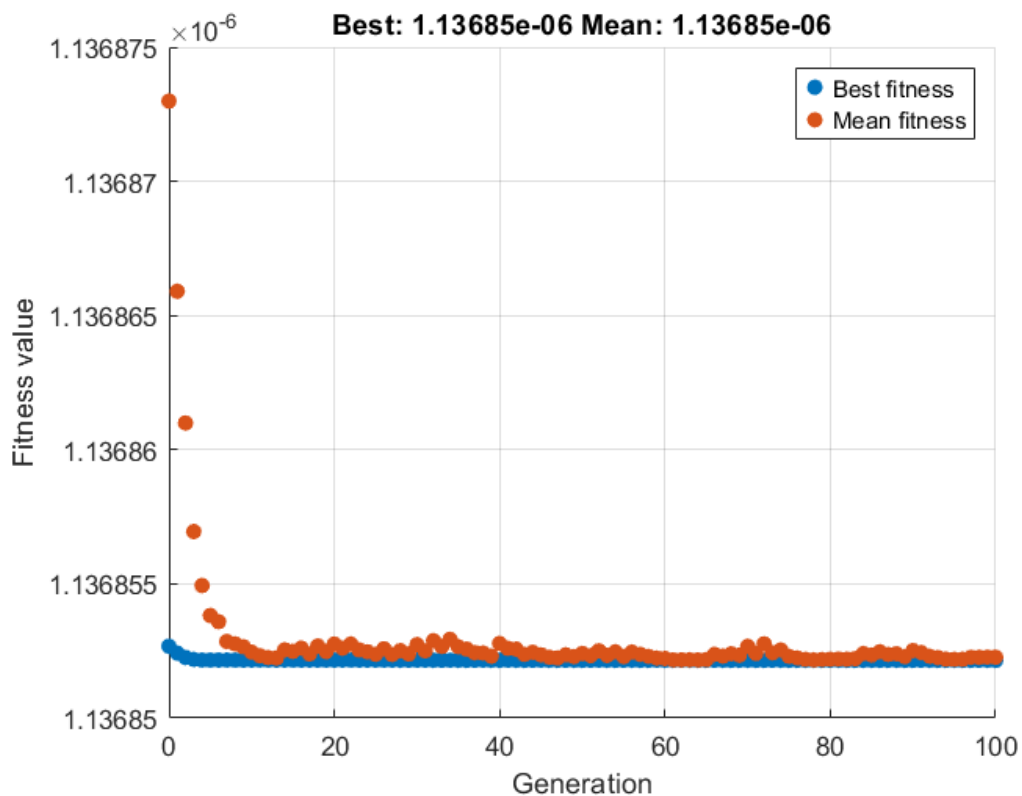
Tabela 7 – Resultados com resistências parasitas - Limites $\pm 10\%$

Parâmetro	Valor Real	Valor Estimado	Erro Relativo	Erro (%)
R [Ω]	13,30	12,6276	0,0506	5,06
L [μH]	822,0	881,6800	0,0726	7,26
C [μF]	40,0	39,0790	0,0230	2,30
D	0,50	0,4907	0,0186	1,86

Fonte: Autoria própria

A Figura 16 ilustra o comportamento de convergência para este cenário.

Figura 16 – Convergência do algoritmo genético - Limites $\pm 10\%$ com ESR



Fonte: Autoria própria

A análise revela comportamento previsível e robusto da metodologia: o erro de identificação de algum parâmetro pode aumentar gradualmente com a ampliação dos limi-

tes de busca e com a introdução de não-idealidades, mas permanece em níveis aceitáveis mesmo no cenário mais desafiador.

4.5 Discussão Geral

Os resultados obtidos demonstram a eficácia da metodologia proposta para identificação paramétrica de conversores Boost utilizando algoritmos genéticos. A discussão a seguir aborda as limitações observadas, explica as discrepâncias encontradas e propõe melhorias futuras.

4.5.1 Limitações do Método

A análise dos resultados revela algumas limitações importantes da metodologia desenvolvida:

Sensibilidade às resistências parasitas: A presença de resistências série equivalentes introduz dinâmicas não modeladas na função de transferência $G_{vg}(s)$, conforme previsto na teoria desenvolvida por Erickson e Maksimović. Estas dinâmicas manifestam-se como ligeiro aumento nos erros de identificação, particularmente visível na comparação entre os cenários ideal e com ESR.

Dependência dos limites de busca: A precisão dos algoritmos genéticos na identificação paramétrica está diretamente ligada à amplitude dos limites de busca definidos. Limites muito amplos (por exemplo, $\pm 10\%$ dos valores nominais) aumentam significativamente o espaço de busca, dificultando a convergência para o melhor valor e resultando em maiores erros nas estimativas. Em contrapartida, limites mais restritos (como $\pm 1\%$) concentram soluções mais próximas dos valores reais, favorecendo a precisão dos resultados. Entretanto, restringir demais esses limites pode reduzir a diversidade inicial da população, limitar a exploração de novas soluções e causar convergência prematura. Portanto, é fundamental determinar um tamanho ótimo do espaço de busca que seja amplo o suficiente para incluir a solução ótima, mas restrito o bastante para assegurar eficiência, precisão e confiabilidade na identificação paramétrica de sistemas.

Limitações da aproximação de pequenos sinais: A metodologia fundamenta-se na validade da teoria de pequenos sinais desenvolvida no Capítulo 2. Para variações de grande amplitude ou frequências próximas à frequência de chaveamento, a precisão pode ser comprometida devido às limitações inerentes ao processo de média temporal (state-space averaging).

4.5.2 Explicação das Discrepâncias Observadas

As discrepâncias observadas entre teoria e simulação podem ser atribuídas a fatores específicos:

Efeitos de discretização temporal: As simulações no Simulink utilizam métodos numéricos de integração que introduzem erros de discretização. Embora pequenos, estes erros acumulam-se ao longo da simulação e podem influenciar sutilmente a resposta em frequência experimental.

Limitações da FFT: A aplicação da Transformada Rápida de Fourier para obtenção da função de transferência experimental está sujeita a limitações de resolução espectral e vazamento espectral (spectral leakage), mesmo com aplicação de técnicas de janelamento.

Aproximações no modelo teórico: O modelo teórico $G_{vg}(s)$ baseia-se em hipóteses simplificadoras, incluindo componentes ideais e operação estritamente no modo de condução contínua. Desvios destas condições ideais introduzem discrepâncias esperadas.

Convergência numérica do algoritmo genético: Embora o algoritmo demonstre convergência robusta, a natureza estocástica dos operadores genéticos pode introduzir pequenas variações nos resultados entre execuções diferentes.

4.5.3 Validação da Abordagem Teórica

Os resultados validam a solidez da abordagem teórica desenvolvida nos Capítulos 2 e 3, validando:

- A adequação da função de transferência $G_{vg}(s)$ como base para identificação paramétrica
- A eficácia dos sinais PRBS para excitação de sistemas lineares
- A robustez dos algoritmos genéticos para problemas de otimização global
- A validade da teoria de pequenos sinais para aplicações de identificação

4.5.4 Sugestões para Melhorias Futuras

Com base nos resultados obtidos e limitações identificadas, propõem-se as seguintes melhorias para trabalhos futuros:

Inclusão de modelos de ordem superior: Incorporação explícita de resistências série equivalentes na formulação da função objetivo, utilizando modelos mais sofisticados que capturem dinâmicas de alta frequência.

Otimização multiobjetivo: Implementação de algoritmos genéticos multiobjetivo (NSGA-II, SPEA-2) para otimização simultânea de precisão na magnitude e fase da função de transferência.

Validação experimental: Implementação da metodologia em protótipo físico para validação experimental dos resultados teóricos e de simulação.

Extensão para outras topologias: Adaptação da metodologia para identificação paramétrica de outros conversores (Buck, Buck-Boost, Flyback), explorando as funções de transferência específicas de cada topologia.

Identificação em tempo real: Desenvolvimento de versões simplificadas do algoritmo para implementação em microcontroladores, visando identificação paramétrica em tempo real para aplicações de diagnóstico e manutenção preditiva.

4.5.5 Contribuições do Trabalho

Os resultados obtidos demonstram as seguintes contribuições principais:

1. Validação da metodologia de identificação paramétrica baseada na função de transferência $G_{vg}(s)$ para conversores Boost
2. Demonstração da eficácia de algoritmos genéticos para problemas de identificação em eletrônica de potência
3. Análise sistemática da robustez da metodologia frente a não-idealidades e variações nos parâmetros de busca
4. Estabelecimento de critérios de configuração para algoritmos genéticos em aplicações de identificação paramétrica
5. Desenvolvimento de framework completo integrando modelagem teórica, simulação e otimização metaheurística

Os resultados obtidos confirmam a viabilidade e eficácia da metodologia proposta para identificação paramétrica de conversores Boost, estabelecendo boas diretrizes para desenvolvimentos futuros em identificação de sistemas em eletrônica de potência.

5 CONCLUSÃO

Neste trabalho, o objetivo geral consistiu em desenvolver e avaliar uma metodologia capaz de identificar, com boa precisão, os parâmetros R , L , C e D de um conversor *Boost* utilizando: (i) um modelo de pequenos sinais fundamentado na função de transferência $G_{vg}(s)$; (ii) excitação pseudo-aleatória de baixos níveis (PRBS); e (iii) um algoritmo genético (GA) configurado para busca global.

O trabalho confirmou que a união de modelagem rigorosa, excitação de pequenos sinais e algoritmos genéticos constitui uma diretriz eficaz para estimar parâmetros de conversores de potência com boa fidelidade e esforço computacional moderado.

Foi obtida uma boa precisão em condições ideais e manteve-se a robustez frente a variações de projeto. A pesquisa reforça o potencial dos métodos evolutivos como ferramentas de engenharia aplicáveis a diagnósticos, sintonização automática de controladores e manutenção preditiva.

5.1 Contribuições do Trabalho

Entre as principais contribuições técnico-científicas deste trabalho destacam-se:

- 1) **Framework integrado de identificação:** Foi proposto um procedimento que combinou excitação PRBS, modelagem por pequenos sinais e otimização baseado em AGs, resultando em erros de estimativa paramétrico dentro dos limites de busca de busca avaliados, $\pm 1\%$, $\pm 5\%$ e $\pm 10\%$.
- 2) **Análise sistemática de robustez:** demonstrou-se empiricamente a influência das amplitudes dos limites de busca e de não-idealidades (ESR) na precisão do GA, oferecendo diretrizes quantitativas para ajuste de parâmetros.
- 3) **Metodologia replicável:** todo o código em MATLAB/SIMULINK foi modularizado e anexado, possibilitando reaplicação imediata a outros conversores ou condições de operação.
- 4) **Consolidação teórico-prática:** evidenciou-se a coerência entre teoria de pequenos sinais e resultados de otimização evolutiva, reforçando a utilidade de $G_{vg}(s)$ como métrica única de identificação.

5.2 Trabalhos Futuros

Para dar continuidade e aprofundar a presente linha de pesquisa, sugere-se explorar as seguintes abordagens:

- **Validação experimental em protótipo físico:** implementação em bancada para avaliar ruídos de medição, atrasos de sensoriamento e quantização.
- **Extensão a outras topologias:** adaptação do fluxo para conversores *Buck*, *Buck-Boost* e isolados (*Flyback*, *Forward*), incluindo modelos multi-entrada/multi-saída.
- **Otimização multi-objetivo:** emprego de NSGA-II ou SPEA-2 para conciliar simultaneamente erros de módulo e fase, tempo de convergência e complexidade computacional.
- **Hibridização de algoritmos:** combinação do GA com PSO, DE ou técnicas determinísticas (e.g. Levenberg–Marquardt) para acelerar a fase de refinamento local.
- **Implementação embarcada:** estudo de versões de baixa complexidade do GA a serem executadas em microcontroladores ou *FPGAs*, habilitando identificação *online* para diagnóstico de envelhecimento.
- **Modelos de ordem superior:** incorporação explícita de ESR, parasitas de layout e não-linearidades magnéticas no modelo de referência, ampliando a faixa de validade para altas frequências.

Referências

- BAI, L.; BAE, J.-Y. Flyback converter modeling and overload control characteristics for power supply based on state-space averaging. In: IEEE. **2024 8th International Conference on Robotics, Control and Automation (ICRCA)**. [S.l.], 2024. p. 273–277.
- BIOLKOVÁ, V.; KOLKA, Z.; BIOLEK, D. State-space averaging (ssa) revisited: on the accuracy of ssa-based line-to-output frequency responses of switched dc-dc converters. **WSEAS Transactions on Circuits and Systems archive**, v. 9, p. 81–90, 2010. Disponível em: <<https://api.semanticscholar.org/CorpusID:1618398>>.
- CHOUDHURY, T. R.; NAYAK, B. Comparative steady state analysis of boost and cascaded boost converter with inductive esr losses & capacitor current behaviour. **International Journal of Power Electronics and Drive Systems**, IAES Institute of Advanced Engineering and Science, v. 7, n. 1, p. 159, 2016.
- ELMA, M.; GOLI, N.; TIDA, U. R. Machine learning assisted magnetic-core coupled inductor design for interleaved buck converter. In: IEEE. **2025 26th International Symposium on Quality Electronic Design (ISQED)**. [S.l.], 2025. p. 1–8.
- ERICKSON, R. W.; MAKSIMOVIĆ, D. **Fundamentals of Power Electronics**. 3rd. ed. New York, USA: Springer Science & Business Media, 2020.
- GERBER, I. P.; MWANIKI, F. M.; VERMEULEN, H. J. Parameter estimation of a grid-tied inverter using in situ pseudo-random perturbation sources. **Energies**, MDPI, v. 16, n. 3, p. 1414, 2023.
- GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Reading, MA, USA: Addison-Wesley, 1989.
- GUO, B. et al. Online parameter identification for fractional order model of lithium ion battery via adaptive genetic algorithm. In: IEEE. **2023 IEEE 12th Data Driven Control and Learning Systems Conference (DDCLS)**. [S.l.], 2023. p. 1227–1232.
- HART, D. W. **Eletrônica de Potência**. São Paulo, Brasil: McGraw-Hill, 2011.
- KO, J.-S. et al. A novel method for predicting the leakage inductance of the high-frequency transformer in a dab converter considering parasitic capacitance. In: IEEE. **2023 IEEE Energy Conversion Congress and Exposition (ECCE)**. [S.l.], 2023. p. 3236–3241.
- KUNSTBERGS, N. et al. Improved single-layer powder core inductor design procedure for dc-dc converters. **IET Power Electronics**, Wiley Online Library, v. 17, n. 4, p. 494–510, 2024.
- MIDDLEBROOK, R. D.; CUK, S. A general unified approach to modeling switching-converter power stages. **Proceedings of the IEEE Power Electronics Specialists Conference**, IEEE, p. 18–34, 1976.

OMIDI, S. A.; JAMIL, M. Design and control of a novel cuk-boost converter using state space averaging technique with dynamic bond graph modeling. In: IEEE. **2022 IEEE 13th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)**. [S.l.], 2022. p. 0573–0582.

PAN, Y. et al. Feedforward decoupling control of interior permanent magnet synchronous motor with genetic algorithm parameter identification. **Progress In Electromagnetics Research M**, Electromagnetics Academy, v. 102, p. 117–126, 2021.

RAVERA, A. et al. Modeling the effect of air-gap length and number of turns on ferrite-core inductors working up to magnetic saturation in a buck converter. **IEEE Transactions on Circuits and Systems I: Regular Papers**, IEEE, 2024.

REN, L.; GONG, C.; ZHAO, Y. An online esr estimation method for output capacitor of boost converter. **IEEE Transactions on Power Electronics**, IEEE, v. 34, n. 10, p. 10153–10165, 2019.

The MathWorks Inc. **Boost Converter - Simulink**. 2024. Disponível em: <<https://www.mathworks.com/help/sps/ug/boost-converter.html>>.

The MathWorks Inc. **MATLAB and Simulink**. Natick, Massachusetts, USA: [s.n.], 2024. Disponível em: <<https://www.mathworks.com>>.

The MathWorks Inc. **PRBS Signal Generator - Simulink Control Design**. 2024. Disponível em: <<https://www.mathworks.com/help/releases/R2024b/slcontrol/ug/prbssignalgenerator.html>>.

6 Anexo

```

1 % Algoritmo Genetico para estimar os parametros R, L, C e D do conversor
   Boost,
2 % utilizando como referencia a funcao de transferencia de linha para
   saida Gvg(s).
3
4 clear; close all; clc; % Limpa variaveis, fecha figuras abertas e limpa
   a tela
5 tic; % Inicia o cronometro para medir o tempo de execucao do algoritmo
6
7 %% Parametros reais do conversor Boost
8 Vin = 50;           % Tensao de entrada real (V)
9 R_real = 13.3;      % Resistencia real da carga (Ohm)
10 L_real = 822e-6;   % Indutancia real do indutor (Henry)
11 C_real = 40e-6;    % Capacitancia real do capacitor (Farad)
12 D_real = 0.5;      % Ciclo de trabalho real (Duty Cycle)
13
14 %% Simulacao do Conversor Boost no Simulink
15 out = sim("Conversor_Boost.slx"); % Executa o modelo do conversor Boost
   no Simulink e salva resultados
16
17 %% Carregamento dos sinais simulados
18 t = out.tempo_sim; % Tempo de simulacao
19 vi_n = out.vi_sim_n; % Tensao de entrada sem perturbacao
20 vo_n = out.vo_sim_n; % Tensao de saida sem perturbacao
21 vi_p = out.vi_sim_p; % Tensao de entrada com perturbacao PRBS
22 vo_p = out.vo_sim_p; % Tensao de saida com perturbacao PRBS
23 il_n = out.il_sim_n; % Corrente no indutor sem perturbacao
24 il_p = out.il_sim_p; % Corrente no indutor com perturbacao
25
26 %% Validacao do Conversor Boost
27 % Grafico das tensoes de entrada e saida sem perturbacao (para verificar
   regime permanente)
28 figure;
29 plot(t(1:11953), vo_n(1:11953), 'LineWidth', 1.2); hold on;
30 plot(t(1:11953), vi_n(1:11953), 'LineWidth', 1.2); hold off;
31 xlabel('t [s]');
32 ylabel('Tensao [V]'); grid on;
33 legend('V_o (saida)', 'V_{in} (entrada)');
34

```

```

35 % Grafico da corrente no indutor (verificacao do modo de conducao
    continua - MCC)
36 figure;
37 plot(t(1:19952), il_n(1:19952), 'LineWidth', 1.2);
38 xlabel('t [s]')
39 ylabel('Corrente [A]'); grid on;
40 legend('i_L (corrente no indutor)');
41
42 % Graficos comparativos das tensoes com e sem perturbacao PRBS
43 figure;
44 subplot(2,1,1) % Subplot superior (entrada)
45 plot(t, vi_n, 'bo', 'LineWidth', 1.2); hold on;
46 plot(t, vi_p, 'LineWidth', 1.2); hold off;
47 xlabel('t [s]')
48 ylabel('Tensao de entrada [V]'); grid on;
49 legend('Vin sem perturbacao', 'Vin com perturbacao');
50
51 subplot(2,1,2) % Subplot inferior (saida)
52 plot(t, vo_n, 'bo', 'LineWidth', 1.2); hold on;
53 plot(t, vo_p, 'LineWidth', 1.2); hold off;
54 xlabel('t [s]')
55 ylabel('Tensao de saida [V]'); grid on;
56 legend('Vo sem perturbacao', 'Vo com perturbacao');
57
58 %% Processamento dos sinais e calculo de Gvg_simulado
59 Ts = t(2)-t(1); % Intervalo de amostragem
60 Fs = 1/Ts; % Frequencia de amostragem
61 N = length(t); % Numero de pontos coletados
62 f = (0:N-1).' * Fs/N; % Vetor frequencia em Hz
63 w = 2*pi*f; % Vetor frequencia angular em rad/s
64
65 % Aplicacao da FFT (Transformada rapida de Fourier) nos sinais simulados
66 Vi_n = fft(vi_n); Vo_n = fft(vo_n); % FFT dos sinais sem perturbacao
67 Vi_p = fft(vi_p); Vo_p = fft(vo_p); % FFT dos sinais com perturbacao
68
69 % Calculo da funcao transferencia simulada (experimental) Gvg
70 Gvg_real = (Vo_p - Vo_n) ./ (Vi_p - Vi_n);
71
72 % Remocao da componente continua (frequencia zero)
73 idxAC = w ~= 0;
74 w = w(idxAC); f = f(idxAC); Gvg_real = Gvg_real(idxAC);
75
76 %% Funcao objetivo para o Algoritmo Genetico (GA)

```

```

77 objfun = @(x) erroObjGvg(x,w,Gvg_real); % Define a funcao objetivo (
      minimiza o erro entre modelo teorico e simulado)
78
79 %% Limites para busca dos parametros no GA
80 % Definindo limites proximos aos valores reais ( 1 %)
81 lb = [R_real, L_real, C_real, D_real]/1.01; % Limite inferior
82 ub = [R_real, L_real, C_real, D_real]*1.01; % Limite superior
83
84 %% Configuracao e execucao do Algoritmo Genetico
85 rng(0); % Semente para reproducao dos resultados
86 gaOpts = optimoptions('ga',...
87     'PopulationSize', 200,...           % Tamanho da populacao
88     'MaxGenerations', 100,...          % Numero maximo de geracoes
89     'CrossoverFraction', 0.8,...      % Fracao de cruzamento (crossover
    )
90     'MutationFcn', @mutationadaptfeasible,... % Funcao de mutacao
    adaptativa
91     'Display', 'iter',...             % Exibicao detalhada por iteracao
92     'PlotFcn', {@gaplotbestf},...     % Exibicao grafica do fitness
93     'UseParallel', true,...           % Usa computacao paralela (
    otimizacao do tempo)
94     'OutputFcn', @gaoutfun);          % Historico do GA
95
96 % Execucao do GA para estimar parametros
97 [x_opt,~,~] = ga(objfun,4,[],[],[],[],lb,ub,[],gaOpts);
98
99 % Parametros estimados
100 R_est = x_opt(1); L_est = x_opt(2); C_est = x_opt(3); D_est = x_opt(4);
101
102 %% Erros absolutos percentuais dos parametros estimados
103 err_R = abs((R_est - R_real)/R_real)*100;
104 err_L = abs((L_est - L_real)/L_real)*100;
105 err_C = abs((C_est - C_real)/C_real)*100;
106 err_D = abs((D_est - D_real)/D_real)*100;
107
108 % Exibicao dos resultados finais no prompt
109 fprintf('\n--- RESULTADOS FINAIS (Gvg GA) ---\n');
110 fprintf('R real = %.2f      | Estimado = %.4f      | Erro = %.2f%%\n',
    R_real, R_est, err_R);
111 fprintf('L real = %.2e H | Estimado = %.4e H | Erro = %.2f%%\n', L_real,
    L_est, err_L);
112 fprintf('C real = %.2e F | Estimado = %.4e F | Erro = %.2f%%\n', C_real,
    C_est, err_C);

```

```

113 fprintf('D real = %.2f    | Estimado = %.4f    | Erro = %.2f%%\n', D_real,
        D_est, err_D);
114
115 %% Calculo das funcoes Gvg teorica e estimada para comparacao grafica
116 Gvg_teo = boostGvg(R_real,L_real,C_real,D_real,w);
117 Gvg_est = boostGvg(R_est,L_est,C_est,D_est,w);
118
119 %% Graficos comparativos das funcoes Gvg
120 figure('Name','Gvg Boost      Modulo & Fase');
121 subplot(2,1,1); % Modulo
122 semilogx(f,20*log10(abs(Gvg_teo)),'k','LineWidth',1.4); hold on;
123 semilogx(f,20*log10(abs(Gvg_real)),'r--','LineWidth',1.2);
124 semilogx(f,20*log10(abs(Gvg_est)),'b-.','LineWidth',1.2);
125 ylabel('|G_{vg}| [dB]'); title('Modulo da G_{vg}'); grid on;
126 legend('Teorico','Real','Estimado');
127
128 subplot(2,1,2); % Fase
129 semilogx(f,rad2deg(angle(Gvg_teo)),'k','LineWidth',1.4); hold on;
130 semilogx(f,rad2deg(angle(Gvg_real)),'r--','LineWidth',1.2);
131 semilogx(f,rad2deg(angle(Gvg_est)),'b-.','LineWidth',1.2);
132 xlabel('Frequencia [Hz]'); ylabel('Fase [ ]'); title('Fase da G_{vg}');
        grid on;
133
134 toc; % Exibe o tempo de execucao do algoritmo
135
136 %% FUNCOES AUXILIARES
137
138 % Funcao objetivo do Algoritmo Genetico (GA) usando Gvg
139 function val = erroObjGvg(x, w, Gvg_r)
140     % Extracao dos parametros candidatos do vetor x
141     R = x(1); % Resistencia candidata (Ohms)
142     L = x(2); % Indutancia candidata (Henry)
143     C = x(3); % Capacitancia candidata (Farad)
144     D = x(4); % Ciclo de trabalho candidato (Duty Cycle)
145
146     % Validacao inicial dos parametros fisicos candidatos
147     if any([R, L, C] <= 0 || D <= 0 || D >= 1)
148         val = 1e20; % Penalizacao: retorna valor alto se parametros
invalidos
149         return;
150     end
151
152     % Calculo da funcao de transferencia teorica usando parametros
candidatos

```

```

153     Gvg_m = boostGvg(R, L, C, D, w);
154
155     % Erro quadratico medio normalizado entre modulo das funcoes real e
156     modelo
157     erro_mod = mean((abs(Gvg_r) - abs(Gvg_m)).^2) / (max(abs(Gvg_r))^2);
158
159     % Valor retornado ao GA (menor erro indica melhor solucao)
160     val = erro_mod;
161 end
162 % Funcao de transferencia linha-saida do conversor Boost (Gvg teorico)
163 function Gvg = boostGvg(R, L, C, D, w)
164     d = 1 - D; % Complemento do ciclo de trabalho D (d = 1-D)
165
166     % Numerador da funcao de transferencia Gvg
167     num = sqrt(C/L) * d * R;
168
169     % Denominador da funcao de transferencia Gvg
170     den = R * L * C * sqrt(C/L) * (1j * w).^2 + sqrt(L*C) * (1j * w) +
171     sqrt(C/L) * d^2 * R;
172
173     % Funcao de transferencia teorica final Gvg
174     Gvg = num ./ den;
175 end
176 % Funcao de saida que salva o historico do melhor fitness do GA
177 function [state, options, optchanged] = gaoutfun(options, state, flag)
178     optchanged = false; % Indica se opcoes foram alteradas dinamicamente
179     persistent bestHist % Declara vetor persistente para historico
180
181     switch flag
182     case 'init' % Inicializacao do GA
183         bestHist = []; % Inicializa historico vazio
184     case 'iter' % A cada iteracao do GA
185         bestHist = [bestHist; state.Best(end)]; % Armazena melhor
186         fitness atual
187     case 'done' % Ao finalizar o GA
188         assignin('base', 'best_history', bestHist); % Salva
189         historico no workspace do MATLAB
190     end
191 end

```