



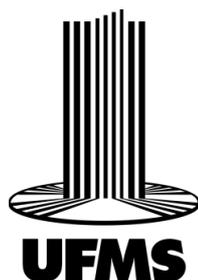
UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM SISTEMAS DE ENERGIA



**MODELOS DE PREDIÇÃO E ANÁLISE DE SENSIBILIDADE,
UTILIZANDO REDES NEURAS ARTIFICIAIS E MODELOS
ESTATÍSTICOS PARA TOPOLOGIAS HÍBRIDAS DE
TRANSFERÊNCIA DE ENERGIA SEM FIO**

Rafael de Souza Silva

Campo Grande - MS
6 de março de 2025



UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM SISTEMAS DE ENERGIA



**MODELOS DE PREDIÇÃO E ANÁLISE DE SENSIBILIDADE,
UTILIZANDO REDES NEURAIS ARTIFICIAIS E MODELOS
ESTATÍSTICOS PARA TOPOLOGIAS HÍBRIDAS DE
TRANSFERÊNCIA DE ENERGIA SEM FIO**

Rafael de Souza Silva

Dissertação de mestrado apresentada como exigência para obtenção do título de Mestrado em Engenharia Elétrica na área de Sistemas de Energia da Universidade Federal de Mato Grosso do Sul – UFMS.

Orientador: Prof. Dr. Ruben Barros Godoy

Campo Grande - MS

6 de março 2025

**MODELOS DE PREDIÇÃO E ANÁLISE DE SENSIBILIDADE,
UTILIZANDO REDES NEURAS ARTIFICIAIS E MODELOS
ESTATÍSTICOS PARA TOPOLOGIAS HÍBRIDAS DE
TRANSFERÊNCIA DE ENERGIA SEM FIO**

Dissertação de mestrado apresentada como exigência para obtenção do título de Mestrado em Engenharia Elétrica na área de Sistemas de Energia da Universidade Federal de Mato Grosso do Sul – UFMS.

Banca Examinadora:

Orientador: Prof. Dr. Ruben Barros Godoy
Orientador

Prof. Dr. Luigi Galotto Junior

Prof. Dr. Tiago Henrique de Abreu Mateus

Campo Grande - MS
6 de março de 2025

*Bendito és tu Senhor, ensina-me os teus
preceitos.*

Salmos 119:12

AGRADECIMENTOS

Agradeço primeiramente a Deus, que concede a alguns a graça do saber e a outros a honra de aprender. À minha esposa Milena Borges Pereira Silva, pelo apoio incondicional antes e durante o desenvolvimento deste trabalho. Aos meus pais, os quais investiram esforço, suor e orações na educação dos seus filhos.

Agradeço especialmente ao meu orientador e amigo Prof. Dr. Ruben Barros Godoy, que com empenho e paciência orientou meus passos durante o programa, contribuindo significativamente para minha formação pessoal e profissional.

Minha gratidão aos professores que, através de seu compromisso com as atividades diárias de ensino e orientação, desempenharam papel fundamental em minha formação. Em especial aos professores Dr. Luigi Galotto Junior, Dr. Raymundo Cordeiro e Dr. Moacyr Aureliano Britto, com os quais tive a honra de aprender tanto em sala de aula quanto em suas atividades acadêmicas.

RESUMO

Este trabalho apresenta uma análise comparativa de sensibilidade paramétrica entre as topologias Double LCC e LCC-S para sistemas de transferência de energia sem fio (WPT), bem como desenvolve e avalia métodos de estimação de parâmetros do circuito secundário utilizando técnicas de regressão e redes neurais artificiais. O estudo emprega o método de Monte Carlo para gerar um espaço amostral considerando tolerâncias típicas de componentes comerciais, permitindo avaliar o impacto das variações paramétricas no desempenho dos sistemas. A análise de sensibilidade revelou que o fator de acoplamento e as bobinas principais são os elementos de maior influência no desempenho de ambas as topologias, sendo a LCC-S mais robusta a variações paramétricas em termos de estabilidade da corrente de saída e mais sensível em relação a demais esforços de tensão e corrente. Para a estimativa de parâmetros do secundário, foram implementadas e comparadas diferentes técnicas, incluindo Rede Neural de Função Base Radial (RBF), Regressão por Componentes Principais (PCR), Regressão Ridge, Regressão Kernel e Regressão por Quadrados Mínimos Parciais (PLS). Os resultados demonstram que todas as técnicas são capazes de estimar parâmetros do secundário utilizando apenas medições do circuito primário, com destaque para o desempenho superior da PLS na redução de dimensionalidade e precisão das estimativas. A RBF demonstrou excelente capacidade na estimativa do fator de acoplamento, enquanto a regressão Ridge apresentou boa relação entre complexidade e precisão. As técnicas desenvolvidas podem ser aplicadas em sistemas de controle adaptativo, contribuindo para o desenvolvimento de sistemas WPT mais eficientes e confiáveis.

Palavras-chave: Transferência de Energia sem Fio, Análise de Sensibilidade, Estimação de Parâmetros, Aprendizado de Máquina, Topologias Híbridas.

ABSTRACT

This work presents a parametric sensitivity comparative analysis between Double LCC and LCC-S topologies for Wireless Power Transfer (WPT) systems, while developing and evaluating secondary circuit parameter estimation methods using regression techniques and artificial neural networks. The study employs the Monte Carlo method to generate a sample space considering typical tolerances of commercial components, enabling the assessment of parametric variations' impact on system performance. The sensitivity analysis revealed that the coupling factor and main coils are the most influential elements in both topologies' performance, with LCC-S being more robust to parametric variations in terms of output current stability and more sensitive regarding other voltage and current stresses. For secondary parameter estimation, different techniques were implemented and compared, including Radial Basis Function Neural Network (RBF), Principal Component Regression (PCR), Ridge Regression, Kernel Regression, and Partial Least Squares Regression (PLS). Results demonstrate that all techniques can estimate secondary parameters using only primary circuit measurements, with PLS showing superior performance in dimensionality reduction and estimation accuracy. RBF demonstrated excellent capability in coupling factor estimation, while Ridge regression presented a good balance between complexity and precision. The developed techniques can be applied in adaptive control systems, contributing to the development of more efficient and reliable WPT systems.

Keywords: Wireless Power Transfer, Sensitivity Analysis, Parameter Estimation, Machine Learning, Hybrid Topologies.

LISTA DE FIGURAS

<i>Número</i>	<i>Página</i>
Figura 1 - Topologias Básicas: (a) Série-Série; (b) Série-Paralelo; (c) Paralelo-Série; (d) Paralelo-Paralelo;	17
Figura 2 - Double LCC.....	20
Figura 3 - Modelo T equivalente da topologia Double LCC	22
Figura 4 - Teorema da superposição aplicado ao modelo T da topologia Double LCC: (a) secundário em curto-circuito; (b) primário em curto-circuito;	24
Figura 5 - Compensação LCC-S	28
Figura 6 - Modelo T equivalente LCC-S	29
Figura 7 - Exemplo de aplicação do coeficiente de Pearson	36
Figura 8 - Histogramas para o espaço amostral de indutâncias geradas (H).	52
Figura 9 - Histogramas para o espaço amostral de capacitâncias geradas (F).	52
Figura 10 – Histogramas das correntes calculadas	53
Figura 11 – Histogramas das tensões calculadas sobre as indutâncias.	53
Figura 12 – Histogramas das tensões calculadas sobre as capacitâncias.	54
Figura 13 - Histogramas das potências obtidas e o rendimento global da transferência.	55
Figura 14 - Análise de dispersões (Pout)	56
Figura 15 – Análise de dispersões (ILF1).	57
Figura 16 - Análise de dispersões (IRE)	57
Figura 17 - Análise de dispersões (VRE).	58
Figura 18 - Coeficientes de Pearson Double LCC.....	59
Figura 19 - Histogramas para o espaço amostral de indutâncias geradas.	62
Figura 20 - Histogramas para o espaço amostral de capacitâncias geradas.	62
Figura 21 - Histogramas das correntes calculadas.	63
Figura 22 - Histogramas das tensões calculadas sobre as indutâncias.	63
Figura 23 - Histogramas das tensões calculadas sobre as capacitâncias.	64
Figura 24 - Histogramas das potências obtidas e o rendimento global da transferência.	64
Figura 25 - Análise de dispersões (Pout)	66
Figura 26 - Análise de dispersões (ILF1).	66
Figura 27 - Análise de dispersões (IRE).	67

Figura 28 - Análise de dispersões (VRE).....	67
Figura 29 - Coeficientes de Pearson LCC-S	68
Figura 30 - Dados dos componentes padronizados para Double LCC	72
Figura 31 - Dados dos esforços de corrente e tensão padronizados para Double LCC.....	72
Figura 32 - Dados dos componentes padronizados para LCC-S.....	73
Figura 33 - Dados dos esforços de corrente e tensão para LCC-S.....	73
Figura 34 - Dados de treino e teste para Double LCC.....	74
Figura 35 – Dados de treino e teste para LCC-S	75
Figura 36 - Estrutura da RBF para estimativa do fator de acoplamento.....	76
Figura 37 - Estimativa do Fator de acoplamento utilizando RBF para Double LCC.....	76
Figura 38 - Estimativa do fator de acoplamento utilizando RBF para LCC-S	77
Figura 39 - Estimativa da corrente IRE para Double LCC utilizando RBF	78
Figura 40 - Estimativa da corrente IRE para LCC-S utilizando RBF.....	78
Figura 41 - Quantidade de informação explicada pelas componentes LCC-S	79
Figura 42 - Validação cruzada aplicada a PCR para topologia LCC-S	80
Figura 43 - Quantidade de informação explicada pelas componentes para Double-LCC	80
Figura 44 - Validação cruzada aplicada a PCR para Double LCC	80
Figura 45 - Estimativa da corrente IRE para Double LCC utilizando PCR	81
Figura 46 - Estimativa da corrente IRE para LCC-S utilizando PCR.....	81
Figura 47 - Validação cruzada para regressão Ridge (Double LCC).....	82
Figura 48 - Estimativa da corrente IRE para Double LCC utilizando Regressão Ridge e OLS .	83
Figura 49 - Validação cruzada para a regressão Ridge (LCC-S)	83
Figura 50 - Estimativa da corrente IRE para LCC-S utilizando Regressão Ridge e OLS	83
Figura 51 - Validação cruzada para regressão Kernel (Double LCC)	84
Figura 52 - Estimativa da corrente IRE para Double LCC utilizando Regressão Kernel	85
Figura 53 - Validação cruzada para regressão Kernel (LCC-S).....	85
Figura 54 - Estimativa da corrente IRE para LCC-S utilizando Regressão Kernel.....	85
Figura 55 - Validação cruzada para Double LCC utilizando PLS	86
Figura 56 - Validação cruzada para LCC-S utilizando PLS	86
Figura 57 - Estimativa da corrente IRE para Double LCC utilizando PLS	87
Figura 58 - Estimativa da corrente IRE para LCC-S utilizando PLS	87
Figura 59 - Inferência sobre a distribuição Gama (LCC-S)	88
Figura 60 - Inferência sobre a distribuição gama (Double-Sided LCC).....	89
Figura 61 - Distribuição dos erros por modelo aplicados a Double LCC.....	90

Figura 62 - Distribuição dos erros por modelo aplicados a LCC-S	90
Figura 63 - Erros dos modelos aplicados a estimativa de corrente IRE para Double LCC	91
Figura 64 - Erros dos modelos aplicados a estimativa de corrente IRE para LCC-S.....	91

LISTA DE TABELAS

<i>Número</i>	<i>Página</i>
Tabela 1 - Capacitâncias primárias e secundárias	18
Tabela 2 - Métodos de análise de dados para análise de sensibilidade	35
Tabela 3 - Exemplo de aplicação	36
Tabela 4 - Valores Nominais Double LCC.....	49
Tabela 5 – Esforços de corrente e tensão em condições nominais para Double LCC	50
Tabela 6 - Tolerâncias aplicadas por componente para Double LCC.....	51
Tabela 7 - Valores nominais para LCC-S	60
Tabela 8 - Esforços de tensão e corrente em condições nominais para Double LCC	60
Tabela 9 - Tolerâncias aplicadas por componente para LCC-S	61
Tabela 10 – Algoritmo utilizado na estimação dos parâmetros	70
Tabela 11 - Intervalo de confiança sobre a distribuição gama (90%).....	89
Tabela 12 - Erros relativos médios.....	92

SUMÁRIO

1. Introdução	12
1.1. Contextualização, Justificativa (motivação) para o desenvolvimento do trabalho.....	12
1.2. Objetivos	14
1.2.1. Objetivo Geral.....	14
1.2.2. Objetivos Específicos.....	15
1.3. Organização do Trabalho (Resumo dos capítulos).....	15
2. REVISÃO BIBLIOGRÁFICA.....	17
2.1. Topologias híbridas	19
2.2. Double-sided LCC	20
2.2.1. Modelo Analítico Double-Sided LCC.....	22
2.3. LCC-S.....	27
2.3.1. Modelo Analítico LCC-S.....	29
2.4. ANÁLISE DE SENSIBILIDADE.....	31
2.4.1. Método de Monte Carlo	32
2.4.2. Análise de dados.....	35
2.5. MODELOS DE REGRESSÃO E ESTIMATIVA DE PARÂMETROS	37
2.5.1. Rede Neural de Função Base Radial (RBF).....	38
2.5.2. Análise do Componente Principal (PCA) e Regressão por componente principal (PCR).....	40
2.5.3. Regressão de Quadrados Mínimos e Regressão Ridge	43
2.5.4. Regressão Kernel	45
2.5.5. Regressão por Quadrados Mínimos Parciais (PLS).....	46
3. APLICAÇÃO DA TÉCNICA DE MONTE CARLO E ANÁLISE DE SENSIBILIDADE.....	49
3.1. Double LCC – Valores nominais	49
3.2. Double LCC – Espaço amostral obtido.....	51
3.3. Double LCC – Gráficos de dispersão	55
3.4. LCC-S – Valores nominais.....	59
3.5. LCC-S – Espaço amostral obtido.....	61
3.6. LCC-S – Gráficos de dispersão	65
4. MODELOS DE REGRESSÃO PARA ESTIMATIVA DO SECUNDÁRIO	70

4.1.	Padronização dos dados	71
4.2.	Dados de treino e teste	74
4.3.	Estimativa do fator de acoplamento utilizando RBF.....	75
4.4.	Estimativa da corrente na carga utilizando RBF	77
4.5.	Estimativa da corrente na carga utilizando PCR	79
4.6.	Estimativa da corrente na carga utilizando OLS e Regressão Ridge	82
4.7.	Estimativa da corrente de carga utilizando regressão Kernel	84
4.8.	Estimativa da corrente de saída utilizando quadrados mínimos parciais (PLS)	86
5.	DISCUSSÕES	88
	Conclusões.....	94
	Referências	96

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO, JUSTIFICATIVA (MOTIVAÇÃO) PARA O DESENVOLVIMENTO DO TRABALHO

Com o avanço da eletrônica de potência e a crescente necessidade de soluções eficientes para carregamento de dispositivos, as tecnologias de transferência de energia sem fio (WPT - *Wireless Power Transfer*) têm se destacado como uma alternativa promissora aos métodos convencionais de alimentação. Entre as diversas aplicações, podemos citar as aplicações com implantes biomédicos, carregamento de veículos elétricos e eletrônicos portáteis [1, 2, 3]. Entre as diferentes abordagens de WPT, encontram-se topologias de acoplamento indutivo ressonante e não-ressonante, acoplamento capacitivo e outras tecnologias associadas a transmissão por microondas [1], a transferência de energia indutiva (IPT - *Inductive Power Transfer*) tem se mostrado particularmente eficaz devido ao seu alto rendimento na transferência de potência e relativa simplicidade de implementação [2].

O efeito de ressonância é fundamental para garantir a viabilidade da transferência de potência para sistemas fracamente acoplados por campos magnéticos [3]. O efeito ressonante pode ser realizado por meio de capacitores a compensar o efeito indutivo das bobinas de transferência, “encurtando” o caminho para a transferência de potência. Esta característica é especialmente relevante em aplicações práticas, onde a distância entre transmissor e receptor pode variar significativamente, como em carregadores de veículos elétricos [4] e dispositivos biomédicos implantáveis [5]. Deste modo, torna-se essencial a seleção dos componentes de compensação visando obter a ressonância na frequência de projeto.

Para algumas topologias, o deslocamento da frequência de ressonância do circuito pode resultar em correntes destrutivas ao circuito devido a efeitos como o de bifurcação [6]. A literatura apresenta quatro topologias clássicas de compensação (Série-Série, Série-Paralelo, Paralelo-Série e Paralelo-Paralelo) [7], que por sua vez apresentam limitações com relação a estabilidade e rendimento quando suscetíveis a variações de frequência e fator de acoplamento. Dadas as limitações destas topologias, atualmente são propostas topologias híbridas de forma a agregar características desejáveis de cada circuito e atenuar características indesejáveis. Para este trabalho foram analisadas duas topologias híbridas, sendo elas, Double LCC e LCC-S.

A análise de sensibilidade em circuitos ressonantes é um aspecto crucial no projeto e desenvolvimento de sistemas eletrônicos robustos. Em sistemas de transferência de energia sem fio, onde a precisão e a estabilidade são fundamentais, a compreensão do impacto das variações paramétricas dos componentes torna-se ainda mais relevante. As tolerâncias inerentes aos componentes comerciais, as variações térmicas e o envelhecimento dos materiais podem afetar significativamente o desempenho do sistema, alterando características fundamentais como a frequência de ressonância e a eficiência de transferência de potência [8]. Deste modo, torna-se primordial encontrar ainda em etapa de projeto componentes e parâmetros aos quais a estabilidade e a eficiência dos sistemas apresentem maior sensibilidade.

A estimativa de parâmetros em sistemas de transferência de energia sem fio tem sido objeto de diversos estudos, com abordagens que variam desde métodos analíticos tradicionais até técnicas avançadas de aprendizado de máquina [9]. Estas metodologias têm evoluído para incluir análises em tempo real e adaptativas, permitindo ajustes dinâmicos dos parâmetros do sistema em resposta a variações nas condições de operação, como mudanças no acoplamento magnético ou na carga.

A necessidade de estimar parâmetros do lado secundário é particularmente crítica em sistemas WPT, pois muitas vezes não há comunicação direta entre o receptor e o transmissor [8]. Esta limitação, combinada com a natureza variável do acoplamento magnético e as incertezas paramétricas dos componentes, torna essencial o desenvolvimento de métodos robustos de estimação que possam garantir a operação eficiente do sistema mesmo sob condições adversas de funcionamento.

M. A. Ngini, C.-T. Truong e S.-J. Choi apresentam uma revisão bibliográfica de métodos aplicados para esse fim. Destaca também a possibilidade de se utilizar técnicas avançadas como redes neurais para otimização da estimativa de parâmetros em estudos futuros [9].

Este trabalho parte de um estudo comparativo prévio entre as topologias Double LCC e LCC-S [10], expandindo a análise para incluir uma investigação detalhada da sensibilidade dos circuitos a variações paramétricas em seus componentes. Utilizando uma base de dados que considera as incertezas paramétricas típicas de componentes comerciais, o estudo propõe o uso de técnicas de regressão e redes neurais na estimativa de parâmetros do circuito secundário, contribuindo assim para um melhor entendimento do comportamento destas topologias em condições reais de operação, e possibilitando futuramente a aplicação em técnicas adaptativas de controle.

1.2. OBJETIVOS

1.2.1. Objetivo Geral

O objetivo geral deste trabalho é realizar uma análise comparativa da sensibilidade paramétrica entre as topologias Double LCC e LCC-S, bem como desenvolver e avaliar métodos de estimação de parâmetros do circuito secundário utilizando técnicas de regressão e redes neurais.

1.2.2. Objetivos Específicos

1. Desenvolver uma base de dados considerando as tolerâncias típicas de componentes comerciais;
2. Analisar o comportamento das topologias Double LCC e LCC-S frente a variações paramétricas dos componentes;
3. Implementar e comparar diferentes técnicas de regressão e redes neurais para estimação de parâmetros do circuito secundário;
4. Avaliar a precisão e robustez dos métodos de estimação propostos em diferentes condições de operação;

1.3. ORGANIZAÇÃO DO TRABALHO (RESUMO DOS CAPÍTULOS)

Capítulo 1 – Introdução - Apresenta a contextualização da transferência de energia sem fio, motivação do trabalho, justificativa para o desenvolvimento da pesquisa e objetivos. Introduz o problema da estimação de parâmetros em sistemas WPT e a necessidade de análise de sensibilidade para topologias híbridas.

Capítulo 2 - Revisão Bibliográfica - Aborda os fundamentos teóricos das topologias híbridas Double LCC e LCC-S, incluindo modelagem matemática, características operacionais e desafios. Apresenta também uma revisão sobre técnicas de análise de sensibilidade e métodos de estimação de parâmetros, incluindo redes neurais e técnicas de regressão.

Capítulo 3 - Análise de Sensibilidade - Detalha a aplicação do método de Monte Carlo para análise de sensibilidade das topologias, incluindo a geração do espaço amostral, análise estatística dos resultados e comparação do comportamento das topologias frente a variações paramétricas.

Capítulo 4 - Modelos de Regressão para Estimativa do Secundário - Desenvolve e compara diferentes técnicas de estimação, incluindo RBF, PCR, Ridge, Kernel e PLS. Apresenta o processo de padronização dos dados, treinamento dos modelos e validação dos resultados.

Capítulo 5 – Discussões - Sintetiza os principais resultados obtidos, compara o desempenho das diferentes técnicas de estimação e discute as implicações práticas para implementação em sistemas reais.

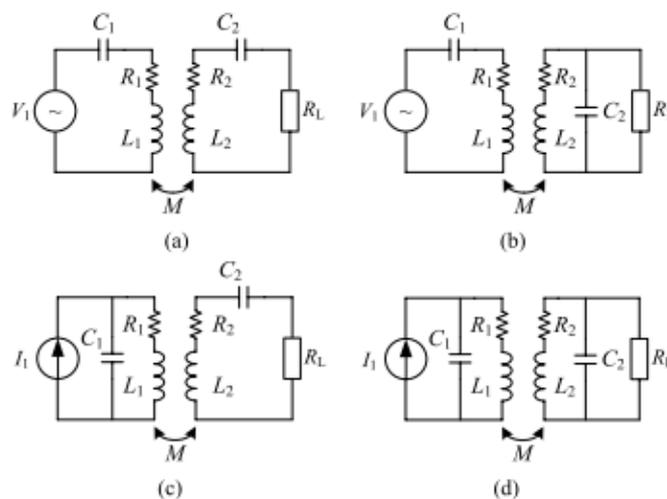
Conclusões - Apresenta as principais conclusões obtidas e aponta trabalhos futuros para melhor desempenho das técnicas abordadas.

2. REVISÃO BIBLIOGRÁFICA

A transferência de energia sem fio indutiva (IWPT - *Inductive Wireless Power Transfer*) é implementada através do acoplamento magnético entre duas bobinas, onde uma fonte de alta frequência alimenta a bobina primária que, por sua vez, induz uma tensão na bobina secundária. Para melhorar a eficiência do sistema, principalmente em casos de baixo acoplamento magnético, são utilizados capacitores de compensação que, quando adequadamente dimensionados, criam um efeito de ressonância na frequência de operação [11], [2], [3].

As topologias clássicas de compensação para sistemas IWPT são conhecidas como Série-Série (SS), Série-Paralelo (SP), Paralelo-Série (PS) e Paralelo-Paralelo (PP) [12]. A Figura 1 apresenta os circuitos de compensação clássicos e a Tabela 1 suas respectivas compensações.

Figura 1 - Topologias Básicas: (a) Série-Série; (b) Série-Paralelo; (c) Paralelo-Série; (d) Paralelo-Paralelo;



Fonte: [13]

Tabela 1 - Capacitâncias primárias e secundárias

SS	$C_2 = \frac{1}{\omega_0^2 \cdot L_2}$	$C_1 = \frac{1}{\omega_0^2 \cdot L_1}$
SP	$C_2 = \frac{1}{\omega_0^2 \cdot L_2}$	$C_1 = \frac{1}{\omega_0^2 \cdot \left(L_1 - \frac{M^2}{L_2}\right)}$
PP	$C_2 = \frac{1}{\omega_0^2 \cdot L_2}$	$C_1 = \frac{1}{\left(\frac{M^2 \cdot R_L}{L_2^2}\right)^2 + \omega_0^2 \cdot \left(L_1 - \frac{M^2}{L_2}\right)^2}$
PS	$C_2 = \frac{1}{\omega_0^2 \cdot L_2}$	$C_1 = \frac{1}{\left(\frac{\omega_0^2 \cdot M^2}{R_L}\right)^2 + \omega_0^2 \cdot L_1^2}$

Fonte: [6]

As equações da Tabela 1 apresentam as diferentes relações entre os parâmetros de operação do circuito e a compensação necessária para a ressonância. Nota-se, portanto, que cada uma das topologias apresenta características específicas:

A topologia SS apresenta cálculo simplificado para capacitância de compensação, independente da carga e do acoplamento. Entretanto, torna-se instável em condições de acoplamento nulo [14].

A topologia SP tem seu rendimento afetado por variações no acoplamento, pois a indutância mútua influencia diretamente o cálculo da capacitância de compensação [12].

As topologias PS e PP apresentam estabilidade em condição de acoplamento nulo, mas têm seu fator de qualidade significativamente afetado por variações no fator de acoplamento [13].

Um desafio comum a todas as topologias é o fenômeno de bifurcação, que pode resultar na transmissão de potência superior à projetada em frequências diferentes da nominal [6]. Este fenômeno pode ser mitigado através de restrições específicas no projeto do fator de qualidade para cada topologia [12].

Estas limitações técnicas específicas de cada circuito têm motivado o desenvolvimento de topologias híbridas, que buscam combinar as melhores características de cada configuração, visando atenuar suas limitações individuais [15].

2.1. TOPOLOGIAS HÍBRIDAS

Para superar as limitações das topologias clássicas, a literatura apresenta diversas topologias híbridas que utilizam múltiplas ressonâncias. Entre estas, destaca-se inicialmente a compensação Série-Paralelo-Série (SPS) [10], que combina características das topologias SS e PS, visando principalmente reduzir o fenômeno de bifurcação [15].

A evolução das topologias híbridas trouxe a configuração LCL (indutor-capacitor-indutor), que introduziu o conceito de simetria entre os lados primário e secundário. Esta simetria permite a bidirecionalidade do fluxo de potência [16] e apresenta vantagens como o consumo exclusivo de potência ativa e independência da corrente primária em relação à carga [17]. Para otimizar esta topologia, especialmente em relação ao tamanho dos indutores e custos, foram desenvolvidas as variações CLCL [16] e Double-Sided LCC [17].

A topologia Double-Sided LCC se destaca por suas características superiores, combinando bidirecionalidade, correntes de entrada e saída constantes, compensação independente da carga e fator de potência próximo da unidade [17]. Embora apresente rendimento ligeiramente inferior à topologia SS devido aos elementos adicionais de compensação, mantém notável estabilidade em condições de desalinhamento [10], tornando-a ideal para aplicações de carregamento dinâmico.

A partir da Double-Sided LCC, foram desenvolvidas outras variações importantes, incluindo a LCC-S, que utiliza uma única capacitância série no secundário. Esta topologia mantém a corrente de saída constante independente da carga e apresenta excelente tolerância a

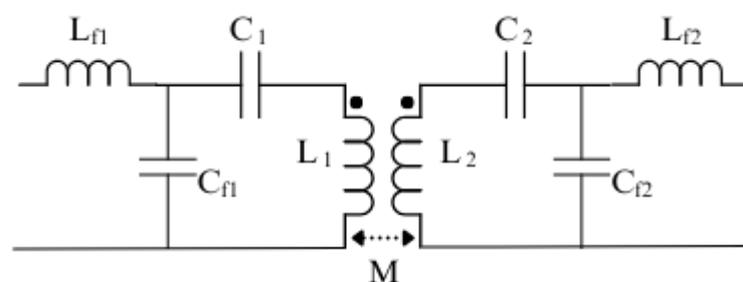
desalinhamentos. Com menor número de componentes, a LCC-S oferece uma solução mais compacta e econômica, mantendo eficiência e estabilidade na transmissão de potência [18].

Considerando as características promissoras apresentadas pela literatura referentes a rendimento, estabilidade, dimensões e custos, este trabalho focará na análise de sensibilidade e estimativa de parâmetros para as topologias Double-Sided LCC e LCC-S. As seções seguintes detalharão as metodologias de projeto e simulação para mesma potência em ambas topologias, visando compreender os parâmetros influentes em cada topologia.

2.2. DOUBLE-SIDED LCC

Entre as topologias de transferência indutiva ressonante, a topologia Double-Sided LCC é promissora e apresentado na Figura 2. A topologia apresenta um circuito de compensação híbrida mesclando as configurações clássicas apresentadas pela literatura. Entre as vantagens, o circuito apresenta a atenuação natural ao fenômeno de bifurcação [12]. O circuito simétrico da topologia agrega facilidade na implementação em aplicações com fluxo bidirecional de potência e fator de potência unitário. A metodologia de projeto desta topologia pode ser encontrada em [13].

Figura 2 - Double LCC



Fonte: [13]

Os componentes principais do circuito são descritos a seguir:

Filtros Indutores (L_{f1} e L_{f2}): os indutores L_{f1} e L_{f2} , também conhecidos como bobinas de filtro, desempenham um papel crucial na filtragem de sinais de alta frequência, permitindo

a passagem apenas das frequências desejadas. Isso melhora a eficiência da transferência de energia ao minimizar a interferência de variações de frequências. O uso das indutâncias de filtro auxilia na estabilidade do sistema para variações do sistema.

Capacitores de Filtro (C_{f2}): os capacitores de filtro, são posicionados em paralelo com os indutores L_{f1} e L_{f2} . Em conjunto com os indutores, estes elementos realizam a compensação da energia reativa do sistema para os indutores de filtro.

Capacitores Ressonantes (C_1 e C_2): os capacitores ressonantes C_1 e C_2 formam um circuito ressonante com as indutâncias L_1 e L_2 . Este circuito ajusta a frequência de ressonância do sistema, o que é crucial para otimizar a eficiência da transferência de energia.

Indutores Acoplados (L_1 e L_2): os indutores acoplados L_1 e L_2 , ou bobinas, são fundamentais para a transferência de energia sem fio. Posicionados no lado transmissor (L_1) e receptor (L_2), eles permitem a transferência de energia através do acoplamento magnético entre eles.

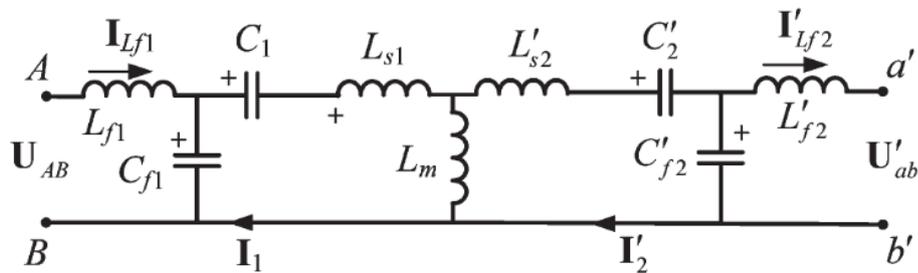
Mútuo Indutivo (M): o mútuo indutivo M representa o coeficiente de acoplamento magnético entre L_1 e L_2 . Este parâmetro é crítico para o desempenho do sistema, pois a eficiência da transferência de energia depende altamente do grau de acoplamento entre as bobinas em meio ao ar.

Neste circuito, a transferência de energia ocorre sem fio através do acoplamento magnético entre os indutores L_1 e L_2 . Os capacitores C_1 e C_2 , em conjunto com as indutâncias L_1 e L_2 , formam um circuito ressonante que facilita a transferência eficiente de energia em uma frequência específica. Os componentes L_{f1} e L_{f2} desempenham um papel crucial na estabilidade e suavização das tensões e correntes durante a transferência e frente a variações do sistema. Os capacitores C_{f1} e C_{f2} desempenham o papel de compensação da energia reativa gerada pelos filtros garantido a ressonância e o rendimento do sistema.

2.2.1. Modelo Analítico Double-Sided LCC

A fim de facilitar o desenvolvimento analítico do circuito, essa topologia é analisada utilizando o modelo T em [13]. O modelo equivalente é demonstrado nas Figuras 3 e 4. Os índices “1” e “2”, referem-se aos lados primário e secundário, respectivamente. As bobinas transmissora e receptora foram substituídas pelo equivalente L_m , calculado conforme (1). As variáveis escritas com aspas simples simbolizam elementos referenciados no lado primário da transmissão, respeitando a relação $n = \sqrt{\frac{L_2}{L_1}}$. Importante observar que, com base no fator de acoplamento, parte de L_1 e L_2 corresponde a dispersão das bobinas principais, L_{s1} e L_{s2} , conforme (2) e (3). Os demais elementos desta topologia estão devidamente referenciados ao primário, conforme (4) a (7), onde “ k ” é relativo ao fator de acoplamento entre as bobinas principais.

Figura 3 - Modelo T equivalente da topologia Double LCC



Fonte: [13]

$$L_m = k \cdot L_1 \quad (1)$$

$$L_{s1} = (1 - k) \cdot L_1 \quad (2)$$

$$L'_{s2} = (1 - k) \cdot \frac{L_2}{n^2} \quad (3)$$

$$L'_{f2} = \frac{L_{f2}}{n^2} \quad (4)$$

$$C'_2 = C_2 \cdot n^2 \quad (5)$$

$$C'_{f2} = C_{f2} \cdot n^2 \quad (6)$$

$$U'_{ab} = \frac{U_{ab}}{n} \quad (7)$$

A topologia apresenta múltiplas ressonâncias que são expressas de (8) a (11). Entretanto, para a WPT, é fundamental que todos os conjuntos ressonantes ressonem em uma única frequência. A análise é realizada sobre o teorema da superposição onde as tensões U_{AB} e U'_{ab} são analisadas separadamente na frequência ω_0 .

$$L_{f1} \cdot C_{f1} = \frac{1}{\omega_0^2} \quad (8)$$

$$L_{f2} \cdot C_{f2} = \frac{1}{\omega_0^2} \quad (9)$$

$$L_1 - L_{f1} = \frac{1}{\omega_0^2 \cdot C_1} \quad (10)$$

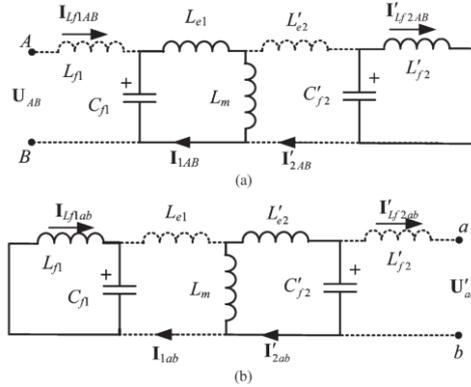
$$L_2 - L_{f2} = \frac{1}{\omega_0^2 \cdot C_2} \quad (11)$$

A fim de se calcular as correntes e tensões sobre o circuito proposto, sugere-se que o princípio da superposição seja aplicado. Sendo assim, a Figura 4 resume as duas condições consideradas, sendo importante observar que as capacitâncias C_1 e C'_2 e as indutâncias L_{s1} e L'_{s2} (vide Figura 3) foram substituídas pelas indutâncias equivalentes L_{e1} e L'_{e2} , conforme se observa em (12) e (13).

$$L_{e1} = \frac{1}{j \cdot \omega_0} \left(\frac{1}{j \cdot \omega_0 \cdot C_1} + j \cdot \omega_0 \cdot L_{s1} \right) = L_{f1} - k \cdot L_1 \quad (12)$$

$$L'_{e2} = \frac{1}{j \cdot \omega_0} \left(\frac{1}{j \cdot \omega_0 \cdot C'_{f2}} + j \cdot \omega_0 \cdot L'_{s2} \right) = L'_{f2} - k \cdot L_1 \quad (13)$$

Figura 4 - Teorema da superposição aplicado ao modelo T da topologia Double LCC: (a) secundário em curto-circuito; (b) primário em curto-circuito;



Fonte: [13]

Analisando inicialmente a Figura 4 (a), onde o secundário está em curto-circuito e U_{AB} alimenta o circuito, devido a ressonância paralela que ocorre entre L'_{f2} e C'_{f2} , I'_{2AB} tem valor nulo. Portanto, conforme (19), o L_{e1} e L_m estarão conectados em série.

$$L_{e1} + L_m = L_{f1} - k \cdot L_{f1} + k \cdot L_1 = L_{f1} \quad (14)$$

Ainda com vistas à Figura 4 (a), outra ressonância paralela é formada entre C_{f1} e L_{f1} , o que resulta em I_{Lf1AB} igual a zero. A nulidade dessas correntes permite concluir que a tensão em C_{f1} é igual a tensão U_{AB} e a tensão em C_{f2} igual a tensão em L_m . Sendo assim, os valores de I_{1AB} e I'_{Lf2AB} podem ser calculados conforme (15) e (16).

$$I_{1AB} = \frac{U_{AB}}{j \cdot \omega_0 \cdot L_{f1}} \quad (15)$$

$$I'_{Lf2AB} = \frac{k \cdot U_{AB} \cdot L_1}{j \cdot \omega_0 \cdot L_{f1} \cdot L'_{f2}} \quad (16)$$

A análise similar pode ser realizada a partir da Figura 4 (b), colocando os terminais primários em curto-circuito e aplicando-se ao secundário tensão U'_{ab} . Os subscritos “ab”

descrevem a contribuição de corrente referente a U_{ab} . Análogo a análise realizada para a Figura 4 (a), pode-se concluir que I'_{Lf2ab} e I_{1ab} são nulas. Conseqüentemente, as correntes resultantes para I'_{2ab} e I_{Lf1ab} podem ser calculadas a partir de (17) e (18).

$$I'_{2ab} = -\frac{U'_{ab}}{j \cdot \omega_0 \cdot L'_{f2}} \quad (17)$$

$$I_{Lf1ab} = -\frac{k \cdot U'_{ab} \cdot L_1}{j \cdot \omega_0 \cdot L_{f1} \cdot L'_{f2}} \quad (18)$$

Se obtivermos as variáveis destacadas em **negrito** compostas por seu módulo e ângulo, e assumirmos U_{AB} como referência de tensão, obteremos as expressões (19) e (20).

$$\mathbf{U}_{AB} = U_{AB} \angle 0^\circ \quad (19)$$

$$\mathbf{U}'_{ab} = \frac{U'_{ab}}{j} = U'_{ab} \angle -90^\circ \quad (20)$$

Por meio da sobreposição das correntes calculadas em (15) e (18) e considerando as tensões vetoriais apresentadas em (19) e (20), é possível calcular as correntes resultantes conforme (21) a (24).

$$I_{Lf1} = I_{Lf1ab} = \frac{k \cdot L_1 \cdot U'_{ab}}{\omega_0 \cdot L_{f1} \cdot L'_{f2}} \angle 0^\circ = \frac{k \cdot \sqrt{L_1 \cdot L_2} \cdot U_{ab}}{\omega_0 \cdot L_{f1} \cdot L_{f2}} \angle 0^\circ \quad (21)$$

$$I_1 = I_{1AB} = \frac{U_{AB}}{j \cdot \omega_0 \cdot L_{f1}} = \frac{U_{AB}}{\omega_0 \cdot L_{f1}} \angle -90^\circ \quad (22)$$

$$I_2 = \frac{I'_2}{n} = \frac{I'_{2ab}}{n} = \frac{U'_{ab}}{n \cdot \omega_0 \cdot L'_{f2}} \angle 0^\circ = \frac{U_{ab}}{\omega_0 \cdot L_{f2}} \angle 0^\circ \quad (23)$$

$$I_{Lf2} = \frac{I'_{Lf2}}{n} = \frac{I'_{Lf2AB}}{n} = \frac{k \cdot \sqrt{L_1 \cdot L_2} \cdot U_{AB}}{\omega_0 \cdot L_{f1} \cdot L_{f2}} \angle -90^\circ \quad (24)$$

Visando analisar a resposta do circuito para condições diferentes dos dados de projeto, ou seja, supondo variações no fator de acoplamento e na frequência de operação, torna-se importante conhecer a impedância do sistema vista a partir da fonte de entrada. Uma vez que, para esse cálculo, o ponto de ressonância deve ser desconsiderado, o valor da impedância equivalente contará com muitos termos, conforme se observa em (25) e (26).

$$A = \frac{\left(R_E + j \cdot \frac{L_{P2} \cdot \omega}{n^2}\right) \cdot \left(\frac{-j}{n^2 \cdot C_{f2} \cdot \omega}\right)}{R_E + j \cdot \left(\frac{L_{P2} \cdot \omega}{n^2} - \frac{1}{n^2 \cdot C_{f2} \cdot \omega}\right)} + j \cdot \left(\frac{L_2 \cdot \omega \cdot (1-k)}{n^2} - \frac{1}{n^2 \cdot C_2 \cdot \omega}\right) \quad (25)$$

$$Z_{eq} = j \cdot \left[L_{f1} \cdot \omega - \frac{\left(\frac{A \cdot k \cdot L_1 \cdot \omega}{A + k \cdot L_1 \cdot \omega} + (1-k) \cdot L_1 \cdot \omega - \frac{1}{C_1 \cdot \omega}\right) \cdot \left(\frac{1}{C_{f1} \cdot \omega}\right)}{\frac{A \cdot k \cdot L_1 \cdot \omega}{A + k \cdot L_1 \cdot \omega} + (1-k) \cdot L_1 \cdot \omega - \frac{1}{C_1 \cdot \omega} - \frac{1}{C_{f1} \cdot \omega}} \right] \quad (26)$$

Supondo L_1 e L_2 conhecidos e iguais, L_{f1} e L_{f2} podem ser calculados conforme (27) [13].

$$L_{f2} = L_{f1} = \sqrt{\frac{\sqrt{L_1 \cdot L_2}}{\omega_0 \cdot P} \cdot k \cdot U_{AB} \cdot U_{ab}} \quad (27)$$

A partir das indutâncias de filtro, L_{f1} e L_{f2} , as capacitâncias C_{f1} e C_{f2} podem ser obtidas conforme (8) e (9). Consequentemente, de posse das indutâncias das bobinas principais (L_1 e L_2), as capacitâncias C_1 e C_2 podem ser calculadas segundo (10) e (11).

Utilizando (25) a (27), para frequência de ressonância ω_0 , os esforços de tensão e corrente podem ser calculados em todos os elementos do circuito.

$$I_{C_{f1}} = I_{L_{f1}} - I_1 \quad (28)$$

$$I_{C_{f_2}} = I_2 - I_{L_{f_2}} \quad (29)$$

$$V_{C_1} = \frac{I_1}{\omega_0 \cdot C_1} \quad (30)$$

$$V_{C_2} = \frac{I_2}{\omega_0 \cdot C_2} \quad (31)$$

$$V_{C_{f_1}} = \frac{I_{C_{f_1}}}{\omega_0 \cdot C_{f_1}} \quad (32)$$

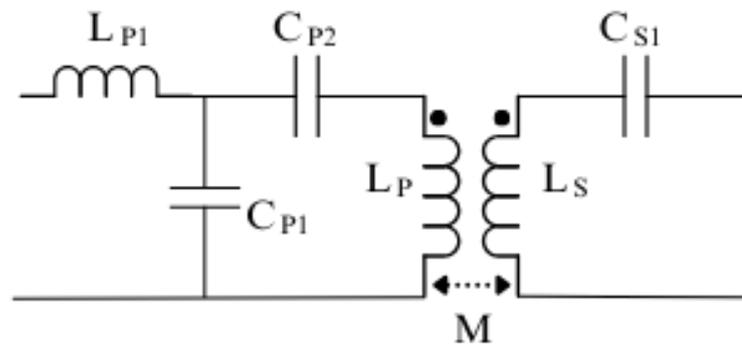
$$V_{C_{f_2}} = \frac{I_{C_{f_2}}}{\omega_0 \cdot C_{f_2}} \quad (33)$$

A potência transferida pela topologia, para frequência de ressonância ω_0 , pode ser calculada em (27).

2.3. LCC-S

A topologia LCC-S é idealizada com a finalidade de reduzir os números de componentes utilizados na Double LCC, mantendo as características de estabilidade obtidas por meio da compensação LCC no circuito primário. A compensação em série no circuito secundário apresenta ao sistema a característica de saída de corrente constante. Deste modo, a topologia apresentada na Figura 5, possui uma transmissão de potência estável e eficiente [14].

Figura 5 - Compensação LCC-S



Fonte: [14].

A metodologia de projeto desta topologia pode ser encontrada em [14]. Os componentes principais do circuito são descritos a seguir:

Indutor (L_{P1}): O indutor L_{P1} , representado por uma bobina, desempenha um papel crucial na formação de uma rede LC com os capacitores subsequentes, contribuindo para a filtragem e estabilidade do sistema de forma análoga a Double LCC.

Capacitores (C_{P1} e C_{P2}): Estes capacitores estão configurados em paralelo (C_{P1}) e em série (C_{P2}) com o indutor L_{P1} . A combinação destes elementos resulta na compensação da energia reativa do sistema.

Indutores Acoplados (L_P e L_S): os indutores acoplados L_P e L_S , ou bobinas, são fundamentais para a transferência de energia sem fio. Posicionados no lado transmissor (L_P) e receptor (L_S), eles permitem a transferência de energia através do acoplamento magnético entre eles.

Capacitor (C_{S1}): Posicionado em série após o indutor secundário L_S , o capacitor C_{S1} , em conjunto com L_S , realiza a compensação da energia reativa, de modo a garantir o efeito de ressonância do sistema.

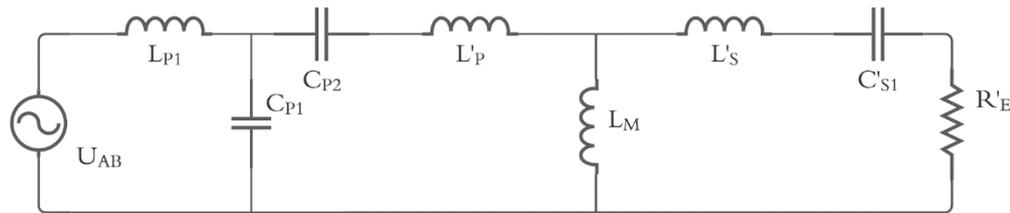
Mútuo Indutivo (M): Representado por setas curvas entre L_P e L_S , o mútuo indutivo M indica o coeficiente de acoplamento magnético entre os indutores primário e secundário.

Neste circuito, a transferência de energia ocorre sem fio através do acoplamento magnético entre os indutores L_P e L_S . Os capacitores C_{P1} , C_{P2} e C_{S1} em conjunto com as indutâncias L_{P1} , L_P e L_S , formam um circuito ressonante que facilita a transferência eficiente de energia em uma frequência específica.

2.3.1. Modelo Analítico LCC-S

O modelo de T equivalente é representado pela Figura 6. As equações de equivalência são descritas de (34) e (39) [14].

Figura 6 - Modelo T equivalente LCC-S



Fonte: [14].

$$L'_P = (1 - k) \cdot L_P \quad (34)$$

$$L'_S = (1 - k) \cdot n^2 \cdot L_S \quad (35)$$

$$L_M = n \cdot M \quad (36)$$

$$n = \sqrt{\frac{L_P}{L_S}} \quad (37)$$

$$C'_{S1} = \frac{C_{S1}}{n^2} \quad (38)$$

$$R'_E = n^2 \cdot R_E \quad (39)$$

Para um valor qualquer de frequência, a impedância equivalente do circuito pode ser calculada de acordo com (40) e (41).

$$A = \frac{n^3 \cdot M \left(\frac{1}{C_{S1}} - \omega^2 \cdot (1-k) \cdot L_S \right) + j \cdot (R_E \cdot n \cdot M \cdot \omega)}{R_E - j \cdot \left[\frac{n^2}{C_{S1} \cdot \omega} - L_S \cdot (1-k) \cdot \omega \cdot n^2 - n \cdot M \cdot \omega \right]} \quad (40)$$

$$Z_{eq} = \frac{\left[A + j \cdot \left((1-k) \cdot L_P \cdot \omega - \frac{1}{C_{P2} \cdot \omega} \right) \right] \cdot \frac{-j}{C_{P1} \cdot \omega}}{A + j \cdot \left((1-k) \cdot L_P \cdot \omega - \frac{1}{C_{P2} \cdot \omega} - \frac{1}{C_{P1} \cdot \omega} \right)} + j \cdot L_{P1} \cdot \omega \quad (41)$$

Através das Leis de Kirchhoff, podem ser calculados os esforços de corrente e tensão em cada elemento do circuito apresentado na Figura 6 utilizando das equações (42)-(48).

$$I_{LP1} = \frac{U_{AB}}{Z_{eq}} \quad (42)$$

$$I_{LP} = \frac{-j \cdot I_{LP1} \cdot \left(\frac{1}{C_{P1} \cdot \omega_0} \right)}{j \cdot \left[(1-k) \cdot L_P \cdot \omega_0 - \frac{1}{C_{P1} \cdot \omega_0} - \frac{1}{C_{P2} \cdot \omega_0} \right] + A} \quad (43)$$

$$I_{CP1} = I_{LP1} - I_{LP} \quad (44)$$

$$I_{RE} = \left(\frac{j \cdot I_{LP} \cdot n \cdot M \cdot \omega_0}{j \cdot \left[n \cdot M \cdot \omega_0 + (1-k) \cdot L_S \cdot n^2 \cdot \omega_0 - \frac{n^2}{C_{S1} \cdot \omega_0} \right] + R_E} \right) \cdot n \quad (45)$$

$$V_{CS1} = \frac{I_{RE} \cdot \left(\frac{-j}{C_{P1} \cdot \omega_0} \right)}{n} \quad (46)$$

$$V_{CP2} = I_{LP} \cdot \left(\frac{-j}{C_{P2} \cdot \omega_0} \right) \quad (47)$$

$$V_{CP1} = (I_{LP1} - I_{LP}) \cdot \left(\frac{-j}{C_{P1} \cdot \omega_0} \right) \quad (48)$$

Partido do pressuposto que as bobinas transmissora e receptora estejam selecionadas (L_P e L_S), para o ponto de ressonância, a indutância de filtro L_{P1} e as correntes de saída podem

ser calculadas de acordo com (49) e (50). Tendo-se a corrente de saída, a potência na carga e a resistência de carga podem ser relacionadas através de (51).

$$L_{P1} = \frac{8.U_d}{\pi^2.\omega_0.I_{out}} \sqrt{\frac{L_P}{L_S}} \quad (49)$$

$$I_{out} = \frac{8.\sqrt{\frac{L_P}{L_S}}.U_d}{\pi.\omega_0.L_{P1}} \quad (50)$$

$$P_{out} = \frac{64.U_d^2.L_P}{\pi^4.\omega_0^2.L_{P1}^2.L_S} R_{out} \quad (51)$$

As capacitâncias primárias e a capacitância secundária podem ser calculadas de (52) a (54).

$$C_{P1} = \frac{1}{\omega_0^2.L_{P1}} + \frac{1}{\omega_0^2.L_P.k} \quad (52)$$

$$C_{P2} = \frac{1}{\omega_0^2.L_P.(1-k)} \quad (53)$$

$$C_{S1} = \frac{1}{\omega_0^2.(1-k).L_S} \quad (54)$$

Por meio do equacionamento acima, poderão ser calculados os parâmetros nominais tanto para seleção de componentes, como para esforços em corrente e tensão para cada item do circuito.

2.4. ANÁLISE DE SENSIBILIDADE

Conforme a seção anterior, podemos obter os valores nominais de projeto para cada circuito. Para valores nominais, as topologias apresentam excelentes resultados para rendimento e estabilidade quando submetidas a variações de acoplamento e frequência de

operação em relação às topologias convencionais. Entretanto, as não idealidades dos circuitos quando implementados podem prejudicar a transferência de potência, alterando inclusive os pontos de ressonância dos circuitos. Zhang et al. [8] demonstraram através de análises de sensibilidade local que variações nos componentes do circuito podem impactar significativamente o desempenho do sistema, especialmente em redes de compensação de alta ordem. As não idealidades são principalmente atribuídas às tolerâncias dos componentes utilizados, como indutores, capacitores e resistores, que podem variar até 30% do valor nominal em casos de indutores comerciais. O acoplamento também apresenta variação natural dada as aplicações de interesse, onde as bobinas são frequentemente desalinhadas.

A análise de sensibilidade é uma técnica vital em modelagem e simulação, utilizada para determinar como a incerteza nos parâmetros de entrada afeta a variabilidade na saída de um sistema. Existem diversos tipos de análise de sensibilidade, incluindo a análise local, que examina o efeito de pequenas variações em torno de um ponto de operação, e a análise global, que considera a variabilidade em toda a gama de possíveis valores dos parâmetros de entrada. Neste estudo, será realizada uma análise de sensibilidade global utilizando o método de Monte Carlo, que será detalhado na próxima seção, permitindo uma avaliação mais abrangente do impacto das variações paramétricas no desempenho do sistema.

2.4.1. Método de Monte Carlo

O Método de Monte Carlo (MMC) é uma técnica computacional baseada em amostragem aleatória que permite analisar problemas complexos através de simulações estatísticas. Em sistemas de transferência de energia sem fio, o MMC tem sido amplamente utilizado para avaliar o impacto de incertezas paramétricas no desempenho de diversos sistemas.

O processo básico do MMC envolve a geração de números aleatórios seguindo distribuições de probabilidade específicas para cada parâmetro de interesse, simulação do

sistema para cada conjunto de parâmetros gerados, e análise estatística dos resultados obtidos. Em sistemas WPT, as distribuições mais comumente utilizadas são a normal (gaussiana) para tolerâncias de componentes e a uniforme para variações de posicionamento [8].

Zhang et al. [8] aplicaram o MMC para analisar a sensibilidade de redes de compensação de alta ordem em sistemas WPT, avaliando o impacto de variações nos componentes no desempenho do sistema. O estudo demonstrou que o método é eficaz para identificar os parâmetros mais críticos e suas interações, permitindo otimizar o projeto para maior robustez. Larbi et al. [19] expandiram essa análise utilizando o MMC em conjunto com técnicas de regressão para caracterizar a variabilidade em sistemas WPT integrados.

Uma das principais vantagens do MMC, destacada por Zhang et al. [8], é sua capacidade de avaliar simultaneamente múltiplas fontes de variação, permitindo uma análise abrangente das interações entre diferentes parâmetros do circuito. Esta característica é especialmente relevante em sistemas WPT, onde as tolerâncias dos componentes podem ter efeitos combinados significativos. Além disso, Larbi et al. [19] demonstraram que a combinação do MMC com técnicas de regressão, como Partial Least Squares (PLS), pode fornecer modelos estatísticos robustos capazes de prever o comportamento do sistema frente a variações paramétricas, sejam elas decorrentes das tolerâncias de fabricação dos componentes ou das condições de operação, permitindo assim uma análise mais precisa da confiabilidade do sistema.

Para garantir resultados estatisticamente significativos, [8] e [19] estabeleceram que o número de simulações deve ser determinado com base na complexidade do circuito e no número de parâmetros analisados. Em seus estudos, utilizaram 10.000 simulações para análise de redes de compensação de alta ordem, obtendo convergência satisfatória nos resultados. Esta base de dados gerada pelo MMC será posteriormente utilizada para treinamento e validação dos modelos de regressão e redes neurais propostos neste trabalho.

Para aplicar o método de Monte Carlo a um circuito eletrônico, primeiramente, é necessário definir os parâmetros de entrada do modelo. Esses parâmetros correspondem aos valores nominais dos componentes eletrônicos, como resistores, capacitores e indutores, e suas respectivas incertezas ou tolerâncias, representadas como desvios padrões. A incerteza ou variabilidade de cada componente é modelada usando uma distribuição normal. Para cada componente i , a distribuição normal é caracterizada pela média μ_i , que representa o valor nominal do componente, e pelo desvio padrão σ_i , que representa a tolerância ou variação esperada em torno do valor nominal. Assim, os valores amostrados para cada componente seguem a distribuição apresentada em (55):

$$x_i \sim \mathcal{N}(\mu_i, \sigma_i^2) \quad (55)$$

sendo x_i é o valor do componente i , μ_i é a média (valor nominal) e σ_i é o desvio padrão (tolerância).

Uma vez geradas as amostras aleatórias dos componentes, o próximo passo é executar o modelo do circuito para cada conjunto de amostras. Isso implica simular o comportamento do circuito para cada combinação de valores dos componentes, obtendo as saídas correspondentes, como tensões e correntes. Por exemplo, em um circuito ressonante LCC-LCC, os valores dos resistores, capacitores e indutores seriam variados de acordo com suas distribuições normais, e o comportamento do circuito seria avaliado para cada configuração.

Utilizando, portanto, de uma amostra aleatória das simulações obtidas, podemos aplicar métodos estatísticos para realizar uma análise dos dados visando encontrar correlações entre as variáveis de entrada e de interesse.

2.4.2. Análise de dados

A análise de dados pode ser realizada através de diversos métodos estatísticos, cada um com suas próprias características, vantagens e desvantagens. O coeficiente de correlação de Pearson é uma medida estatística que quantifica a força e a direção da relação linear entre dois conjuntos de dados [20]. É definido pela equação (56):

$$r_{XY} = \frac{cov(X,Y)}{\sigma_X \sigma_Y} \quad (56)$$

sendo, r_{XY} é o coeficiente de correlação de Pearson entre as variáveis X e Y, $cov(X, Y)$ é a covariância entre X e Y, σ_X e σ_Y são respectivamente os desvios padrão de X e Y;

O coeficiente de Pearson pode variar de +1 a -1, identificando respectivamente a intensidade da correlação linear positiva ou negativa entre as variáveis comparadas. Esta técnica permite que sejam analisados os principais componentes com efeito sobre as variáveis de saída [20].

Outras metodologias de análise de dados podem ser utilizadas para a análise de sensibilidade do modelo. Dentre os métodos, três se destacam apresentam diferentes características para compreensão do modelo estatístico. Para este trabalho, até o presente momento, optou-se pelo uso da análise por coeficiente de Pearson. A Tabela 2 apresenta outros métodos possíveis para a análise, bem como vantagens e desvantagens.

Tabela 2 - Métodos de análise de dados para análise de sensibilidade

Critério	Coeficiente de Pearson	ANOVA	Índices de Sobol
Tipo de Relação	Linear	Linear e algumas não linearidades	Linear e não linear
Facilidade de Cálculo	Alta	Moderada	Baixa
Consideração de Interações entre variáveis	Não	Sim	Sim
Sensibilidade a Outliers	Alta	Moderada	Baixa

Critério	Coefficiente de Pearson	ANOVA	Índices de Sobol
Aplicação em Modelos Complexos	Limitada	Moderada	Alta
Complexidade Computacional	Baixa	Moderada	Alta

Fonte: Autor.

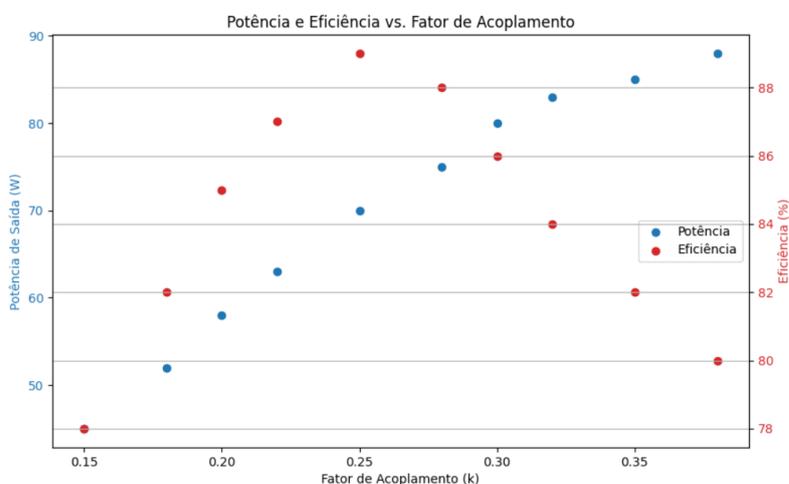
Para exemplificar a aplicação do coeficiente de Pearson, considere um experimento onde foram medidas a potência de saída (P_{out}), o fator de acoplamento (k) e a eficiência (η) de um sistema WPT em 10 diferentes posições e frequências de operação, conforme apresentado na Tabela 3. A Figura 7 apresenta a distribuição de pontos medidos.

Tabela 3 - Exemplo de aplicação

Posição	k	P_{out} (W)	η (%)
1	0.15	45	78
2	0.18	52	82
3	0.20	58	85
4	0.22	63	87
5	0.25	70	89
6	0.28	75	88
7	0.30	80	86
8	0.32	83	84
9	0.35	85	82
10	0.38	88	80

Fonte: Autor.

Figura 7 - Exemplo de aplicação do coeficiente de Pearson



Fonte: Autor.

A análise dos coeficientes de Pearson mostra uma forte relação positiva ($r = 0.993$) entre o fator de acoplamento (k) e a potência de saída (P_{out}), enquanto a relação entre k e a eficiência (η) é mais complexa, sendo positiva até $k = 0.25$ e depois negativa ($r = -0.142$). Embora correlações não impliquem necessariamente causalidade, a teoria de WPT confirma que tanto o fator de acoplamento quanto a frequência de operação influenciam diretamente o desempenho do sistema, através de relações causais que envolvem múltiplos fatores como perdas nos componentes e efeitos da frequência de ressonância.

Portanto, esse método possibilita identificar a quais variações paramétricas o sistema possui maior sensibilidade por meio de fortes correlações lineares, podendo contribuir para melhor seleção de componentes e manufatura para determinadas condições de operação.

2.5. MODELOS DE REGRESSÃO E ESTIMATIVA DE PARÂMETROS

Em aplicações de transferência de energia sem fio é incomum o uso de sensores para os parâmetros do circuito secundário, visto que não podem ser transmitidos por meio de cabos de comunicação e o uso de ondas eletromagnéticas sofre constante influência das altas frequências e do campo magnético das bobinas [15]. Estudos mostram que as interferências causadas pelas altas frequências e pelos campos magnéticos podem alterar significativamente o desempenho do sistema de transferência de energia [16]. Portanto, este item propõe a estimativa dos parâmetros secundários com base em dados da amostra gerada no item anterior por meio de técnicas de regressão convencionais, otimizadas e um algoritmo de rede neural.

A correta estimativa desses parâmetros é essencial para a implementação eficaz de técnicas de controle. Com dados precisos sobre tensão e corrente, é possível ajustar dinamicamente os componentes do sistema para manter condições operacionais ideais, adaptando-se a mudanças nas condições de carga ou ambiente. Isso não apenas melhora a eficiência do sistema, mas também aumenta sua robustez e resiliência, prevenindo sobrecargas

e minimizando perdas. A integração de dados estimados em algoritmos de controle avançados, como controle preditivo e adaptativo, permite uma resposta mais rápida e precisa às variações, assegurando uma operação estável e segura.

Outro parâmetro a ser estimado é o fator de acoplamento (k). Medir o fator de acoplamento em sistemas de transferência de energia sem fio apresenta desafios significativos devido à natureza complexa das interações eletromagnéticas entre as bobinas transmissora e receptora. O fator de acoplamento, que apresenta alto fator de influência sobre a transferência de potência para ambas as topologias, pode ser influenciado por diversas variáveis, como a distância entre as bobinas, o alinhamento, e as características do meio ambiente. A variação de qualquer um desses parâmetros pode levar a flutuações no fator de acoplamento, dificultando medições consistentes e precisas. Além disso, os métodos tradicionais de medição muitas vezes não conseguem capturar os efeitos dinâmicos das altas frequências e das condições de operação realistas. De acordo com estudos recentes, como os apresentados por K. Kim et al. (2018) e H. Zhang et al. (2019), é necessário desenvolver técnicas de medição mais robustas e adaptativas para superar essas dificuldades e obter uma avaliação precisa do fator de acoplamento em condições operacionais variadas [21] [22].

Para o fator de acoplamento, optou-se pelo uso de uma Rede Neural Artificial (RBF). Foram utilizadas das seguintes técnicas afim de obter a estimativa da corrente na carga: Radial Basic Function (RBF); Regressão com componentes principais (PCR); Regressão de quadrados mínimos (OLS); Regressão Ridge; Regressão Kernel; Regressão de quadrados mínimos parciais (PLS).

2.5.1. Rede Neural de Função Base Radial (RBF)

A Rede Neural de Função de Base Radial (RBF) é amplamente utilizada em problemas de classificação, regressão e aproximação de funções devido à sua capacidade de modelar

funções complexas e não lineares de forma eficiente. Uma rede neural RBF é composta por três camadas principais:

Camada de Entrada: Esta camada recebe os dados de entrada e os transmite para a camada oculta sem realizar qualquer transformação.

Camada Oculta: A camada oculta contém os neurônios RBF, que aplicam funções de base radial aos dados de entrada. A função de base radial mais comum é a Gaussiana, definida pela equação (57).

$$\phi(\|x - c_i\|) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) \quad (57)$$

onde $\|x - c_i\|$ é a distância Euclidiana entre a entrada x e o centro do neurônio c_i , e σ_i é o desvio padrão que determina a largura da função Gaussiana.

Camada de Saída: A camada de saída realiza uma combinação linear das saídas da camada oculta, produzindo a saída final da rede. Para um problema de regressão, a saída y da rede pode ser expressa pela equação (58).

$$y(x) = \sum_{i=1}^N w_i \phi(\|x - c_i\|) \quad (58)$$

onde w_i são os pesos que conectam os neurônios da camada oculta à camada de saída, e N é o número de neurônios na camada oculta.

Dada a robustez da técnica em estimar parâmetros, após a estimativa o fator de acoplamento, a mesma técnica é utilizada para estimativa dos demais parâmetros do secundário.

2.5.2. Análise do Componente Principal (PCA) e Regressão por componente principal (PCR)

Dentre as técnicas de análise de dados, podemos citar a técnica de PCA (Principal Component Analysis). Esta técnica utiliza de uma transformação de modo que, um conjunto de dados correlacionados, é transformado em um conjunto de variáveis não correlacionadas entre si. De modo que as primeiras variáveis (componentes principais) carregam em si a maior variabilidade do sistema. Em um circuito de transferência de energia sem fio, dados como corrente e tensão de um determinado sistema podem apresentar alta correlação. Utilizando da análise de componente principal, é possível otimizar o condicionamento do modelo e a estimativa de parâmetros analisando apenas o subconjunto de variáveis transformadas com maior variabilidade.

A matriz de covariância dos dados centralizados é calculada conforme equação (59):

$$\Sigma = \frac{1}{n-1} X_{\text{centralizado}}^T X_{\text{centralizado}} \quad (59)$$

onde Σ é a matriz de covariância de dimensão $p \times p$.

A matriz de covariância Σ é então decomposta para encontrar seus autovalores e autovetores conforme a equação (60).

$$\Sigma v_i = \lambda_i v_i \quad (60)$$

onde λ_i são os autovalores e v_i são os autovetores correspondentes. Os autovetores formam uma base ortonormal e os autovalores indicam a variância explicada por cada componente principal.

Os autovetores correspondentes aos maiores autovalores são selecionados como componentes principais. A matriz dos componentes principais V é formada pelos k autovetores selecionados apresentados na equação (61):

$$V = [v_1, v_2, \dots, v_k] \quad (61)$$

Os dados originais são transformados no espaço dos componentes principais conforme equação (62).

$$T = X_{\text{centralizado}}V \quad (62)$$

onde T é a matriz dos dados transformados no espaço dos componentes principais.

Com os componentes principais T , realiza-se uma regressão linear múltipla para prever a variável dependente Y conforme equação (63).

$$Y = T\beta + \epsilon \quad (63)$$

onde Y é o vetor de respostas, T é a matriz de componentes principais, β é o vetor de coeficientes de regressão, ϵ é o termo de erro.

Os coeficientes de regressão são estimados usando a fórmula dos mínimos quadrados conforme (64).

$$\hat{\beta} = (T^T T)^{-1} T^T Y \quad (64)$$

Finalmente, as previsões para novas observações X_{nova} pode ser realizada primeiramente padronizando os novos dados por meio da equação (65).

$$X_{nova, padronizado} = \frac{X_{nova} - \bar{X}}{\sigma} \quad (65)$$

Os dados padronizados são transformados para o espaço dos componentes principais utilizando a matriz de componentes V como apresenta a equação (66).

$$T_{nova} = X_{nova, padronizado} V \quad (66)$$

Por fim, a estimativa dos dados pode ser obtida por meio de um modelo de regressão simples por meio dos coeficientes de regressão obtidos inicialmente utilizando a equação (67).

$$\hat{Y}_{nova} = T_{nova} \hat{\beta} \quad (67)$$

Esta técnica pode ser aplicada para análise de componentes das topologias de transferência de energia sem fio, visando modelos com menor quantidade de variáveis para a estimativa de parâmetros.

2.5.3. *Regressão de Quadrados Mínimos e Regressão Ridge*

A regressão linear é uma técnica fundamental em estatística e aprendizado de máquina, utilizada para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes. Duas técnicas comuns de regressão são a Regressão Linear Ordinária (OLS) e a Regressão Ridge. A seguir, apresentamos uma descrição detalhada e a formulação matemática de cada técnica.

A Regressão Linear Ordinária (Ordinary Least Squares - OLS) é a técnica mais básica de regressão linear. O objetivo do OLS é encontrar os coeficientes β que minimizam a soma dos quadrados dos resíduos (diferenças entre os valores observados e os valores previstos). A equação (68) apresenta a relação entre os dados de entrada os coeficientes utilizados na regressão.

$$Y_{OLS} = X\beta + \epsilon \quad (68)$$

onde Y_{OLS} é o vetor de respostas (variável dependente), X é a matriz de preditores (variáveis independentes), β é o vetor de coeficientes de regressão, ϵ é o vetor de erros (resíduos).

Podemos obter a função custo a partir da equação (69):

$$J(\beta) = (Y - X\beta)^T(Y - X\beta) \quad (69)$$

Os coeficientes β são estimados minimizando a função de custo, conforme apresenta a equação (70):

$$\hat{\beta} = (X^T X)^{-1} X^T Y \quad (70)$$

A Regressão Ridge é uma técnica de regularização que modifica a regressão OLS para incluir um termo de penalidade ou ajuste. Essa técnica é utilizada para lidar com problemas de colinearidade entre variáveis independentes e para evitar o sobreajuste (overfitting). A formulação para a Regressão Ridge é semelhante ao OLS, mas com um parâmetro de suavização conforme apresentam as equações (71) e (72) [23].

$$Y_{Ridge} = X\beta + \epsilon \quad (71)$$

$$J(\beta) = (Y - X\beta)^T(Y - X\beta) + \lambda\|\beta\|^2 \quad (72)$$

onde:

λ é o parâmetro de regularização que controla a suavização.

Os coeficientes β são estimados minimizando a função de custo com a suavização da regularização conforme equação (73):

$$\hat{\beta} = (X^T X + \lambda I)^{-1} X^T Y \quad (73)$$

onde I é a matriz identidade.

A técnica OLS apresenta excelente desempenho na estimativa de parâmetros sendo largamente utilizada como técnica de regressão. Entretanto, não apresenta bom desempenho frente a variáveis com alta colinearidade ou grande quantidade de variáveis independentes. Deste modo, a Regressão Ridge apresenta-se como a otimização da técnica de regressão por quadrados mínimos [23].

2.5.4. Regressão Kernel

A regressão kernel não-paramétrica é uma técnica estatística que permite modelar relações não-lineares entre variáveis sem assumir uma forma funcional específica para a função de regressão. Esta abordagem é particularmente útil quando a relação entre as variáveis é complexa ou desconhecida [17].

O estimador de Nadaraya-Watson, um dos métodos mais utilizados em regressão kernel, pode ser expresso como uma média ponderada local, onde os pesos são determinados por uma função kernel que mede a "similaridade" entre os pontos de dados conforme equação (74) [17].

$$m(x) = \frac{\sum_{i=1}^n K_h(x-x_i)y_i}{\sum_{i=1}^n K_h(x-x_i)} \quad (74)$$

onde:

$K_h(\cdot)$ é a função kernel com parâmetro de suavização h

x_i são os pontos de dados de entrada

y_i são os valores observados

h é o parâmetro de largura de banda que controla o grau de suavização

A função kernel gaussiana, comumente utilizada neste tipo de regressão, é definida pela equação (75):

$$K_h(u) = \frac{1}{h\sqrt{2\pi}} \exp\left(-\frac{u^2}{2h^2}\right) \quad (75)$$

O processo de regressão kernel envolve o cálculo de uma matriz de similaridade entre os pontos de dados. Esta matriz é construída utilizando a função kernel gaussiana para

determinar os pesos de cada observação. A similaridade entre dois pontos pode ser calculada pela equação (76).

$$w_i = \exp\left(-\frac{|x-x_i|^2}{2h^2}\right) \quad (76)$$

O parâmetro h (largura de banda) é crucial para o desempenho do modelo:

Valores pequenos de h resultam em estimativas mais locais e potencialmente mais ruidosas. Por sua vez, valores grandes de h produzem estimativas mais suaves, mas podem perder características importantes dos dados.

A normalização dos pesos é uma etapa fundamental do processo, garantindo que a soma dos pesos para cada ponto de predição seja igual a 1. Isto assegura que a estimativa final seja uma média ponderada válida dos valores observados [17]. A implementação computacional detalhada deste método pode ser encontrada no Apêndice.

2.5.5. Regressão por Quadrados Mínimos Parciais (PLS)

A técnica de Partial Least Squares (PLS), ou Mínimos Quadrados Parciais, é uma técnica de modelagem estatística usada para encontrar relações entre dois conjuntos de variáveis, tipicamente denominados X (variáveis preditoras) e Y (variáveis resposta). PLS é particularmente útil quando há um grande número de variáveis preditoras que são altamente correlacionadas e quando o número de amostras é menor do que o número de preditores [23].

O objetivo da PLS é encontrar componentes latentes que capturam a variância nos conjuntos de dados X e Y e maximizar a correlação entre essas componentes. A técnica de PLS envolve decompor X e Y por meio das equações (77) e (78).

$$X = TP^T + E \quad (77)$$

$$Y = UQ^T + F \quad (78)$$

onde: T e U são matrizes de scores (componentes latentes) de X e Y , respectivamente, P e Q são matrizes de carregamentos (loadings), E e F são matrizes de resíduos (erros).

O algoritmo de PLS é considerado um algoritmo iterativo, envolve os seguintes passos principais:

Peso dos preditores: Calcular os pesos dos preditores W maximizando a covariância entre X e Y utilizando a equação (79):

$$w = \arg \max_w \text{cov}(X_w, Y)^2 \quad (79)$$

Componentes de X: Calcular os componentes (scores) T utilizando a equação (80):

$$t = Xw \quad (80)$$

Peso das respostas: Calcular os pesos das respostas q utilizando a equação (81):

$$q = \frac{y^T t}{t^T t} \quad (81)$$

Componentes de Y: Calcular os componentes (scores) U utilizando a equação (82):

$$u = Yq \quad (82)$$

Recarregar: Recalcular os pesos dos preditores p e ajustar os scores utilizando a equação (83):

$$p = \frac{X^T t}{t^T t} \quad (83)$$

Deflacionar: Subtrair a parte explicada dos dados X e Y utilizando as equações (84) e (85):

$$X = X - tp^T \quad (84)$$

$$Y = Y - tq^T \quad (85)$$

Repetir: Repetir os passos acima até que o número desejado de componentes latentes seja extraído.

Depois de ajustar o modelo, as novas observações X_{new} podem ser projetadas nos componentes latentes para prever Y_{new} por meio da equação (86).

$$\widehat{Y}_{new} = X_{new}W(P^T W)^{-1}Q^T \quad (86)$$

onde W , P e Q são obtidos do modelo ajustado.

3. APLICAÇÃO DA TÉCNICA DE MONTE CARLO E ANÁLISE DE SENSIBILIDADE

3.1. DOUBLE LCC – VALORES NOMINAIS

Conforme a literatura apresentada em [13], foram obtidos os valores de projeto para um circuito de transferência de energia sem fio com a topologia Double LCC com valores nominais conforme apresentados na Tabela 4.

Tabela 4 - Valores Nominiais Double LCC

Potência transferida (P)	100 W
Frequência de Chaveamento (f_s)	120 kHz
Tensão de entrada (U_d)	36 V
Fator de acoplamento (k)	0,25
Bobina transmissora (L_1)	360 μ H
Bobina receptora (L_2)	360 μ H
Indutor de filtro (L_{f1})	35,41 μ H
Indutor de filtro (L_{f2})	35,41 μ H
Capacitor de filtro (C_{f1})	49,67 nF
Capacitor de filtro (C_{f2})	49,67 nF
Capacitor de ressonância (C_1)	5,42 nF
Capacitor de ressonância (C_2)	5,42 nF

Fonte: Autor

Foram consideradas também resistências para as bobinas principais e para os indutores de filtro. Para estes componentes utilizou-se como valor nominal as resistências estimadas em [14], sendo 0,5415 Ω (bobinas) e 0,0031 Ω (indutâncias de filtro). Para os valores nominais,

foram calculados utilizando a metodologia apresentada em [14] as correntes e tensões para cada componente no circuito. Também foram calculadas as potências referentes a entrada e saída do circuito e o respectivo rendimento esperado.

Os valores nominais dos esforços de tensão e corrente em cada elemento são calculados e apresentados na Tabela 5.

Tabela 5 – Esforços de corrente e tensão em condições nominais para Double LCC

Elemento	Tensão (V)	Corrente (A)
Resistência de carga (R_E)	32, 1451	3.0600
Bobina transmissora (L_1)	339.5512	1.2136
Bobina receptora (L_2)	336.9472	1.2043
Indutor de filtro (L_{f1})	0.0096	3.0855
Indutor de filtro (L_{f2})	0.0095	3.0600
Capacitor de filtro (C_{f1})	88.5231	3.3155
Capacitor de filtro (C_{f2})	87.7990	3.2884
Capacitor de ressonância (C_1)	297.0052	1.2136
Capacitor de ressonância (C_2)	294.7386	1.2043

Fonte: Autor

O espaço amostral foi obtido por meio do software MATLAB. Para a análise de sensibilidade, optou-se pelo uso da técnica de Monte Carlo, que consiste na geração de nuvem aleatória de dados obedecendo uma distribuição estatística que melhor se adequa ao problema a ser analisado. Deste modo, foram gerados 100.000 valores aleatórios para cada componente. Considerando a característica de fabricação dos elementos utilizados, as variações paramétricas foram geradas de forma aleatória respeitando uma distribuição normal com desvio padrão conforme tolerâncias comumente trabalhadas na literatura para cada componente. As tolerâncias são apresentadas na Tabela 6. Para obter aleatoriedade entre os dados, foram selecionados de forma randômica 1.000 pontos de operação.

Tabela 6 - Tolerâncias aplicadas por componente para Double LCC

Bobina transmissora (L_1)	360 μ H (20%)
Bobina receptora (L_2)	360 μ H (20%)
Indutor de filtro (L_{f1})	35,41 μ H (20%)
Indutor de filtro (L_{f2})	35,41 μ H (20%)
Capacitor de filtro (C_{f1})	49,67 nF (10%)
Capacitor de filtro (C_{f2})	49,67 nF (10%)
Capacitor de ressonância (C_1)	5,42 nF (10%)
Capacitor de ressonância (C_2)	5,42 nF (10%)

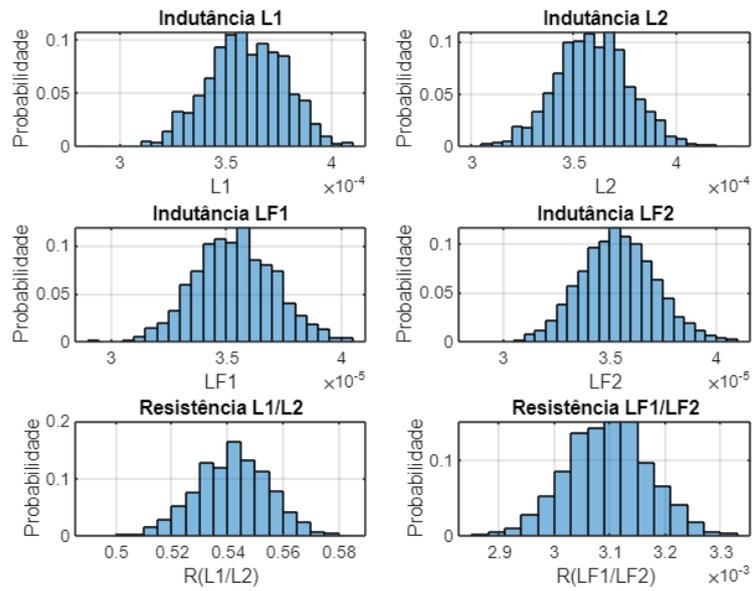
Fonte: Autor

Em torno das resistências estimadas para as bobinas de filtro e de indutores, foram considerados valores aleatórios dentro da distribuição normal com desvio padrão relativo de 10% ao valor nominal. Foram variados também os parâmetros de acoplamento em 50% e a resistência equivalente de carga em 20%.

3.2. DOUBLE LCC – ESPAÇO AMOSTRAL OBTIDO

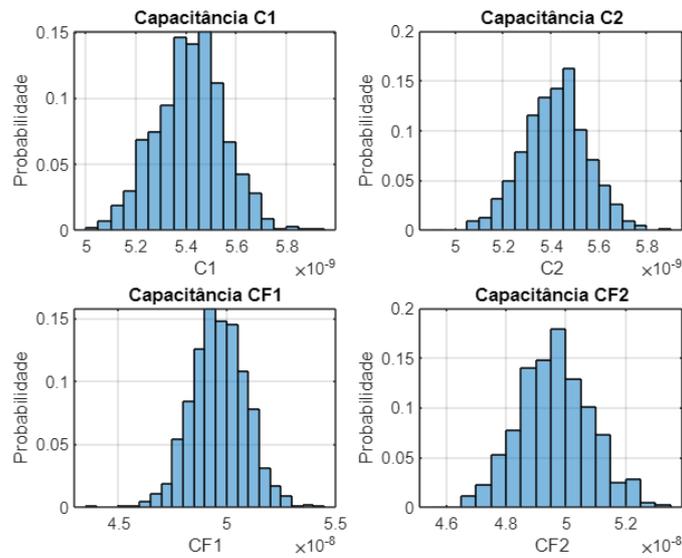
A Figura 8 e Figura 9 apresentam os histogramas para o espaço amostral de valores gerados em torno do valor nominal de cada componente.

Figura 8 - Histogramas para o espaço amostral de indutâncias geradas (H).



Fonte: Autor

Figura 9 - Histogramas para o espaço amostral de capacitâncias geradas (F).

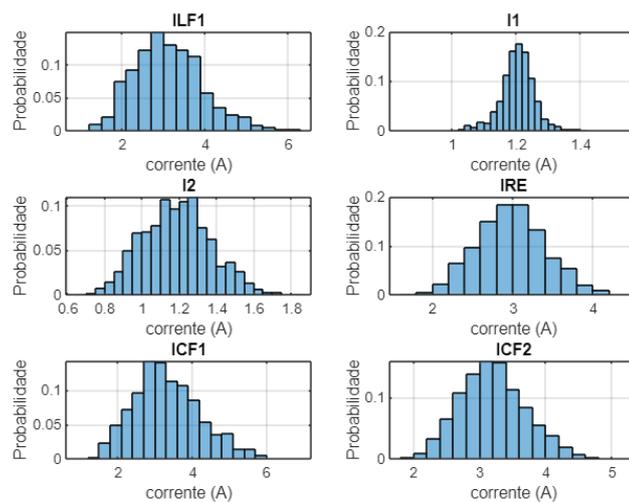


Fonte: Autor

Pode-se notar que os histogramas referentes aos componentes apresentam formas próximas a distribuição normal aplicada, que melhor modela a aleatoriedade dos componentes dentro de uma tolerância nominal.

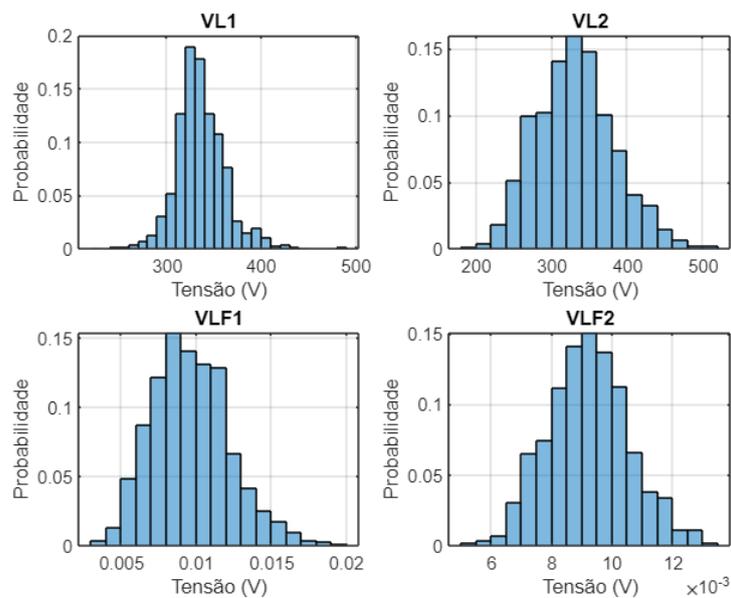
Utilizando do espaço amostral obtido, foram calculados os esforços de corrente e tensão sobre cada componente, bem como a potência de entrada e saída para a topologia para cada conjunto de dados do espaço amostral. Nas Figuras 10 e 12 apresentam-se os histogramas referentes aos resultados obtidos para correntes e tensões em cada componente.

Figura 10 – Histogramas das correntes calculadas



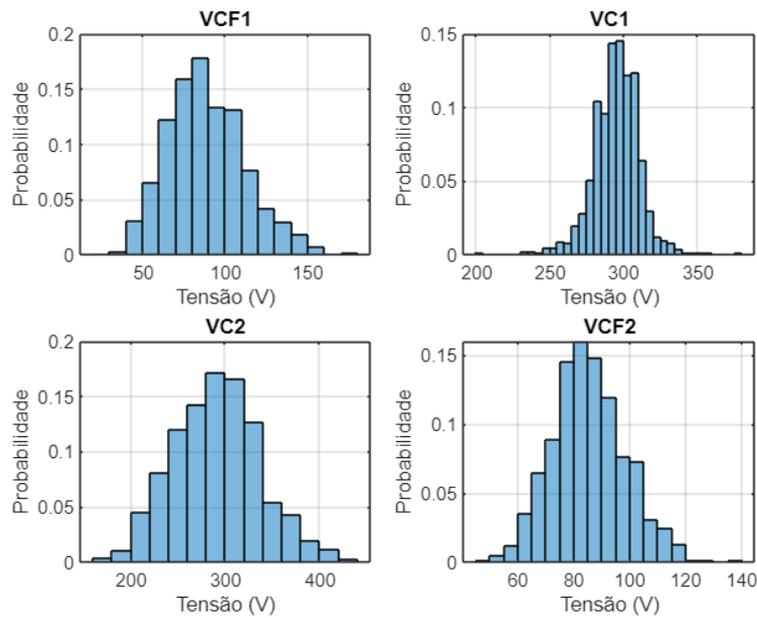
Fonte: Autor

Figura 11 – Histogramas das tensões calculadas sobre as indutâncias.



Fonte: Autor

Figura 12 – Histogramas das tensões calculadas sobre as capacitâncias.

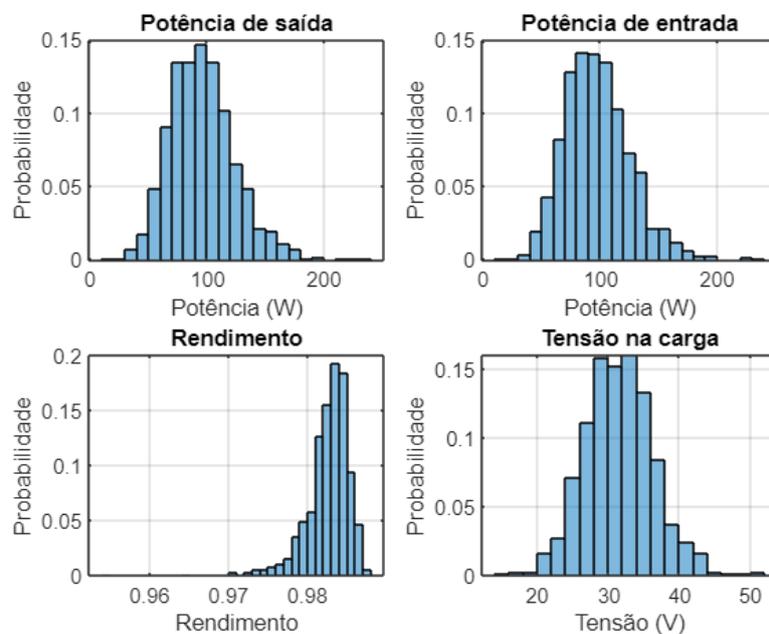


Fonte: Autor

Os esforços calculados apresentam um desvio natural em torno dos valores nominais das correntes e tensões calculadas, demonstrando o efeito do deslocamento do ponto de ressonância. Destaca-se que a variação obtida a depender das combinações obtidas, podem resultar em esforços de tensão e corrente dobrados sobre os componentes.

Também foram obtidas as potências de entrada e saída do circuito, de modo que se obteve também o rendimento da transferência de potência. Na Figura 13 observa-se os respectivos histogramas para potência de entrada, potência de saída, tensão na carga e rendimento.

Figura 13 - Histogramas das potências obtidas e o rendimento global da transferência.



Fonte: Autor.

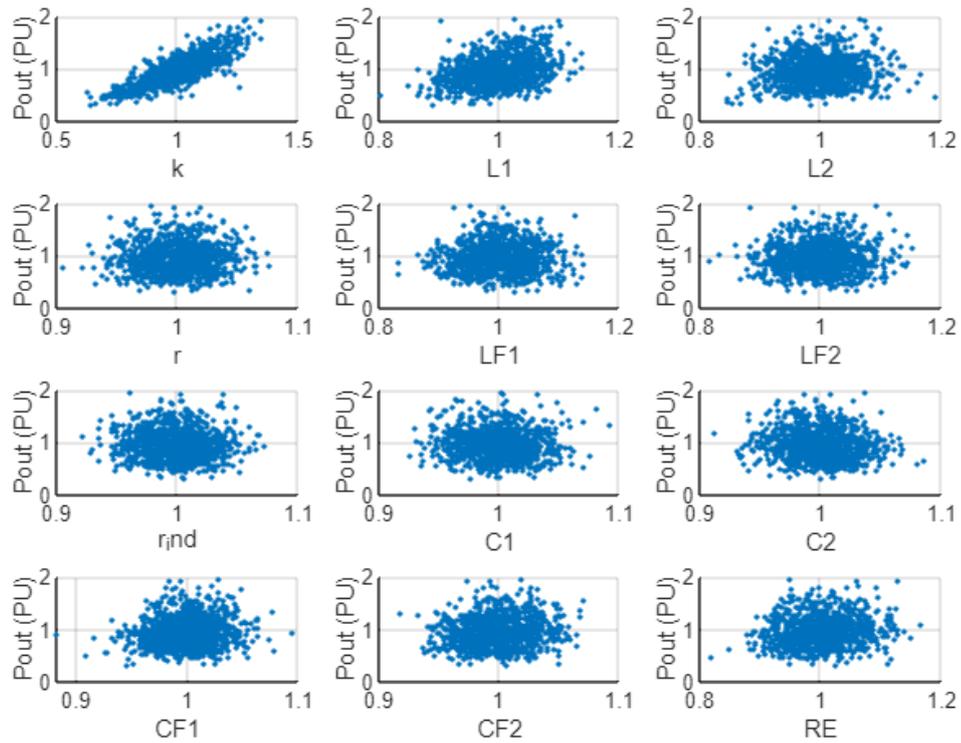
Os histogramas apresentam seu pico em torno de 100W, entretanto a depender da seleção dos componentes, os valores de potência transferida e potência de entrada podem dobrar ou reduzir pela metade. O rendimento por sua vez, apresenta seu pico em torno de 98,3%, podendo chegar a 96,5% a depender da combinação de componentes selecionados.

3.3. DOUBLE LCC – GRÁFICOS DE DISPERSÃO

A análise de dispersões foi aplicada visando obter os parâmetros de maior influência sobre as variáveis de maior interesse. As variáveis analisadas são a corrente de entrada, corrente de saída, tensão na carga e potência de saída. Visando assim, obter um sistema estável com relação as correntes de entrada e eficiente com relação a potência transferida em casos de variações paramétricas no momento da construção ou alterações dos parâmetros nominais

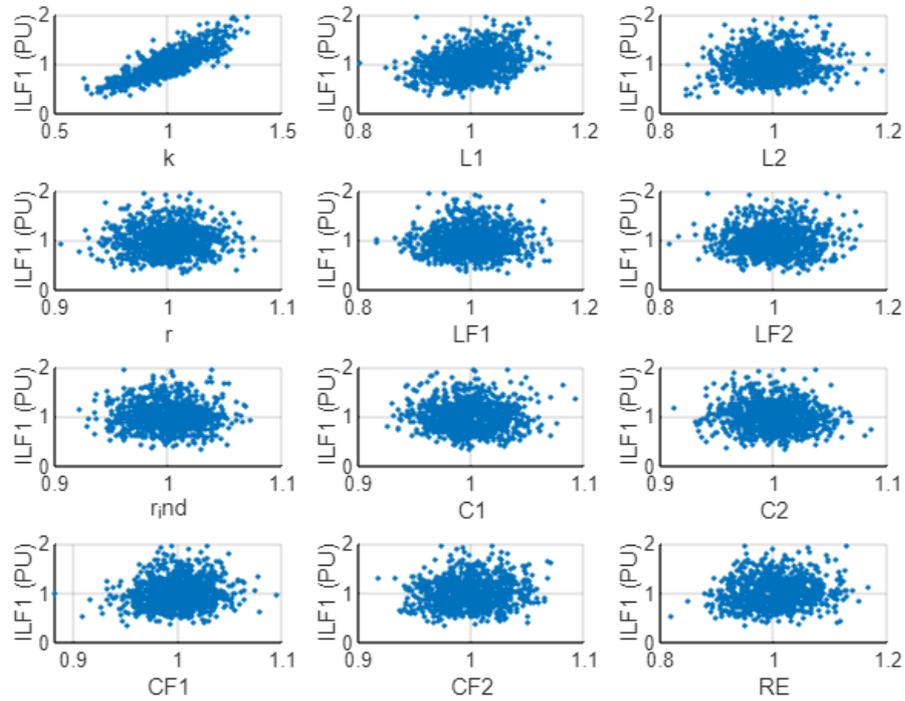
durante a operação do sistema. Nas Figuras 14 e 17 apresentam-se as distribuições de pontos conforme as variações de cada componente em análise.

Figura 14 - Análise de dispersões (Pout)



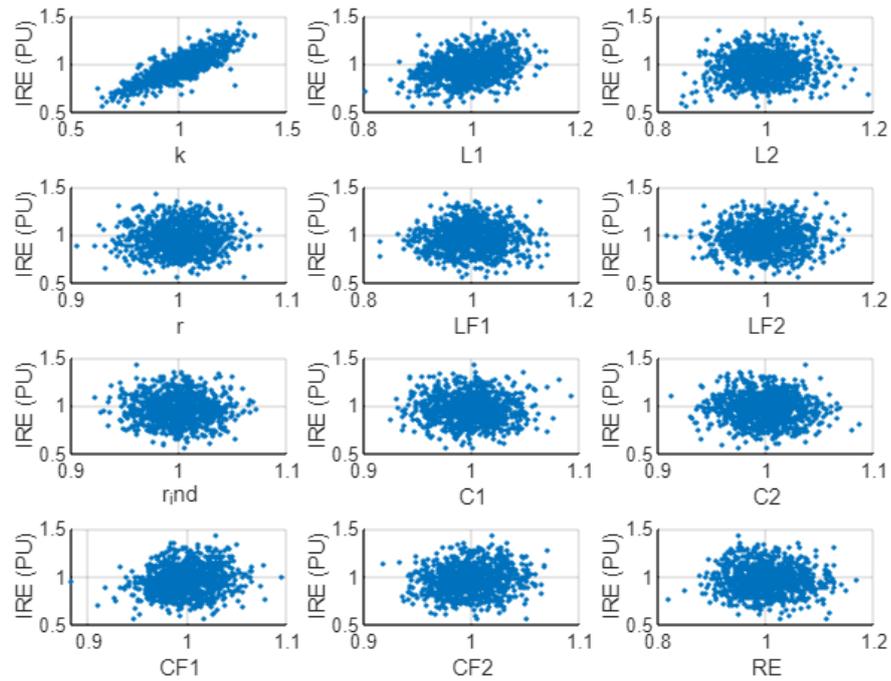
Fonte: Autor

Figura 15 – Análise de dispersões (ILF1).



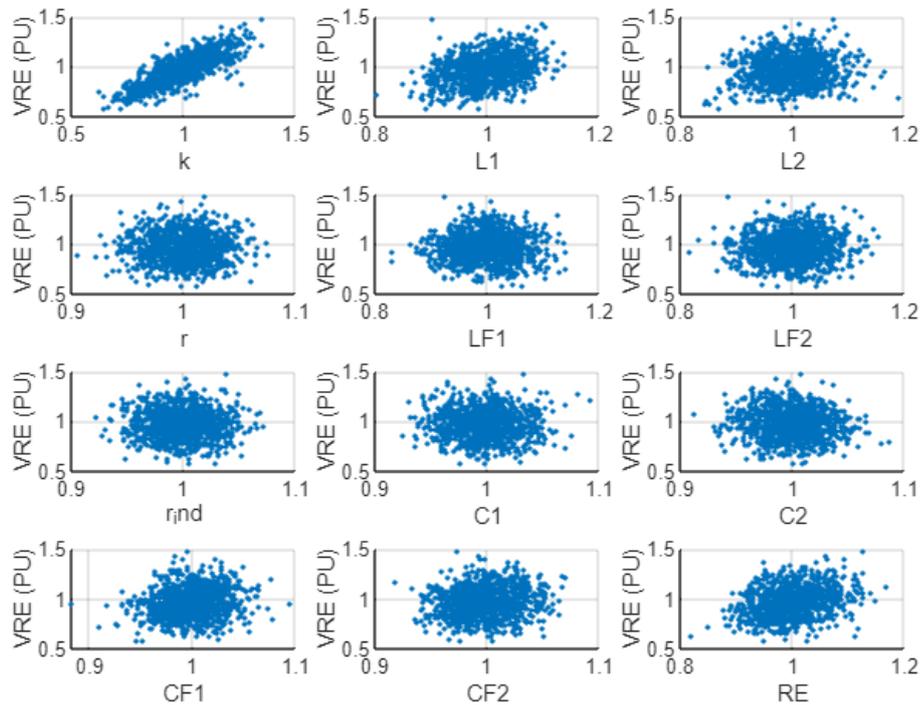
Fonte: Autor

Figura 16 - Análise de dispersões (IRE)



Fonte: Autor

Figura 17 - Análise de dispersões (VRE)

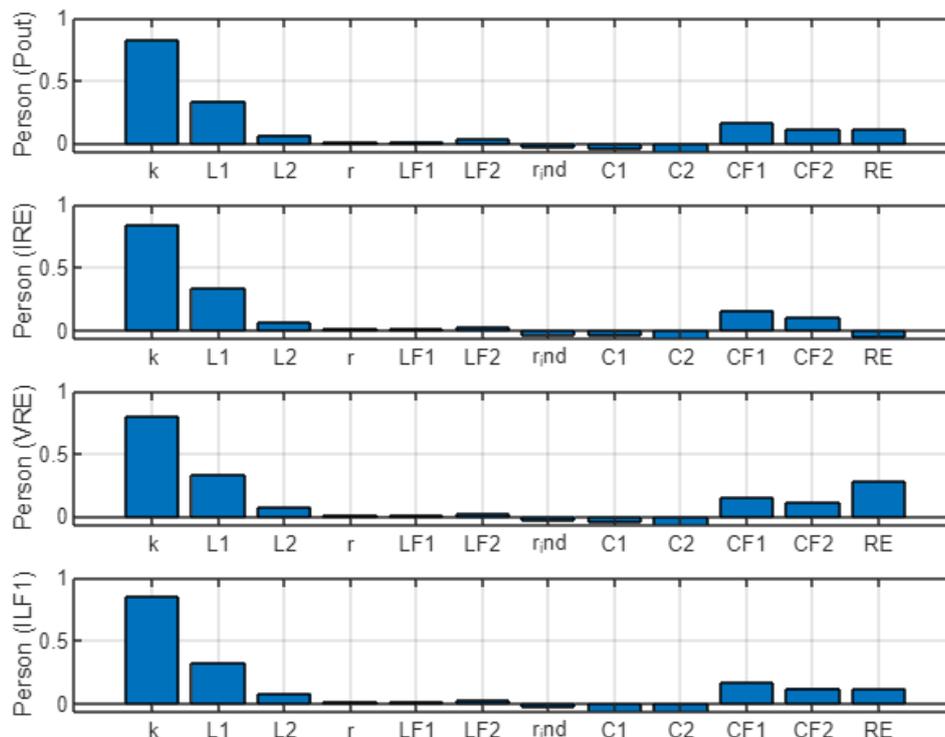


Fonte: Autor

Dadas as dispersões apresentadas, destaca-se que o fator de acoplamento possui para todas as variáveis em análise um comportamento semelhante ao linear em comparação as demais variáveis. Destacando, portanto, uma correlação linear positiva para as quatro variáveis em análise.

Na Figura 18 são apresentados os coeficientes de Pearson obtidos analisando a covariância entre as variáveis. Este indicativo apresenta os elementos de maior influência ou correlação para as variáveis de análise do circuito.

Figura 18 - Coeficientes de Pearson Double LCC



Fonte: Autor

Podemos observar que conforme apontam os coeficientes de Pearson e os gráficos de dispersão, o principal fato de influência no sistema vem a ser o acoplamento magnético entre as bobinas. Em sequência, o valor da bobina transmissora influencia significativamente para todas as variáveis analisadas. Entre os elementos de compensação, os capacitores de filtro C_{F1} e C_{F2} apresentam maior influência.

3.4. LCC-S – VALORES NOMINAIS

Conforme a literatura apresentada em [14], foram obtidos os valores de projeto para um circuito de transferência de energia sem fio com a topologia LCC-S com valores nominais conforme apresentados na Tabela 7.

Tabela 7 - Valores nominais para LCC-S

Potência transferida (P)	100 W
Frequência de Chaveamento (f_s)	120 kHz
Tensão de entrada (U_d)	36 V
Fator de acoplamento (k)	0,25
Indutância da bobina transmissora (L_P)	360 μ H
Indutância da bobina receptora (L_S)	360 μ H
Indutância de filtro (L_{P1})	38,70 μ H
Capacitância primária de filtro (C_{P1})	64,99 nF
Capacitância de ressonância do primário (C_{P2})	6,51 nF
Capacitância de ressonância do secundário (C_{S1})	6,51 nF

Fonte: Autor

Foram consideradas também resistências para as bobinas principais e para os indutores de filtro. Para estes componentes utilizou-se como valor nominal as resistências estimadas em [10], sendo 0,5415 Ω (bobinas) e 0,0031 Ω (indutâncias de filtro). Para os valores nominais, foram calculados utilizando a metodologia apresentada em [14] as correntes e tensões para cada componente no circuito. Os valores nominais dos esforços de tensão e corrente são calculados para cada elemento no circuito são apresentados na Tabela 8.

Tabela 8 - Esforços de tensão e corrente em condições nominais para Double LCC

Elemento	Tensão (V)	Corrente (A)
Resistência de carga (R_E)	89,1466	1,0998
Indutância da bobina transmissora (L_P)	423,1955	1,7200
Indutância da bobina receptora (L_S)	240,9873	1,0998
Indutância de filtro (L_{P1})	96,4571	3,3055
Capacitância primária de filtro (C_{P1})	90,3408	4,4272
Capacitância primária de filtro (C_{P2})	350,1582	1,7200
Capacitância secundária de ressonância (C_{S1})	223,8923	1,0998

Fonte: Autor

A metodologia utilizada para criação do espaço amostral para topologia LCC-S é análoga a utilizada para Double LCC em item anterior. Deste modo, a Tabela 9 apresenta as tolerâncias consideradas.

Tabela 9 - Tolerâncias aplicadas por componente para LCC-S

Bobina transmissora (L_P)	360 μ H (20%)
Bobina receptora (L_S)	360 μ H (20%)
Indutor de filtro (L_{P1})	38,70 μ H (20%)
Capacitor de filtro (C_{P1})	64,99 nF (10%)
Capacitor de filtro (C_{P2})	6,51 nF (10%)
Capacitor de ressonância (C_{S1})	6,51 nF (10%)

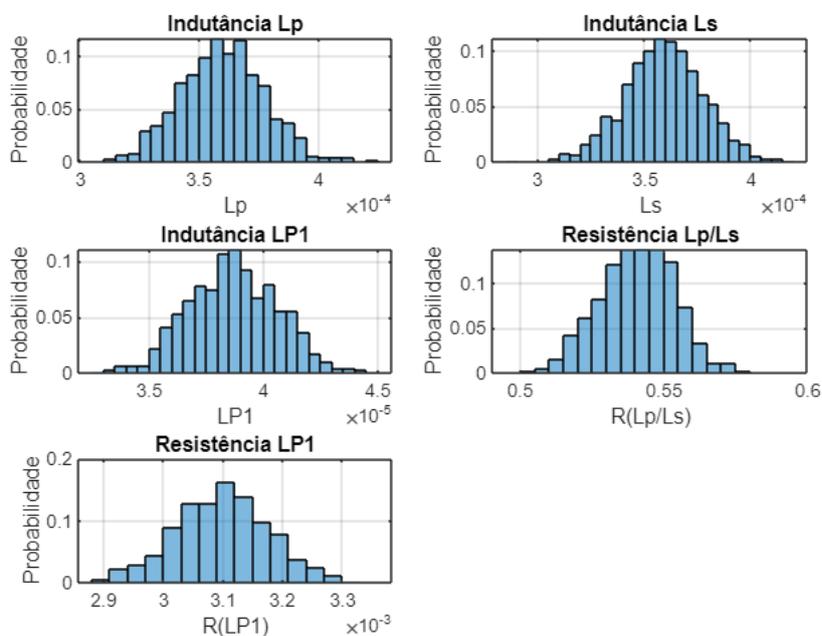
Fonte: Autor

Em torno das resistências estimadas para as bobinas de filtro e de indutores, foram considerados valores aleatórios dentro da distribuição normal com desvio padrão relativo de 10% ao valor nominal. Foram variados também os parâmetros de acoplamento em 50% e a resistência equivalente de carga em 20%.

3.5. LCC-S – ESPAÇO AMOSTRAL OBTIDO

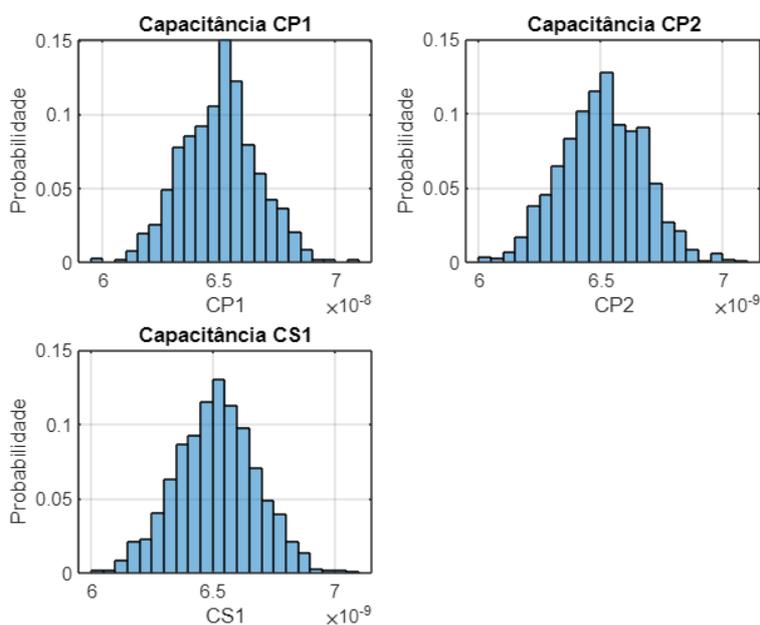
Nas Figuras 19 e 20 apresentam-se os histogramas para o espaço amostral de valores gerados em torno do valor nominal de cada componente.

Figura 19 - Histogramas para o espaço amostral de indutâncias geradas.



Fonte: Autor

Figura 20 - Histogramas para o espaço amostral de capacitâncias geradas.

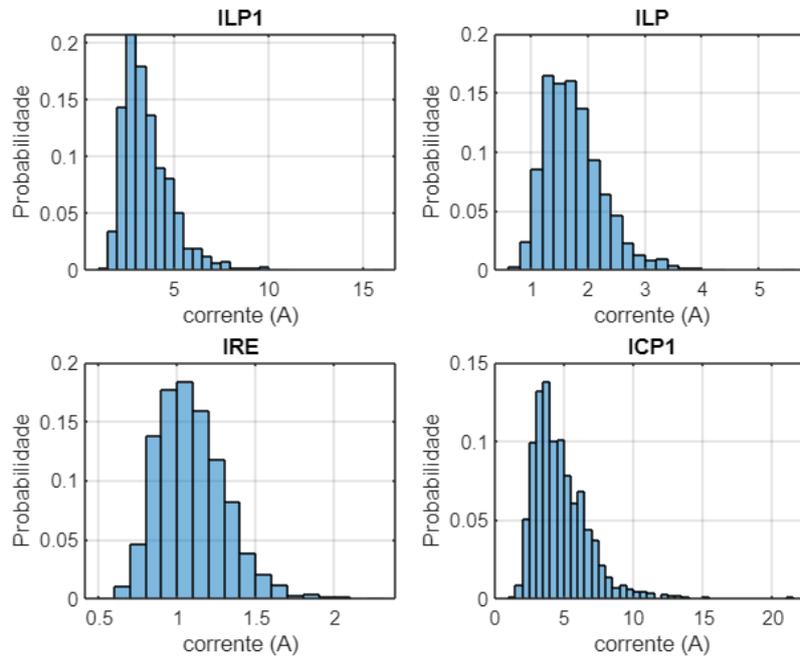


Fonte: Autor

As formas observadas seguem conforme a distribuição normal utilizada de forma análoga ao espaço amostral da seção anterior. Utilizando do espaço amostral obtido, foram calculados os esforços de corrente e tensão sobre cada componente, bem como a potência de entrada e saída para da topologia para cada conjunto de dados do espaço amostral. Nas Figuras

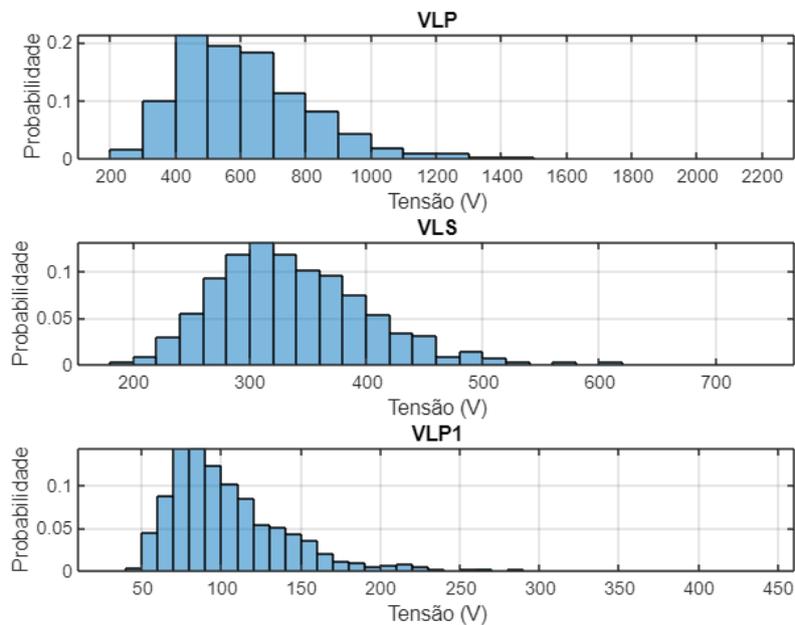
21 e 23 apresentam-se os histogramas referentes aos resultados obtidos para correntes e tensões em cada componente.

Figura 21 - Histogramas das correntes calculadas.



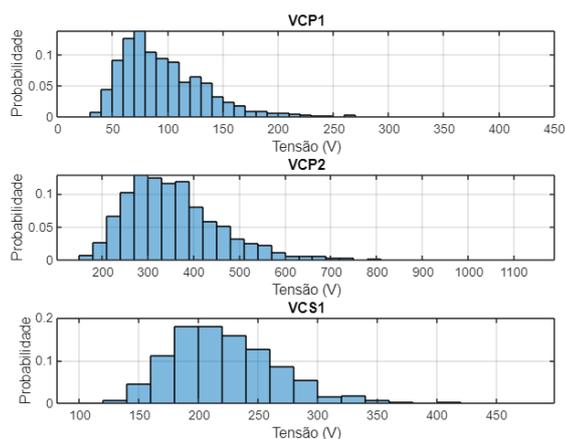
Fonte: Autor

Figura 22 - Histogramas das tensões calculadas sobre as indutâncias.



Fonte: Autor

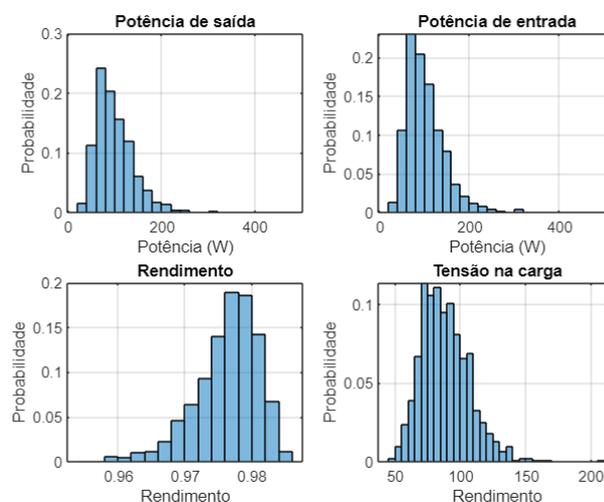
Figura 23 - Histogramas das tensões calculadas sobre as capacitâncias



Fonte: Autor

Destaca-se nas distribuições dos esforços da LCC-S, uma forma com seu pico em torno dos valores nominais. Entretanto, a distribuição dos resultados calculados apresenta possibilidades de variação maior que a Double LCC, demonstrando que para esforços de tensão e corrente em componentes internos, a topologia pode ser mais sensível a variações paramétricas. Também foram obtidas as potências de entrada e saída do circuito, de modo que se obteve também o rendimento da transferência de potência. A Figura 24 apresenta os respectivos histogramas para potência de entrada, potência de saída, tensão na carga e rendimento.

Figura 24 - Histogramas das potências obtidas e o rendimento global da transferência.



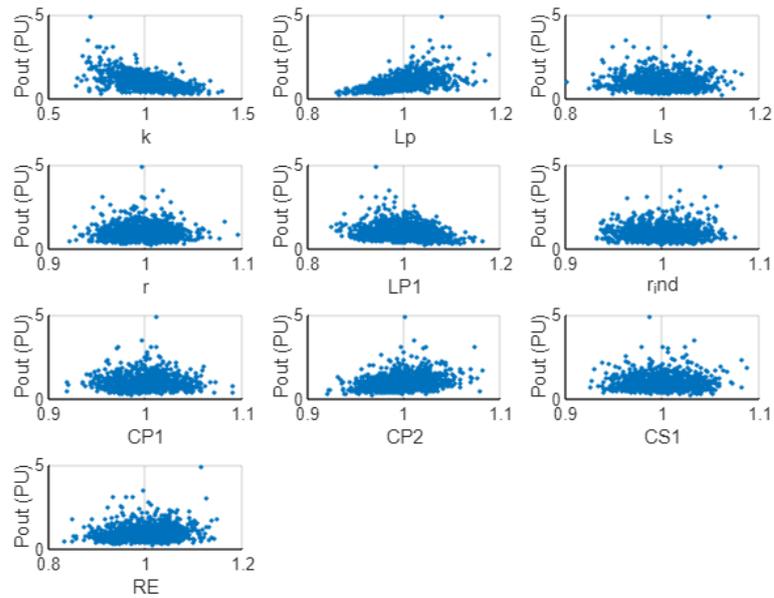
Fonte: Autor.

Os histogramas apresentados demonstram os efeitos da variação paramétrica sobre a potência transferida, rendimento e tensão na carga. A alteração do ponto de ressonância da topologia LCC-S apresenta maior sensibilidade a outliers, visto que, a depender da combinação dos parâmetros, a topologia pode resultar em aumento significativo sobre parâmetros como a potência transferida e potência de entrada. A seção de discussões apresenta o ajuste por meio de distribuição estatística para os principais parâmetros, visando estimar a variabilidade do projeto por meio de intervalos de confiança.

3.6. LCC-S – GRÁFICOS DE DISPERSÃO

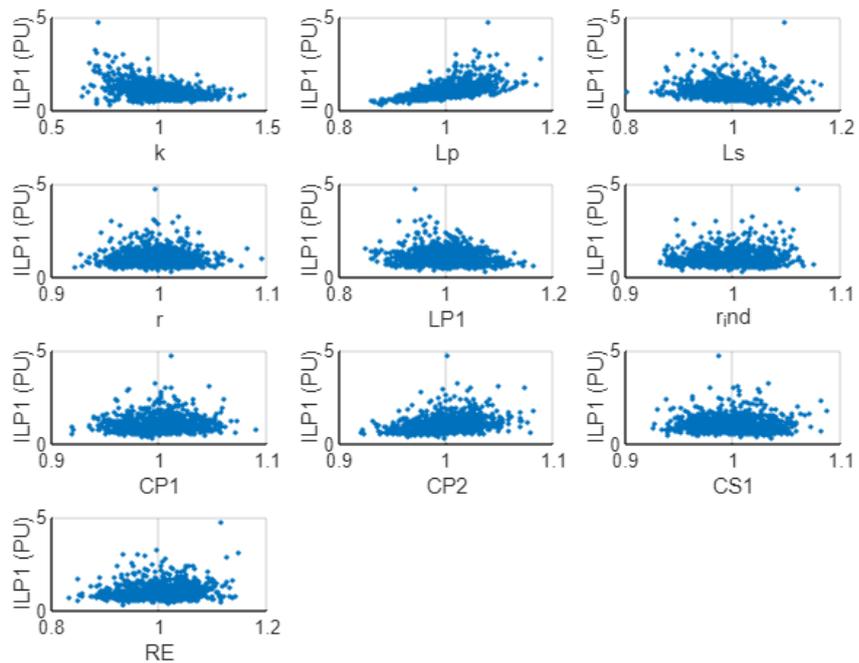
A análise de dispersões foi aplicada visando obter os parâmetros de maior influência sobre as variáveis de maior interesse. As variáveis analisadas são a corrente de entrada, corrente de saída, tensão na carga e potência de saída. Visando assim, obter um sistema estável com relação as correntes de entrada e eficiente com relação a potência transferida em casos de variações paramétricas no momento da construção ou alterações dos parâmetros nominais durante a operação do sistema. Nas Figura 25 e Figura 28 apresentam-se as distribuições de pontos conforme as variações em cada componente em análise.

Figura 25 - Análise de dispersões (Pout)



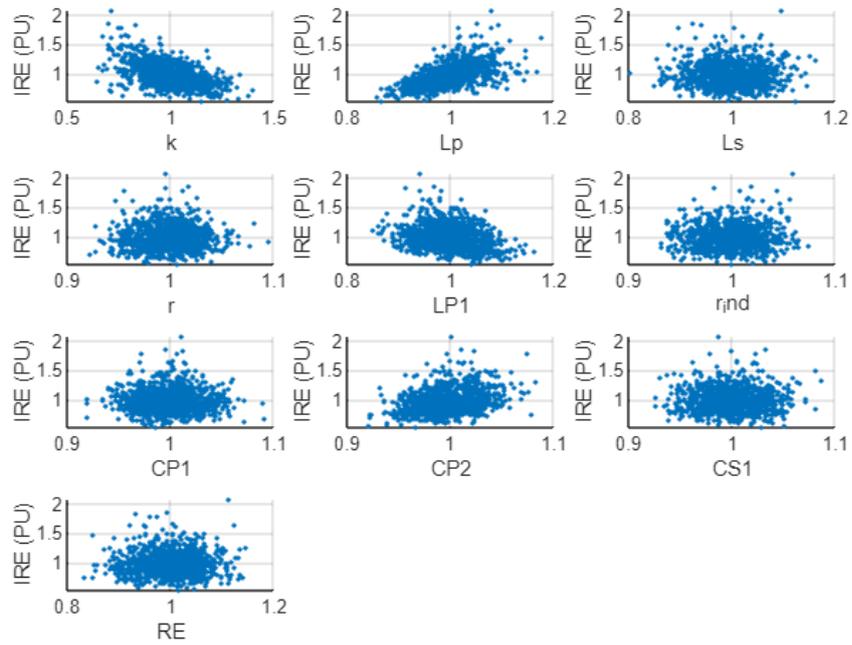
Fonte: Autor

Figura 26 - Análise de dispersões (ILP1).



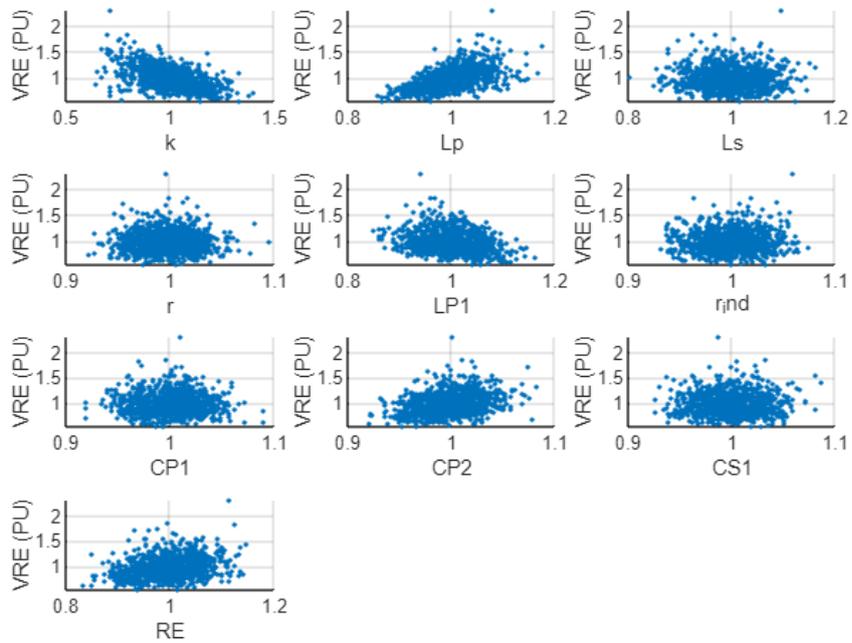
Fonte: Autor

Figura 27 - Análise de dispersões (IRE).



Fonte: Autor

Figura 28 - Análise de dispersões (VRE).

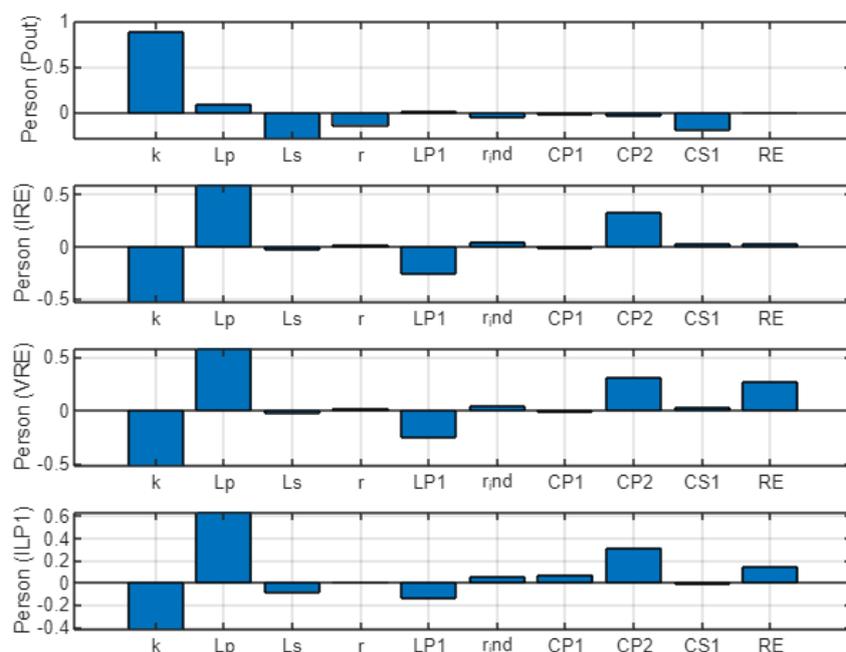


Fonte: Autor

As variáveis que mais apresentam comportamento linear são o fator de acoplamento e a indutância primária, demonstrando assim, maior correção linear entre as variáveis de interesse.

A Figura 29 apresenta os coeficientes de Pearson obtidos analisando a covariância entre as variáveis. Este indicativo apresenta os elementos de maior dependência ou correlação para as variáveis de análise do circuito.

Figura 29 - Coeficientes de Pearson LCC-S



Fonte: Autor

Podemos observar que conforme apontam os coeficientes de Pearson e os gráficos de dispersão, o principal fato de influência no sistema vem a ser o acoplamento magnético entre as bobinas, seguido da bobina primária para a potência transferida. Entretanto, para as variáveis relacionadas a corrente e tensão na carga, bem como a corrente de entrada, a indutância da bobina primária apresenta maior influência, seguida do fator de acoplamento. Destaca-se também a forte correlação da capacitância primária C_{P2} . Apesar de não apresentar forte correlação com a potência transferida, apresenta forte influência nos esforços de tensão e corrente.

Na próxima seção, abordar-se-á técnicas de estimativa de parâmetros para o circuito secundário em ambas as topologias. A operação normal de um sistema de WPT pode apresentar as variações paramétricas conforme simuladas pelos espaços amostrais apresentados. Portanto, utilizou-se de modelos estatísticos, técnicas de regressão e redes neurais artificiais para estimar parâmetros localizados no circuito secundário de forma propor redução de custo e complexidade para implementação de controles robustos para ambas as topologias.

4. MODELOS DE REGRESSÃO PARA ESTIMATIVA DO SECUNDÁRIO

Para a estimativa dos parâmetros do secundário, foi proposto inicialmente a estimativa do fator de acoplamento utilizando uma rede neural artificial, de modo obter valores capazes de alimentar o modelo de estimativa dos demais parâmetros do secundário, possibilitando assim a implementação para estimativa simultânea dos dados. Os dados obtidos pelo espaço amostral gerado foram divididos entre variáveis referentes ao circuito primário e variáveis referentes ao circuito secundário. A Tabela 10 demonstra as etapas utilizadas pelo algoritmo implementado para a estimativa de parâmetros.

Tabela 10 – Algoritmo utilizado na estimação dos parâmetros

<i>Etapa</i>	<i>Dados de Entrada</i>	<i>Processamento</i>	<i>Variável Estimada</i>	<i>Implementação</i>
1	<i>Dados brutos (ILF1, II, VCF1, VC1, k, Pout, IRE)</i>	<i>Padronização e centralização</i>	-	<i>dados_primario_padronizado, dados_secundario_padronizado</i>
2	<i>Dados padronizados</i>	<i>Divisão treino/teste (50%)</i>	-	<i>X_treino, X_teste, Y_treino, Y_teste</i>
3	<i>Dados do primário (treino)</i>	<i>Treinamento RBF</i>	<i>k</i>	<i>net_rbf_k = newrb()</i>
4	<i>Dados do primário (teste)</i>	<i>Estimativa de k</i>	<i>k estimado</i>	<i>k_est_RBF = net_rbf_k()</i>
5	<i>Dados primário + k estimado</i>	<i>Validação cruzada PCR</i>	<i>Pout, IRE</i>	<i>Otimização número componentes</i>
6	<i>Dados primário + k estimado</i>	<i>Validação cruzada Kernel</i>	<i>Pout, IRE</i>	<i>Otimização largura de banda</i>
7	<i>Dados primário + k estimado</i>	<i>Validação cruzada Ridge</i>	<i>Pout, IRE</i>	<i>Otimização fator alpha</i>
8	<i>Dados primário + k estimado</i>	<i>Validação cruzada PLS</i>	<i>Pout, IRE</i>	<i>Otimização número componentes</i>
9	<i>Dados primário + k estimado</i>	<i>Treinamento RBF final</i>	<i>Pout, IRE</i>	<i>net_rbf_1 = newrb()</i>
10	<i>Resultados dos modelos</i>	<i>Análise de erros</i>	<i>MSE, erro relativo</i>	<i>immse(), boxplot()</i>

Fonte: Autor.

4.1. PADRONIZAÇÃO DOS DADOS

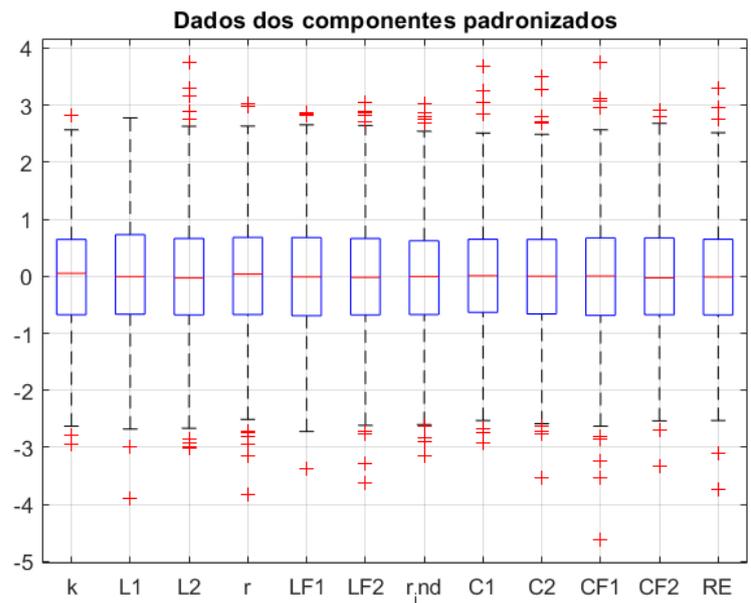
Inicialmente, para aplicação de modelos de regressão, optamos em trabalhar com dados padronizados. Portanto, a média dos dados foi centrada em zero, e o desvio padrão unitário. A padronização dos dados é essencial para garantir que todas as variáveis contribuam de forma equitativa para o modelo, evitando que variáveis com maiores magnitudes dominem o processo de ajuste [17]. Além disso, técnicas como Regressão por Componentes Principais (PCR), Regressão Ridge e Mínimos Quadrados Parciais (PLS) são particularmente sensíveis às escalas das variáveis, e a padronização melhora significativamente a performance e interpretabilidade desses modelos [23]. Os dados de entrada foram padronizados conforme a equação (87).

$$X_{padronizado} = \frac{x - \bar{x}}{\sigma} \quad (87)$$

onde X são os dados selecionados, \bar{X} são a média das variáveis, e σ é o desvio padrão.

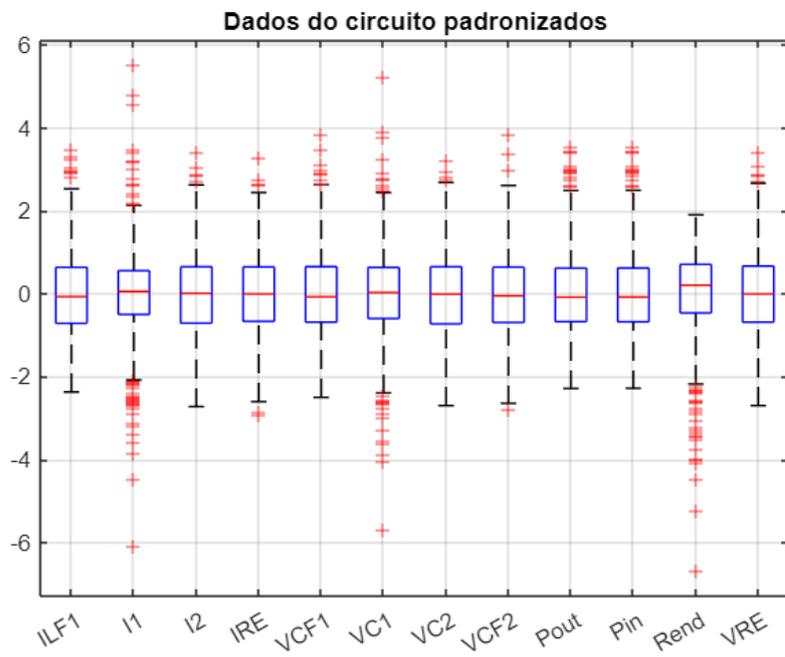
Nas Figuras 30-33 apresentam-se os dados dos componentes e dos circuitos padronizados.

Figura 30 - Dados dos componentes padronizados para Double LCC



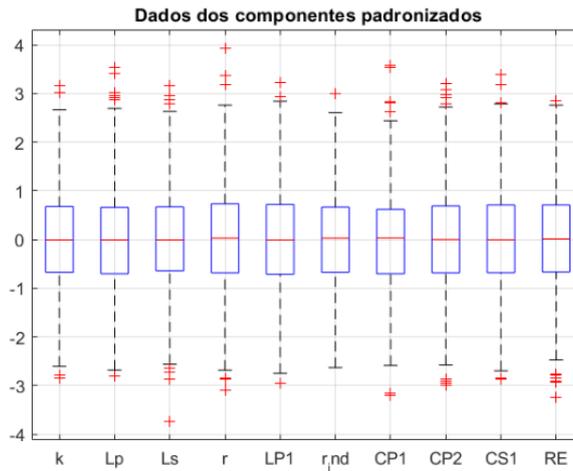
Fonte: Autor.

Figura 31 - Dados dos esforços de corrente e tensão padronizados para Double LCC



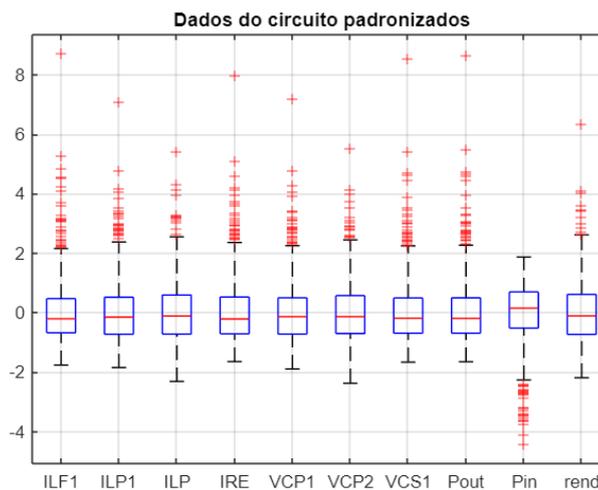
Fonte: Autor

Figura 32 - Dados dos componentes padronizados para LCC-S



Fonte: Autor

Figura 33 - Dados dos esforços de corrente e tensão para LCC-S



Fonte: Autor.

Destaca-se que os dados gerados por meio de distribuição normal apresentam o valor médio em 0 após a padronização. Entretanto, os valores obtidos por meio do cálculo de correntes e tensões apresentam desvio sobre o valor nominal devido ao efeito do deslocamento do ponto de ressonância.

Para a estimativa de parâmetros, foram necessários selecionar dados de entrada e dados a serem estimados. No circuito secundário apresentam-se as variáveis de interesse, e o circuito

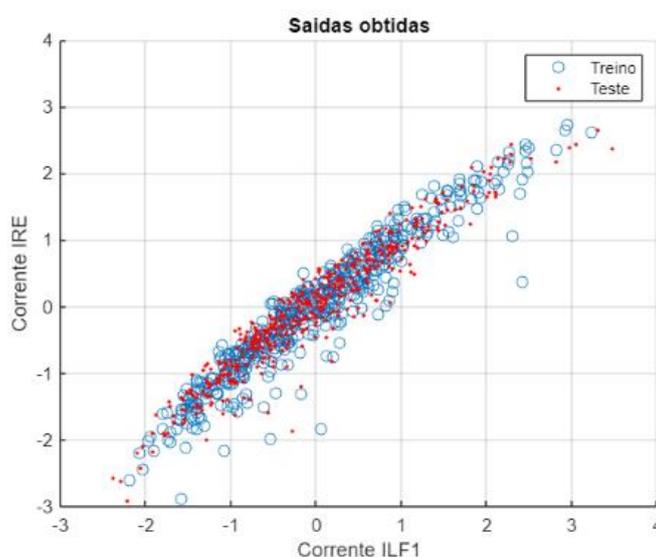
primário concentra as variáveis que podem facilmente ser medidas, deste modo, serão utilizados como parâmetros de entrada os valores nominais de projeto dos componentes, e os esforços de corrente e tensão no circuito primário. A principal variável de saída de interesse torna-se a corrente do secundário para este trabalho. As demais variáveis do circuito secundário podem ser obtidas, entretanto visando a comparação entre as técnicas, e a limitação da implementação para múltiplas saídas em algumas técnicas, optou-se para verificar o desempenho para a estimativa apenas da corrente em primeiro momento.

4.2. DADOS DE TREINO E TESTE

Para os modelos de estimação de parâmetros, são utilizados inicialmente todos os dados amostrados. A amostra foi dividida em 50% para dados de treino e 50% para dados de teste.

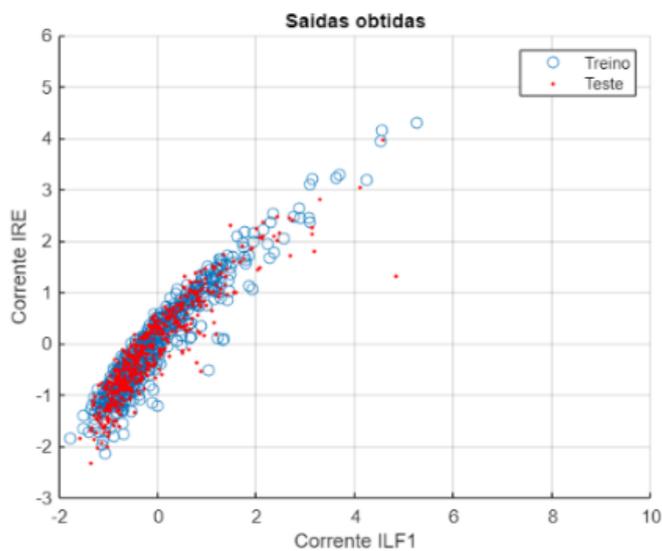
Para fins de apresentação, nas Figuras 34 e 35 apresenta-se a distribuição de dados para cada corrente de saída, as correntes de entrada. Entretanto, todos os parâmetros dos circuitos compõem as bases de dados.

Figura 34 - Dados de treino e teste para Double LCC



Fonte: Autor.

Figura 35 – Dados de treino e teste para LCC-S



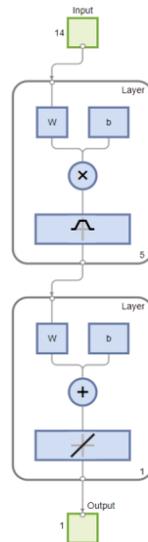
Fonte: Autor.

4.3. ESTIMATIVA DO FATOR DE ACOPLAMENTO UTILIZANDO RBF

Para a estimativa do fator de acoplamento, foram utilizados os demais dados de entrada e o fator de acoplamento como saída. Deste modo, os valores obtidos por medições de tensões e correntes do circuito primário, associados aos valores de projeto, tornam possíveis a estimativa do acoplamento entre as bobinas transmissora e receptora.

Na Figura 36 apresenta-se a estrutura da rede neural aplicada para ambas as topologias. Foram utilizados 5 em cada camada.

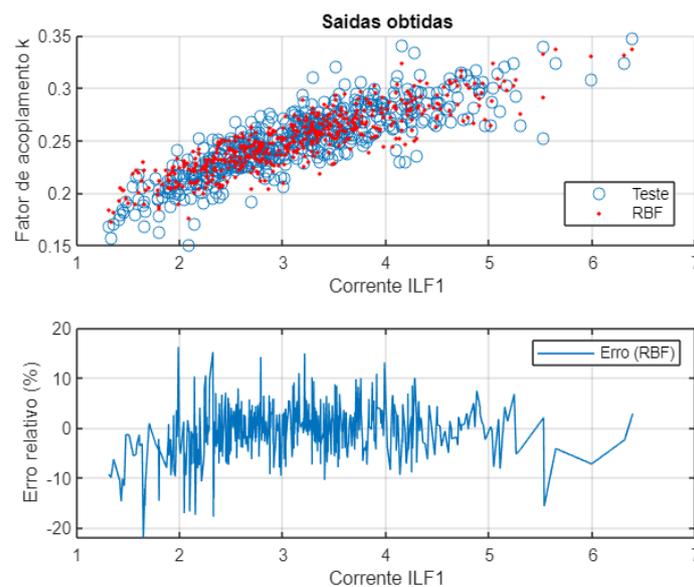
Figura 36 - Estrutura da RBF para estimativa do fator de acoplamento



Fonte: Autor.

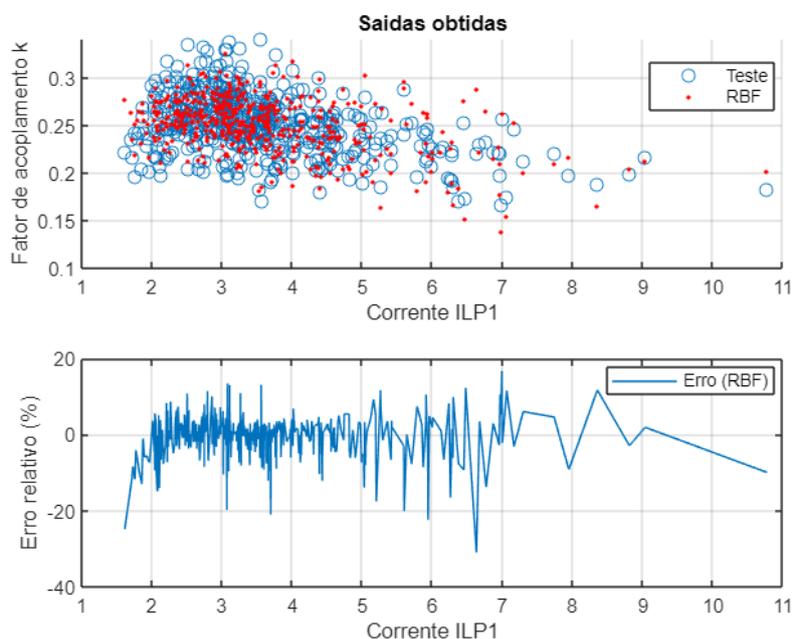
Utilizando, portanto, os parâmetros de projeto e a base de dados do circuito primário, obtemos a estimativa do fator de acoplamento para ambas as topologias utilizando a RBF. Nas Figuras 37 e 38 apresentam-se os dados estimados e o erro relativo entre a variável estimada e a variável calculada.

Figura 37 - Estimativa do Fator de acoplamento utilizando RBF para Double LCC



Fonte: Autor.

Figura 38 - Estimativa do fator de acoplamento utilizando RBF para LCC-S



Fonte: Autor.

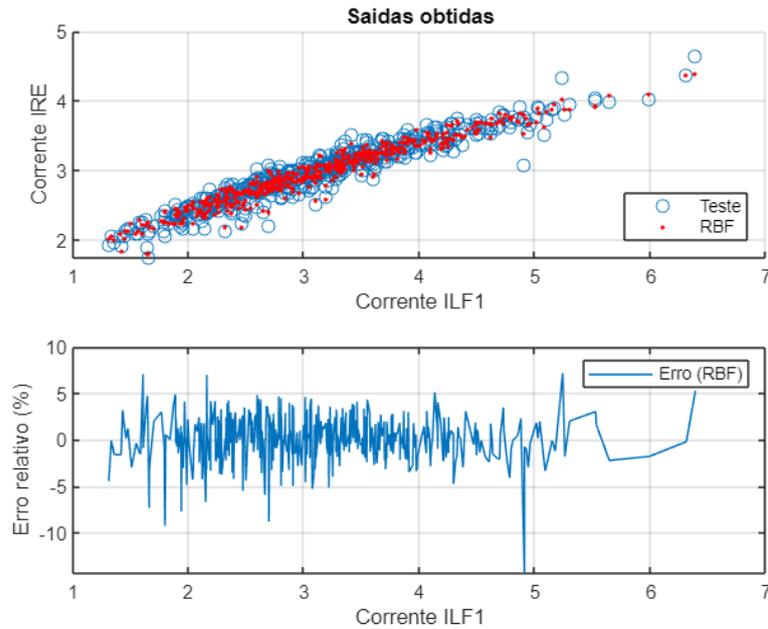
Para a LCC-S o erro relativo médio é de 3,82%, e para Double-Sided LCC é de 3,71%. Para a estimativa do fator de acoplamento, foram obtidos erros quadráticos médios inferiores a 19.609×10^{-3} para ambas as técnicas.

4.4. ESTIMATIVA DA CORRENTE NA CARGA UTILIZANDO RBF

Utilizando, portanto, da rede neural RBF apresentada, foram estimados agora com os dados do fator de acoplamento alimentados por meio de uma estimativa inicial, foram estimadas as correntes de saída. Os parâmetros de entrada são compostos pelos valores nominais de projeto, bem como as variáveis medidas do circuito primário. A mesma metodologia foi utilizada para ambas topologias.

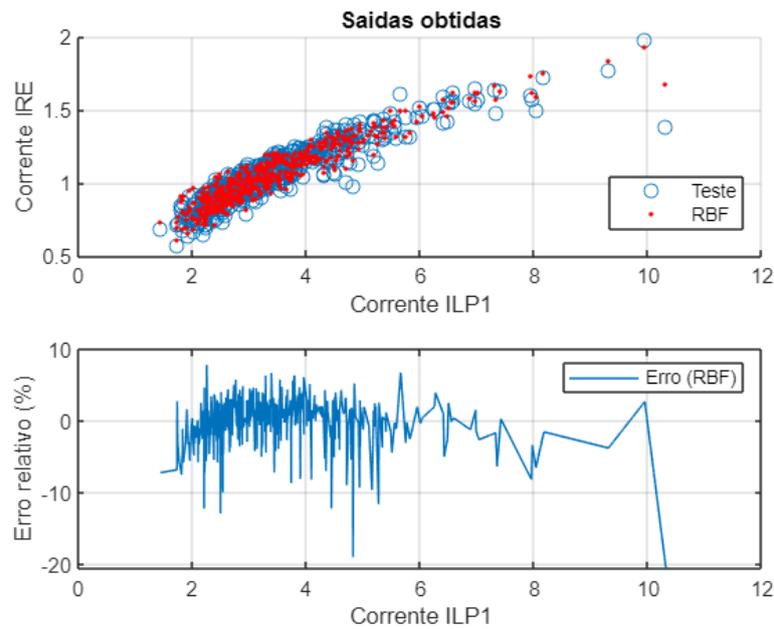
Os dados apresentados nas Figuras 39 e 40 condizem a estimativa da corrente “ I_{RE} ” em função da corrente de entrada “ I_{LF1} ” ou “ I_{LP1} ”.

Figura 39 - Estimativa da corrente IRE para Double LCC utilizando RBF



Fonte: Autor.

Figura 40 - Estimativa da corrente IRE para LCC-S utilizando RBF



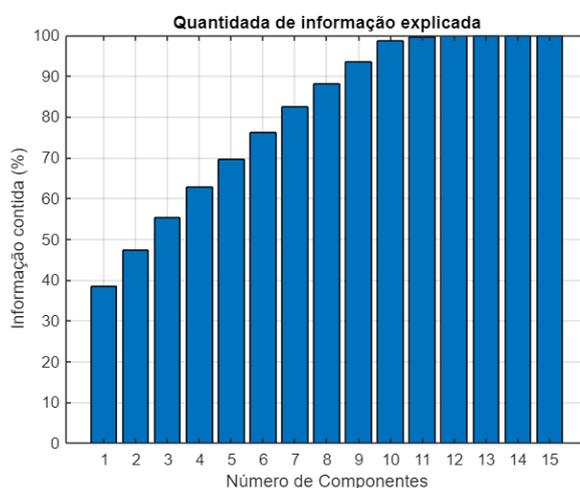
Fonte: Autor.

A Double-LCC por sua vez, apresenta menor erro na estimativa deste parâmetro. Destaca-se que por sua vez, a topologia LCC-S apresenta menor variação da corrente de saída para variações de parâmetros de projeto ou condições de operação.

4.5. ESTIMATIVA DA CORRENTE NA CARGA UTILIZANDO PCR

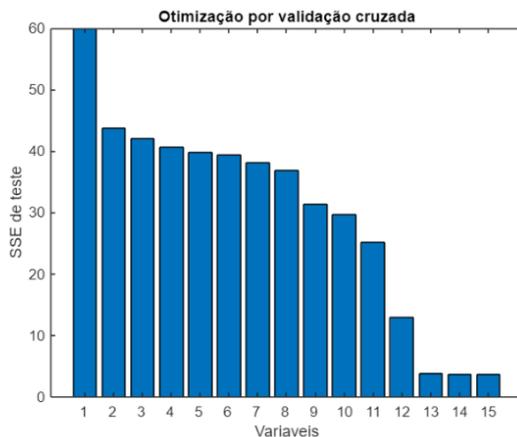
A técnica de PCA foi aplicada em ambas as topologias, separando, portanto, em componentes principais as variáveis de entrada do modelo. Nas Figuras 41 e 43, apresenta-se a quantidade de informação explicada por cada componente separado pela técnica de PCA. Nas Figuras 42 e 44, apresenta-se a validação cruzada realizada por meio de dados de treino e teste visando obter o melhor desempenho com o menor número de variáveis.

Figura 41 - Quantidade de informação explicada pelas componentes LCC-S



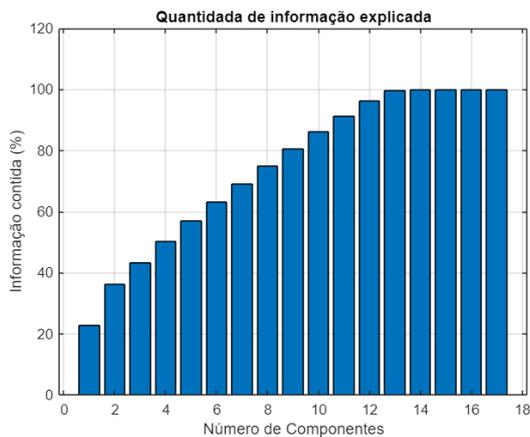
Fonte: Autor.

Figura 42 - Validação cruzada aplicada a PCR para topologia LCC-S



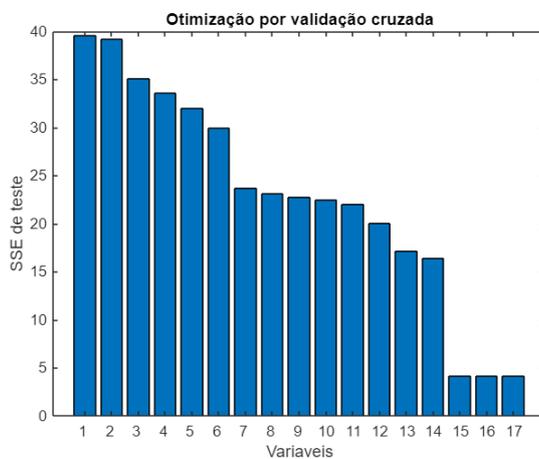
Fonte: Autor.

Figura 43 - Quantidade de informação explicada pelas componentes para Double-LCC



Fonte: Autor.

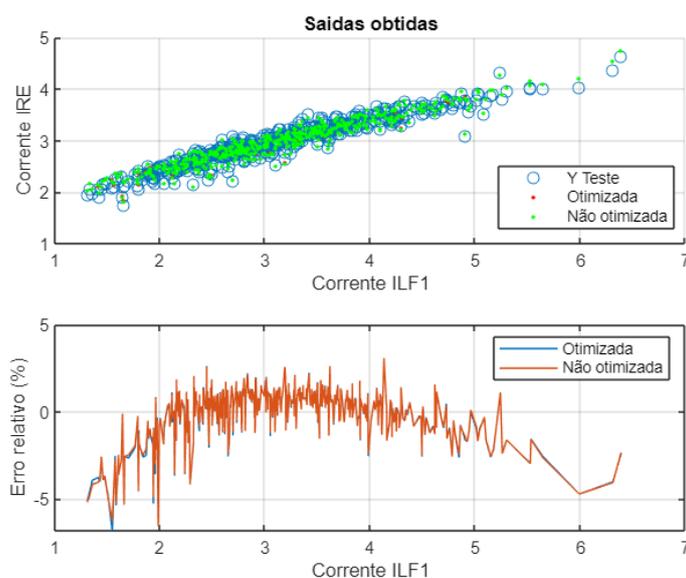
Figura 44 - Validação cruzada aplicada a PCR para Double LCC



Fonte: Autor.

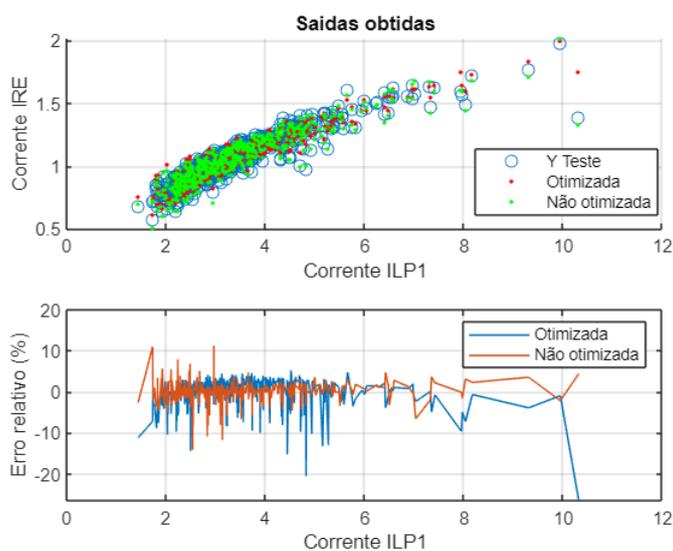
A estimativa da corrente na carga utilizando a técnica de PCR é apresentada nas Figuras 45 e 46. Para estas estimativas foram utilizadas 11 componentes principais para a técnica “otimizada” e todas as variáveis para a técnica não otimizada. Optou-se pelo uso de 11 variáveis visando obter o menor número de variáveis que em ambas as topologias obtivessem 90% da variabilidade do respectivo modelo.

Figura 45 - Estimativa da corrente IRE para Double LCC utilizando PCR



Fonte: Autor.

Figura 46 - Estimativa da corrente IRE para LCC-S utilizando PCR



Fonte: Autor.

Pode-se observar que a LCC-S apresenta menor erro quanto a estimativa geral. Podemos observar que a técnica de PCR não apresenta seu melhor desempenho para estimativa quando otimizada para um número menor de variáveis. Isto se dá porque para este modelo, todas as entradas contribuem com informação para a estimativa da corrente de saída. De modo que se nota que a validação cruzada de ambas as topologias, o menor erro é atingido com o uso de todas as variáveis dos modelos.

4.6. ESTIMATIVA DA CORRENTE NA CARGA UTILIZANDO OLS E REGRESSÃO RIDGE

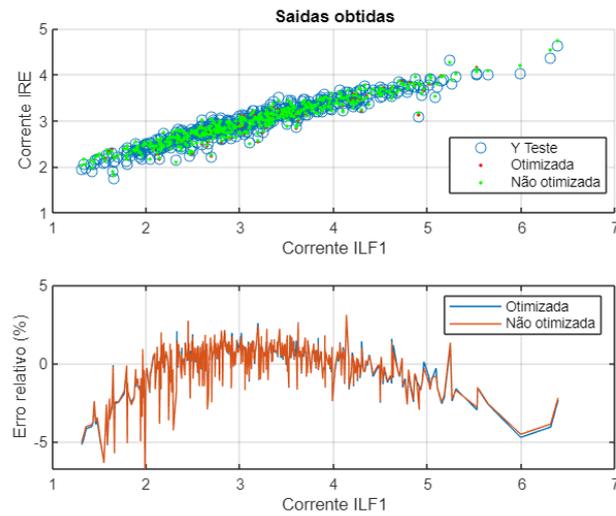
A corrente de carga pode ser estimada por meio das técnicas OLS e Regressão Ridge. Para selecionar o valor de λ utilizou-se da técnica de validação cruzada, obtendo assim dados para ajuste do modelo de regressão linear e os dados de teste foram utilizados para otimizar o ajuste obtendo o menor erro para os dados de teste. Nas Figuras 47 e 50 apresenta-se a validação cruzada para a seleção do ajuste para a Regressão Ridge com menor erro para estimação dos dados de teste, e a estimativa das correntes na carga para ambas as topologias.

Figura 47 - Validação cruzada para regressão Ridge (Double LCC)



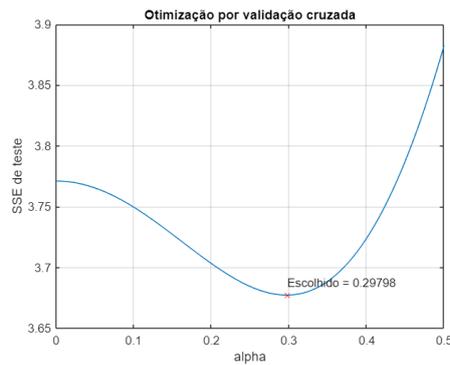
Fonte: Autor.

Figura 48 - Estimativa da corrente IRE para Double LCC utilizando Regressão Ridge e OLS



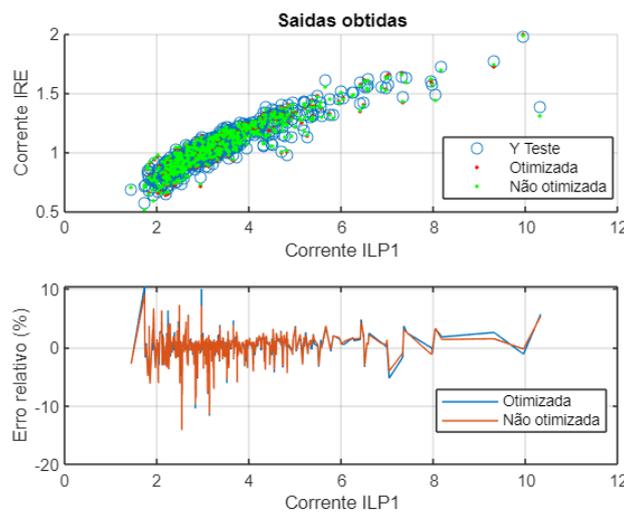
Fonte: Autor.

Figura 49 - Validação cruzada para a regressão Ridge (LCC-S)



Fonte: Autor.

Figura 50 - Estimativa da corrente IRE para LCC-S utilizando Regressão Ridge e OLS



Fonte: Autor.

4.7. ESTIMATIVA DA CORRENTE DE CARGA UTILIZANDO REGRESSÃO KERNEL

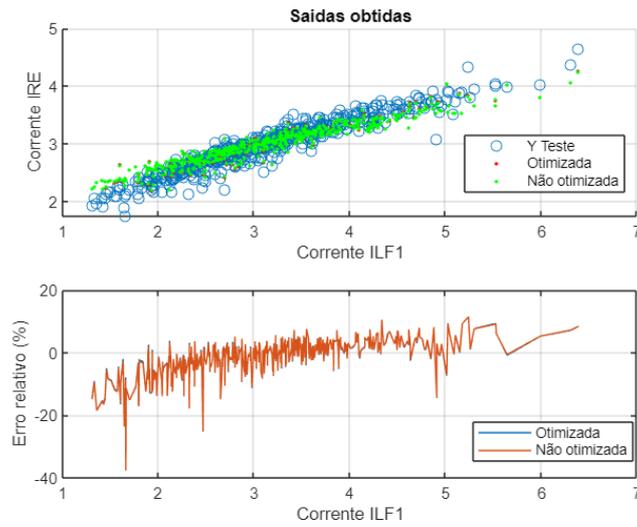
A técnica de Regressão Kernel foi aplicada de modo análogo a Regressão Ridge com o intuito de estimar a corrente de saída do modelo. As estimações utilizando regressão Kernel foram otimizadas por meio do termo α de igual modo a regressão Ridge. Deste modo. Nas Figuras 51 e 53 apresentam-se as respectivas otimizações por meio de validação cruzada, visando o menor erro para os dados de teste para a corrente IRE. Nas Figuras 52 e 54 apresentam-se os resultados obtidos pela estimação de parâmetros otimizada e não otimizada para cada topologia.

Figura 51 - Validação cruzada para regressão Kernel (Double LCC)



Fonte: Autor.

Figura 52 - Estimativa da corrente IRE para Double LCC utilizando Regressão Kernel



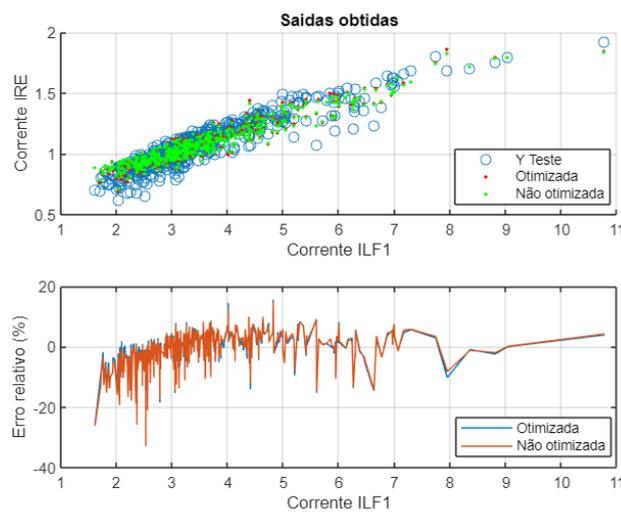
Fonte: Autor.

Figura 53 - Validação cruzada para regressão Kernel (LCC-S)



Fonte: Autor.

Figura 54 - Estimativa da corrente IRE para LCC-S utilizando Regressão Kernel

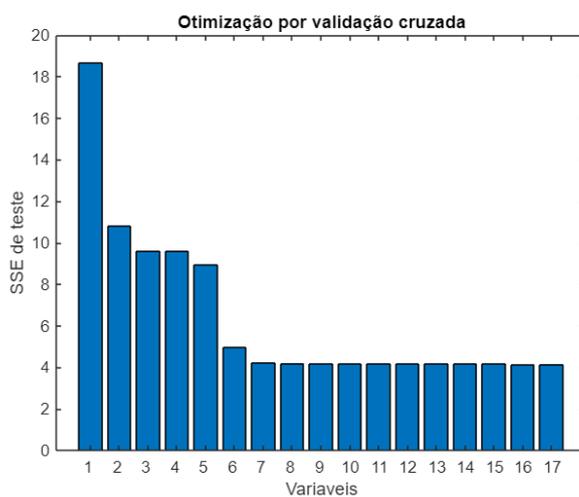


Fonte: Autor.

4.8. ESTIMATIVA DA CORRENTE DE SAÍDA UTILIZANDO QUADRADOS MÍNIMOS PARCIAIS (PLS)

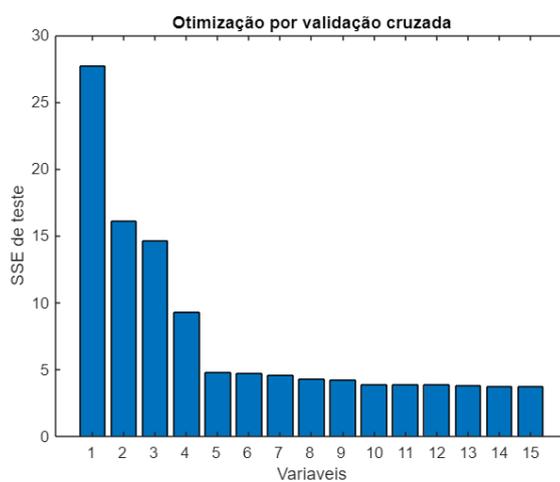
A técnica de PLS foi desenvolvida de forma análoga a PCR para seleção de variáveis a serem aplicadas no modelo. Nas Figuras 55-58 apresentam-se as validações cruzadas para quantidade de variáveis aplicadas no modelo, e as estimativas de corrente na carga.

Figura 55 - Validação cruzada para Double LCC utilizando PLS



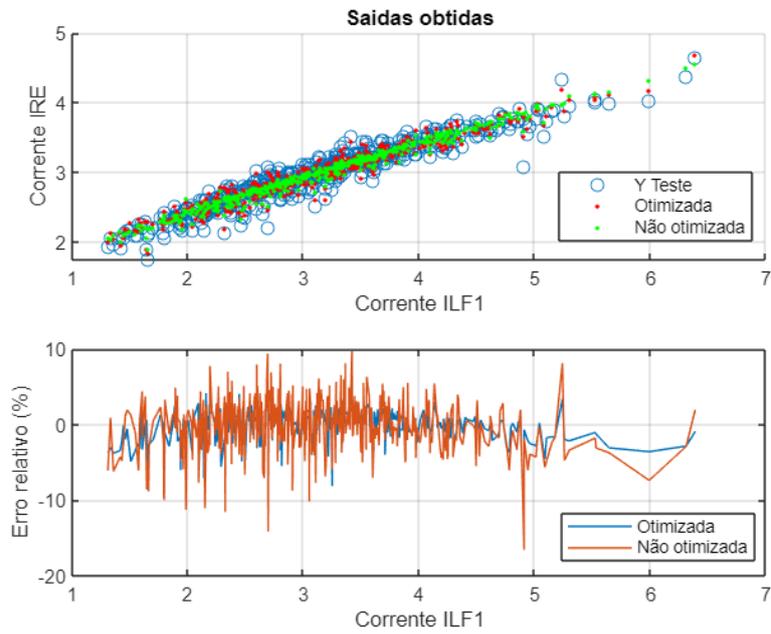
Fonte: Autor.

Figura 56 - Validação cruzada para LCC-S utilizando PLS



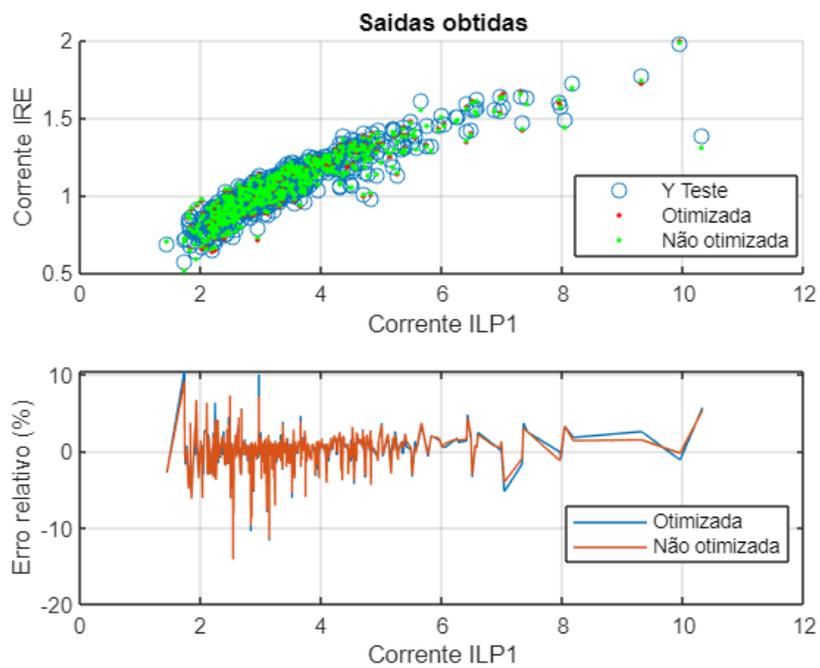
Fonte: Autor.

Figura 57 - Estimativa da corrente IRE para Double LCC utilizando PLS



Fonte: Autor.

Figura 58 - Estimativa da corrente IRE para LCC-S utilizando PLS

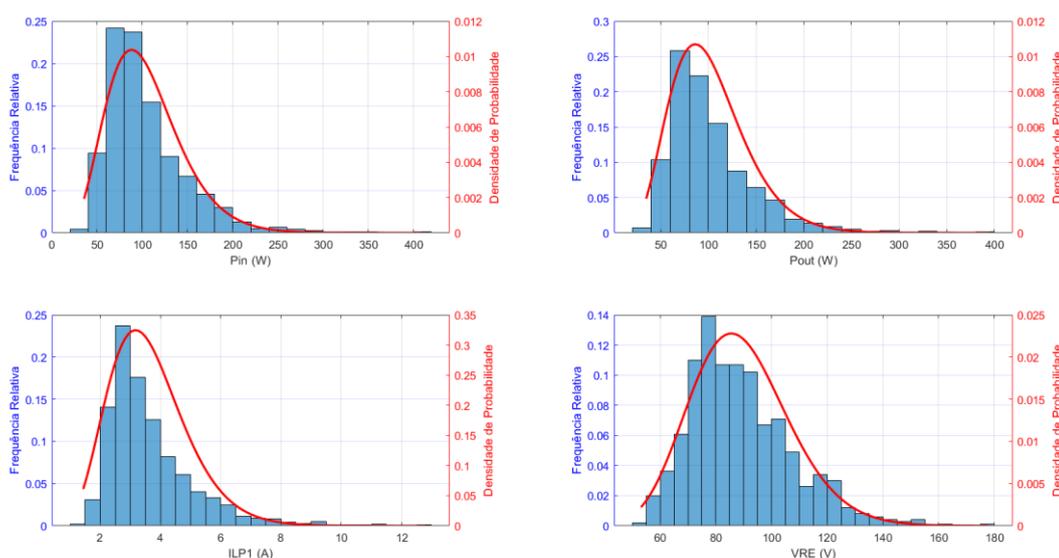


Fonte: Autor.

5. DISCUSSÕES

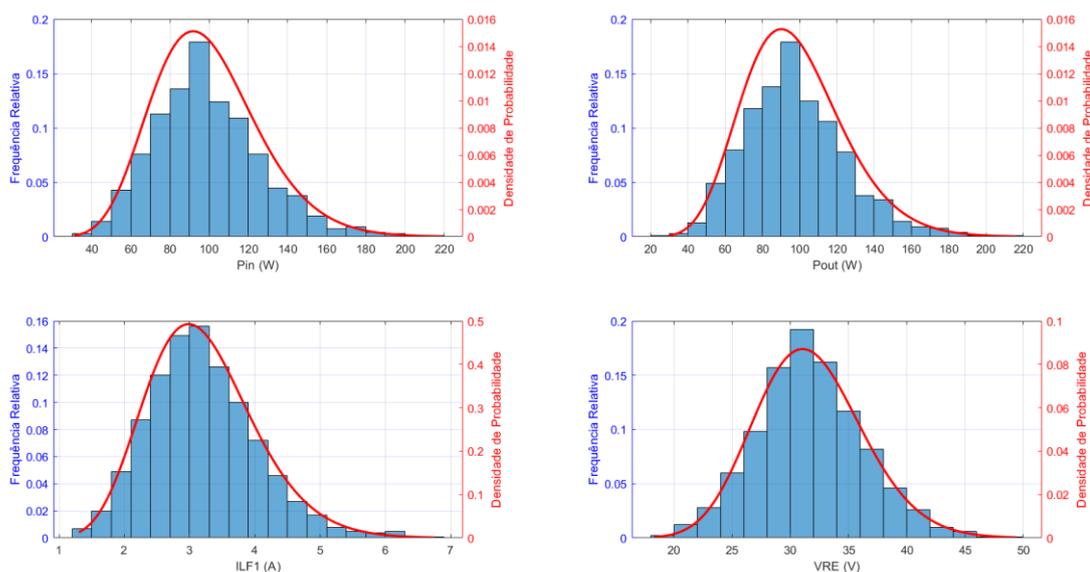
A técnica de Monte Carlo demonstrou o efeito do deslocamento do ponto de ressonância causado pelas incertezas do modelo sobre cada topologia. A combinação de componentes imprecisos e condições de operação variadas podem resultar não apenas na redução da eficiência ou variação na potência transferida, mas em aumento significativo nos esforços de tensão e corrente para os componentes de compensação. A topologia LCC-S apresentou maior sensibilidade as variações paramétricas conforme demonstram os histogramas dos espaços amostrais obtidos, podendo resultar em tensões e correntes múltiplas sobre os valores nominais. As Figuras 59 e 60 apresentam a inferência utilizando a distribuição gama sobre os principais fatores de interesse (Potência de entrada, Potência de saída, Corrente de entrada e Tensão na carga). A Tabela 11 apresenta os valores mínimos e máximos dentro do intervalo de confiança de 90% obtidos por meio da distribuição gama.

Figura 59 - Inferência sobre a distribuição Gama (LCC-S)



Fonte: Autor.

Figura 60 - Inferência sobre a distribuição gama (Double-Sided LCC)



Fonte: Autor.

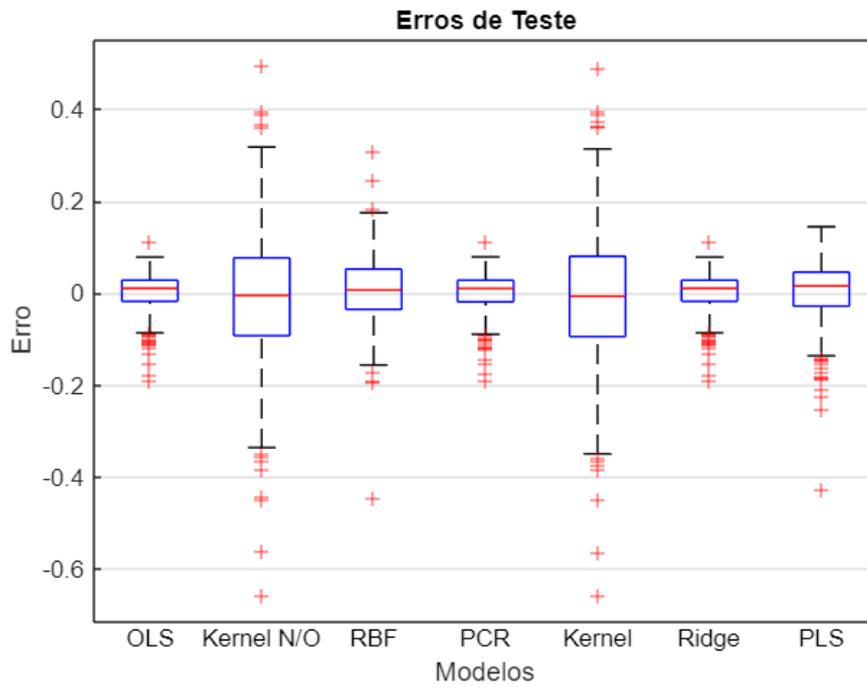
Tabela 11 - Intervalo de confiança sobre a distribuição gama (90%)

	LCC-S		Double-Sided LCC	
Parâmetro	Valor Mínimo	Valor Máximo	Valor Mínimo	Valor Máximo
Pin	37,8 W	210,22 W	48,33 W	173,64 W
Pout	37,07 W	204,48 W	47,31 W	171,16 W
ILP1	1,45 A	7,02 A	1,61 A	5,5 A
VRE	51,11 V	141,61 V	20,33 V	46,87 V

Fonte: Autor.

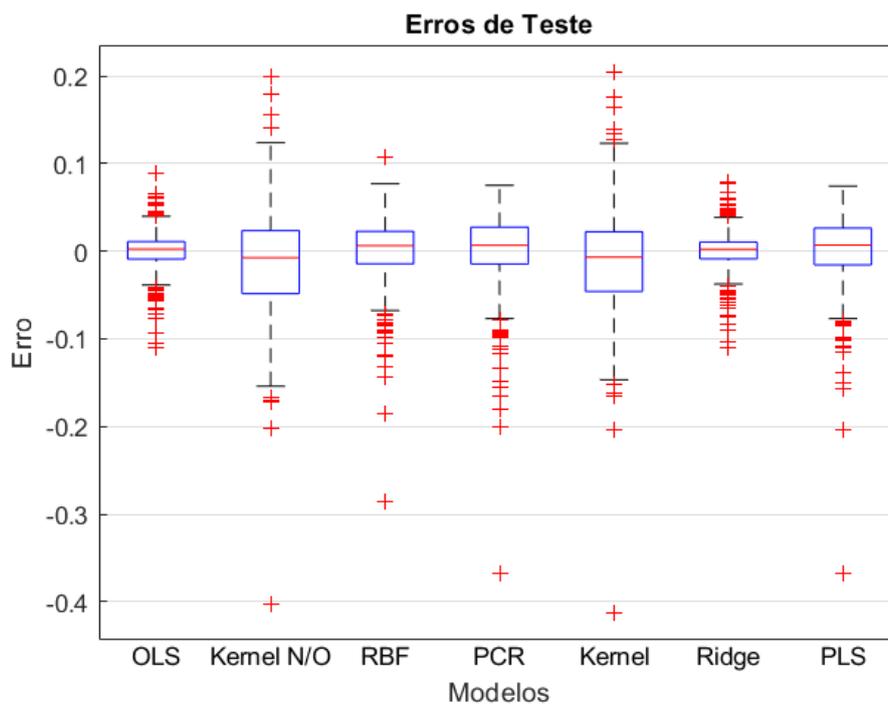
Após a aplicação e otimização das técnicas com o intuito de estimar a corrente de saída, pode-se observar que todas podem ser utilizadas na estimativa de parâmetros do secundário como a corrente de saída utilizando como entradas as variáveis medidas do primário e os dados de projeto da topologia. Nas Figuras 60 e 62 apresentam-se as distribuições dos erros de estimativa para cada técnica. Nas Figuras 63 e 64 apresentam-se os erros quadráticos médios obtidos para cada técnica. A Tabela 12 apresenta os erros relativos médios de cada uma das técnicas aplicadas.

Figura 61 - Distribuição dos erros por modelo aplicados a Double LCC



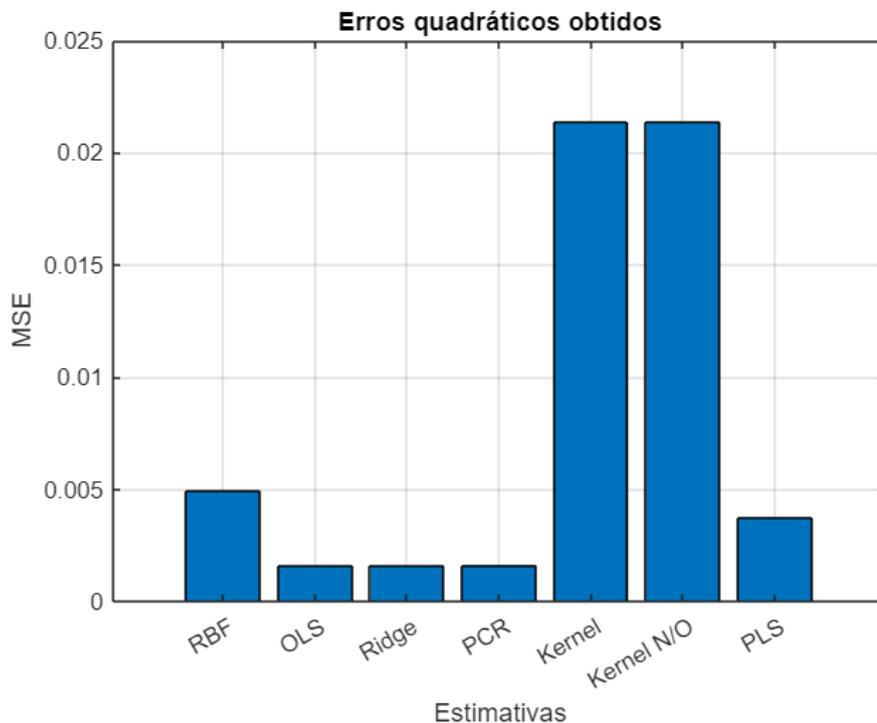
Fonte: Autor.

Figura 62 - Distribuição dos erros por modelo aplicados a LCC-S



Fonte: Autor.

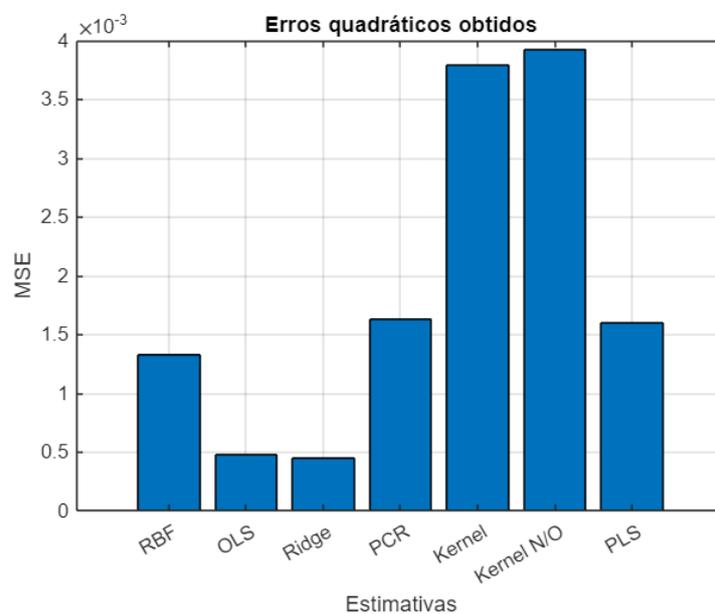
Figura 63 - Erros dos modelos aplicados a estimativa de corrente IRE para Double LCC



Estimativas

Fonte: Autor.

Figura 64 - Erros dos modelos aplicados a estimativa de corrente IRE para LCC-S



Estimativas

Fonte: Autor.

Tabela 12 - Erros relativos médios

Técnica	Double-Sided LCC	LCC-S
RBF (k)	3,720 %	3,980 %
RBF (IRE)	1,620 %	2,302 %
OLS (IRE)	0,961 %	1,356 %
Ridge (IRE)	0,961 %	1,319 %
PCR (IRE)	0,966 %	2,858 %
Kernel (IRE)	3,796 %	4,066 %
Kernel Não Otimizada (IRE)	3,803 %	4,322 %
PLS	1,644 %	2,769 %

Fonte: Autor.

Podemos notar que as técnicas de melhor ajuste são as regressões que utilizam a regressão de quadrados mínimos (OLS e Ridge). Vale ressaltar que, visto que o modelo se trata de um circuito elétrico, a estimativa do secundário possuindo todas as variáveis do primário e dos componentes trata-se de variáveis altamente correlacionadas. De modo a justificar que as validações cruzadas obtidas nas técnicas de Ridge, PCR e PLS não grande ganho com a redução de componentes ou uso de fatores de ajuste dos modelos. Indicando que, para este sistema, os componentes carregam uma variância bem distribuída entre as variáveis.

Outro ponto a se destacar na utilização das regressões PLS e PCR é que obtém erro maior em relação ao teste aplicado a OLS, mas apresentam a redução de dimensionalidade. A PLS apresenta menor erro de teste na estimativa da variável de saída e com o uso de menos componentes principais. Enquanto a PCR utilizou-se de 11 componentes, a PLS utilizou-se de 7 componentes.

A regressão Kernel apresentou o maior erro entre as técnicas. Por sua vez a otimização ficou próximo ao valor padrão de 'h'. Conforme a literatura apresenta, a regressão Kernel tende a ter seu ponto ótimo próximo a 1 em casos de dados padronizados.

A rede neural RBF apresentou ajuste equivalente as regressões de aplicadas. Entretanto, não foi aplicada nenhuma técnica de otimização ou validação cruzada obter melhor desempenho. De modo que, a aprimoração do trabalho explorando novas estruturas para a rede neural com relação a quantidade de neurônios, camadas e interações pode apresentar melhor resultado. Também se destacou obtendo desempenho na estimativa do fator de acoplamento.

CONCLUSÕES

Conclui-se, portanto, que a análise de sensibilidade em sistemas de WPT pode apontar elementos críticos na construção de circuitos experimentais, prevendo os resultados do deslocamento do ponto de ressonância na potência transferida, no rendimento e nos esforços de tensão e corrente nos componentes de compensação. O fator de acoplamento se destaca, sendo o parâmetro com maior influência sobre a transferência de potência em ambas as topologias. A topologia LCC-S apresenta maior sensibilidade dos esforços de corrente e tensão com relação ao valor da indutância primária e a capacitância secundária C_{P2} .

Podemos concluir preliminarmente, que a regressão kernel, mesmo otimizada, possui o menor desempenho para estimativa dos parâmetros de interesse. As demais técnicas de regressão Ridge, PCR e PLS, destacam-se principalmente: a técnica PLS que obteve desempenho com redução significativa de variáveis no modelo; e a Regressão Ridge que obteve excelente desempenho e destaca-se como uma técnica de menor complexidade com relação a PLS.

A RBF por sua vez, demonstra-se promissora sendo capaz de estimar o fator de acoplamento e os parâmetros do secundário com desempenho similar as técnicas de regressão sem nenhuma técnica de otimização aplicada.

As técnicas foram exploradas para estimativa da corrente de saída apenas, de modo que são possíveis novas análises visando a exploração das técnicas para a estimativa da tensão na carga ou mesmo para múltiplas saídas.

Para seguimento do trabalho, podemos citar alguns caminhos como, estimativa da tensão de saída do modelo, desenvolvimento de metodologia de otimização da RBF,

comparação entre modelos com saídas multivariadas, comparação de desempenho frente a redução de variáveis de entrada, desempenho das técnicas em sistemas de controle, e desempenho das técnicas frente ao circuito experimental. Outro caminho é a modelagem estatística da topologia com variação completa de parâmetros, de modo a explorar modelos com comportamentos não lineares, e o desempenho das técnicas frente a estes modelos.

REFERÊNCIAS

- [1] X. Lu, P. Wang, D. Niyato, D. I. Kim e Z. Han, “Wireless Charging Technologies: Fundamentals, Standards, and Network Applications,” *IEEE Communications Surveys & Tutorials*, pp. 1413-1452, abril 2016.
- [2] T. Sun, Z. Wang e X. Xie, *Wireless power transfer for medical microsystems*, 2013.
- [3] T. Imura, *Wireless Transfer Power: Using Magnetic and Electric Resonance Coupling Techniques*, 2020.
- [4] G. Buja, C. C. Mi, S. Y. Choi e C. T. Rim, “Modern Advances in Wireless Power Transfer Systems for Roadway Powered Electric Vehicles,” *Modern Advances in Wireless Power Transfer Systems for Roadway Powered Electric Vehicles*, pp. 6533-6545, 2016.
- [5] K. N. Bocan e E. Sejdić, *Adaptive Transcutaneous Power Transfer to Implantable Devices: A State of the Art Review*, *Sensors*, 2016, pp. 6533-6545.
- [6] C.-S. Wang, G. A. Covic e O. H. Stielau, “Power Transfer Capability and Bifurcation Phenomena of Loosely Coupled Inductive Power Transfer Systems,” *IEEE Trans. Ind. Electron*, p. 148–157, 2004.
- [7] W. Zhang e C. C. Mi, “Compensation Topologies of High-Power Wireless Power Transfer Systems,” *IEEE Transactions on Vehicular Technology*, pp. 4768-4778, 2016.
- [8] L. Zhang, H. Wang e J. He, “Comprehensive Sensitivity Analysis and Optimization of High-Order Compensation Networks for Wireless Power Transfer,” *IEEE Transactions on Power Electronics*, pp. 4738-4751, 2022.
- [9] M. A. Ngini, C.-T. Truong e S.-J. Choi, “Parameter Identification for Primary-Side Control of Inductive Wireless Power Transfer Systems: A Review,” *IEEE Access*, pp. 15885-15904, 2025.
- [10] R. d. S. Silva, *Estudo comparativo entre topologias híbridas para transferência de energia sem fio: simulação e implementação*, Campo Grande: Universidade Federal de Mato Grosso do Sul, 2022.

-
- [11] W. Zhong, D. Xu e R. S. Y. Hui, *Wireless power transfer: Between Distance and Efficiency*, 2016.
- [12] C.-S. Wang, G. A. Covic e O. H. Stielau, “Investigating an LCL load resonant inverter for inductive power transfer applications,” *IEEE Trans. Power Electron*, p. 995–1002, 2004.
- [13] S. Li, W. Li, J. Deng, T. . D. Nguyen e C. C. Mi, “A Double-Sided LCC Compensation Network and Its Tuning Method for Wireless Power Transfer,” *IEEE Trans. Veh. Technol*, p. 2261–2273, 2015.
- [14] J. Yang, X. Zhang, K. Zhang, X. Cui, C. Jiao e X. Yang, “Design of LCC-S Compensation Topology and Optimization of Misalignment Tolerance for Inductive Power Transfer,” *IEEE Access*, p. 191309–191318, 2020.
- [15] J. Silva, R. Souza e L. Almeida, “Challenges in Wireless Power Transfer Systems,” *Journal of Wireless Technology*, pp. 234-245, 2023.
- [16] P. Moura e Costa, “Effects of High Frequencies and Magnetic Fields on Wireless Power Transfer Efficiency,” *International Journal of Power Electronics*, pp. 189-200, 2022.
- [17] T. Hastie, J. H. Friedman e R. Tibshirani, *The Elements of Statistical Learning Data Mining, Inference, and Prediction*, Springer, 2009.
- [18] D. C. Montgomery, G. G. Vining e E. A. Peck, *Introduction to Linear Regression Analysis*, Wiley, 2012.
- [19] M. Larbi, R. Trinchero, F. G. Canavero, P. Besnier e M. Swaminathan, “Analysis of Parameter Variability in an Integrated Wireless Power Transfer System via Partial Least Squares Regression,” *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2020.
- [20] J. F. Hair, B. J. Babin, R. E. Anderson e W. C. Black, *Multivariate Data Analysis*, Cengage, 2019.
- [21] K. Kim, Y. Kim e J. Park, “Challenges in Measuring Coupling Coefficient for Wireless Power Transfer Systems,” *IEEE Transactions on Power Electronics*, pp. 123-130, 2018.
- [22] H. Zhang, X. Liu e L. Wang, “Dynamic Measurement Techniques for Coupling Coefficient in Wireless Power Transfer Systems,” *IEEE Transactions on Industrial*

Electronics, pp. 2345-2354, 2019.

- [23] D. Witten, R. Tibshirani e T. Hastie, *An Introduction to Statistical Learning: with Applications*, Springer, 2013.
- [24] A. Triviño, J. M. González-González e J. A. Aguado, “Wireless Power Transfer Technologies Applied to Electric Vehicles: A Review,” *Energies*, vol. 14, p. 1547, 2021.