



HOKKAIDO UNIVERSITY

Title	電磁デバイスの最適設計および機械学習による高速化に関する研究
Author(s)	地引, 琢人
Degree Grantor	北海道大学
Degree Name	博士(情報科学)
Dissertation Number	甲第16516号
Issue Date	2025-03-25
DOI	https://doi.org/10.14943/doctoral.k16516
Doc URL	https://hdl.handle.net/2115/95194
Type	doctoral thesis
File Information	Takuto_Jibiki.pdf



博士論文

電磁デバイスの最適設計および
機械学習による高速化に関する研究

地引 琢人



HOKKAIDO
UNIVERSITY

2025 年 2 月

北海道大学 大学院情報科学院
システム情報科学コース

本論文は北海道大学大学院情報科学院に
博士 (情報科学) 授与の要件として提出した博士論文である.

地引 琢人

審査委員： 主査 五十嵐 一 教授
副査 野口 聡 教授
北 裕幸 教授

Copyright © 2025 by Takuto Jibiki.

In reference to IEEE copyrighted material which is used with permission in this thesis, the IEEE does not endorse any of Hokkaido University's products or services. Internal or personal use of this material is permitted. If interested in reprinting/republishing IEEE copyrighted material for advertising or promotional purposes or for creating new collective works for resale or redistribution, please go to http://www.ieee.org/publications_standards/publications/rights/rights_link.html to learn how to obtain a License from RightsLink.

電磁デバイスの最適設計および 機械学習による高速化に関する研究*

地引 琢人

概要

情報化社会の進展に伴って通信トラフィックが急速に増大しており、ネットワーク機器の高性能化、小型化が要求されていることから、無線通信に使われるマイクロ波回路の新たな設計手法が必要とされている。

電磁デバイスの設計では、目標の特性と電磁界シミュレーションで計算した特性の差を目的関数として定義し、これを最小化する形状を求めることで設計を行う最適設計のアプローチがよく用いられる。最適設計の一手法であるトポロジー最適化 (TO: topology optimization) は高い自由度の設計が可能であり、革新的な構造を見出すことができる。ただし、マイクロ波回路の基本要素であるマイクロストリップライン (MSL: microstrip line) により構成される回路への適用例は少なく、その有効性は不明である。また進化計算を用いた TO は大域的な探索が可能な代わりにその計算コストが問題となっている。

電気電子機器の小型化のためにインダクタやモータなどのデバイスが高周波化しており、周波数に比例して増加するヒステリシス損失 (ヒス損) を正確に考慮した設計が重要となっている。正確なヒス損解析には近似式を用いた簡便な解析手法よりも多くの計算コストが必要となり、多数のヒス損解析を行うインダクタやモータなどの最適設計では、その計算コストの増大が問題となる。

上記の最適設計における計算コストの問題に対処するために、時間のかかる計算を機械学習により置き換える代替モデル法が知られている。計算を置き換えるだけの典型的な代替モデル法では、代替モデルによって特性を精度よく予測できることが前提となっている。一方で MSL で構成されるフィルタ回路は高精度な代替モデルの作成が難しく、精度が不十分な代替モデルで最適設計を実行すると、予測誤差に起因して最適設計が失敗してしまう問題がある。

* 北海道大学大学院情報科学院 システム情報科学コース 博士論文, SSI-DT46245041, 2025 年 2 月 13 日。

本研究では電磁デバイス、特にマイクロ波回路と電気機器を対象にその最適設計の高度化 (TO 法の開発および高速化) を目的とし、以下の 3 つの課題を考える。

1. マイクロ波回路へのトポロジー最適化の適用例が少なく、その有効性は不明である
2. マイクロ波のフィルタ回路はその特性の正確な予測が難しく、電磁界解析を置き換えるだけの典型的な代替モデル法が MSL 回路の TO に適用できない
3. ヒステリシス特性を正確に考慮できる既存のヒス損解析手法は実行に時間を要するため、最適設計などの多数のヒス損解析が必要な際に問題となる

第 3 章では 1. の課題を解決するために、MSL で構成されるフィルタ回路および電力分配回路を TO により設計し、その有効性を検証する。本研究ではガウス基底関数法 (NGnet 法) および幾何射影法の二つの TO 手法を検討し、従来の設計手法もあわせて比較する。最適設計を実施した結果、フィルタ回路の設計については NGnet 法の方が従来法よりも回路長を短くできることが分かった。また二つの TO を比較した結果、スタブ構造を活用できる、扁平なメッシュが生成されづらいという二つの理由から、幾何射影法の方が NGnet 法よりも MSL 回路の設計に適していることが明らかになった。

第 4 章では 2. の課題を解決するために、代替モデルの精度を予測する手法およびそれを用いた最適設計手法を提案する。提案法では畳み込みニューラルネットワークにより代替モデルの精度を予測し、その予測結果に基づいて電磁界解析と代替モデルを切り替えて最適設計を行う。提案法により MSL からなるフィルタ回路を設計した結果、代替モデルの予測誤差に起因する最適化の失敗 (誤誘導) を回避しつつ、最適化時間を 9 倍高速化できた。提案法を用いることで、高精度な代替モデルの作成が難しい MSL のフィルタ回路であっても代替モデルを利用した TO が可能であることを示した。

第 5 章では 3. の課題を解決するために、機械学習により電磁デバイスのヒス損解析を高精度かつ高速に実行する手法を提案する。ヒステリシス特性は入力波形の極値によって特徴づけられるという性質を利用し、提案法では入力波形を極値で分割した区間ごとに代替モデルを適用する。インダクタのヒス損解析に対して提案法を適用した結果、従来の高精度なヒス損解析手法と同様の解析結果を得つつ、計算時間を約 2,000 倍高速化できた。さらに提案法を用いてヒス損を最小化するインダクタの最適設計を実行した結果、代替モデルの作成に要する時間を含めて最適設計の所要時間を 2.5 倍高速化できた。

キーワード: マイクロ波回路, トポロジー最適化, 機械学習, 代替モデル, ヒステリシス損失

Study on optimal design of electromagnetic devices and acceleration by machine learning[†]

Takuto Jibiki

Abstract

The rapid growth of communication traffic in the information society has led to demands for higher performance and smaller network equipment. This has created a need for new design methods for microwave circuits used in wireless communications.

In the design of electromagnetic devices, the optimal design approach is often used, where the difference between the target characteristics and the characteristics computed by electromagnetic simulation is defined as the objective function, and the shape that minimizes this difference is found. Topology optimization (TO), one of the optimal design methods, allows a high degree of design freedom and can find innovative structures. However, TO has not been sufficiently applied to circuits composed of microstrip lines (MSLs), which are the basic elements of microwave circuits, and its effectiveness is not yet known. In addition, although TO using evolutionary computation can perform global searches, its computational cost is a problem.

Devices such as inductors and motors are being used at higher frequencies to miniaturize electrical and electronic equipment, and it has become important to accurately evaluate the hysteresis loss (hysloss), which increases with frequency. Accurate hysloss analysis requires more computational cost than simple analysis methods using approximation formulas, and the increase in computational cost is a problem in the optimal design of inductors and motors, where a large number of hysloss analyses are performed.

To address the above problem of computational cost in optimal design, surrogate model methods are known to replace time-consuming computation with machine learning. The typical surrogate model method that only replaces computation assumes that the surrogate model can accurately predict the characteristics. On the other hand, it is difficult to create a surrogate model with high accuracy for filter circuits composed of MSLs, and if an inaccurate surrogate model is used for optimal design, the optimal design will fail due to prediction errors.

The purpose of this study is to improve (develop and accelerate the TO method) the optimal design of electromagnetic devices, especially microwave circuits and electrical devices. The following three problems are considered.

[†] Doctoral Thesis, Course of Systems Science and Informatics, Graduate School of Information Science and Technology, Hokkaido University, SSI-DT46245041, February 13, 2025.

1. The effectiveness of topology optimization for microwave circuits is unknown because there are few examples of its application to microwave circuits.
2. The typical surrogate model method, which only replaces the electromagnetic computation, cannot be applied to the TO of MSL circuits because it is difficult to accurately predict the characteristics of microwave filter circuits.
3. Existing accurate hysloss analysis methods are time-consuming to perform, which is a problem when many hysloss analyses are required, such as for optimal design.

In Chapter 3, to solve Problem 1, we design a filter circuit and a power divider circuit composed of MSLs using TO and verify the effectiveness of the TO method. Two TO methods, the Gaussian basis function method (NGnet method) and the geometry projection method, are considered in this study, and conventional design methods are also compared. The optimal design results show that the NGnet method can shorten the circuit length for filter circuit design better than the conventional method. The comparison of the two TO methods shows that the geometry projection method is more suitable for designing MSL circuits than the NGnet method for two reasons: it can utilize stub structures, and it is less likely to generate flat meshes.

In Chapter 4, to solve Problem 2, we propose a method for predicting the accuracy of surrogate model and an optimal design method based on this method. The proposed method uses a convolutional neural network to predict the accuracy of the surrogate model, and switches between electromagnetic field analysis and surrogate model based on the prediction results to perform optimal design. The proposed method can avoid optimization failures (misleading) caused by surrogate model prediction errors and accelerate the optimization time by a factor of 9. The proposed method enables TO using surrogate model even for MSL filter circuits, for which it is difficult to create a highly accurate surrogate model.

In Chapter 5, to solve Problem 3, we propose a method to perform hysloss analysis of electromagnetic devices with high accuracy and speed using machine learning. The proposed method applies a surrogate model to each section of the input waveform divided by its extreme values, taking advantage of the fact that hysteresis characteristics are characterized by the extreme values of the input waveform. As a result of applying the proposed method to the hysloss analysis of an inductor, the computational time was reduced by 2,000 times while obtaining the same analysis results as those obtained by conventional high-precision hysloss analysis methods. Furthermore, the optimal design of inductors that minimize hysloss using the proposed method resulted in a 2.5-fold reduction in the time required, including the time required to create surrogate models.

Keywords: microwave circuit, topology optimization, machine learning, surrogate model, hysteresis loss

目次

第 1 章	序論	1
1.1	研究背景	1
1.2	研究目的	2
1.2.1	マイクロストリップラインのトポロジー最適化	2
1.2.2	精度予測に基づく代替モデル法によるトポロジー最適化の高速化	3
1.2.3	機械学習を用いたヒステリシス損失の高速解析	3
1.3	本論文の構成	3
第 2 章	最適設計手法	5
2.1	はじめに	5
2.2	トポロジー最適化	5
2.2.1	ガウス基底関数法 (NGnet 法)	6
2.2.2	幾何射影法 (geometry projection method)	7
2.3	最適化アルゴリズム	7
2.3.1	正規分布	8
2.3.2	遺伝的アルゴリズム	8
2.3.3	共分散行列適応進化戦略 (CMA-ES)	12
2.4	進化計算における制約の取り扱い	14
2.5	まとめ	15
第 3 章	マイクロストリップラインのトポロジー最適化	17
3.1	はじめに	17
3.2	マイクロストリップ帯域通過フィルタの設計	18
3.2.1	問題設定	18
3.2.2	NGnet 法による設計	19
3.2.3	幾何射影法による設計	24
3.3	マイクロストリップ二重帯域通過フィルタの設計	27
3.3.1	問題設定	27
3.3.2	NGnet 法および幾何射影法による設計	28

3.4	マイクロストリップ電力分配器の設計	31
3.4.1	問題設定	31
3.4.2	NGnet 法による設計	31
3.5	まとめ	35
第 4 章	精度予測に基づく代替モデル法によるトポロジー最適化の高速化	37
4.1	はじめに	37
4.2	提案する最適設計手法	39
4.2.1	代替モデルの精度の予測	39
4.2.2	精度予測に基づく最適化	40
4.3	提案法を適用した結果	41
4.3.1	事前最適化	41
4.3.2	代替モデル	43
4.3.3	精度予測器	45
4.3.4	最適化結果	47
4.4	まとめ	49
第 5 章	機械学習を用いたヒステリシス損失の高速解析	51
5.1	はじめに	51
5.2	定式化	52
5.2.1	プレイモデル	52
5.2.2	磁気エネルギーの計算	54
5.2.3	仮定	55
5.2.4	提案法の手順	55
5.3	提案法によるヒス損解析	57
5.3.1	学習データの生成	57
5.3.2	NN の学習	60
5.3.3	ヒス損解析の結果	62
5.3.4	異なる波形への適用	63
5.4	提案法によるインダクタの最適設計	65
5.4.1	問題設定	65
5.4.2	学習データの生成	66
5.4.3	NN の学習	67
5.4.4	最適化結果	68
5.5	まとめ	71
第 6 章	結論	73
6.1	マイクロストリップラインのトポロジー最適化 (第 3 章)	73

6.2	精度予測に基づく代替モデル法によるトポロジー最適化の高速化（第 4 章） .	74
6.3	機械学習を用いたヒステリシス損失の高速解析（第 5 章）	74
	謝辞	75
	参考文献	77
付 録 A	平行結合線路帯域通過フィルタの設計	85
A.1	はじめに	85
A.2	設計手順	86
A.3	設計した結果	86

目 次

2.1	NGnet 法の概要	6
2.2	幾何射影法の概要. 離散要素として円を採用した場合の例.	7
2.3	進化的アルゴリズムによる最適化の流れ	8
2.4	正規分布	9
2.5	稜構造を持つ関数の例 (Rosenbrock 関数)	10
2.6	ペナルティ関数により緩和された目的関数	14
3.1	マイクロストリップラインの構造	17
3.2	MSBPF の最適化モデル	19
3.3	MSBPF のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している.	19
3.4	目的関数 F_1 の収束履歴	20
3.5	最適化結果をもとに作製した MSBPF とその特性 [24] ©2024 IEEE	21
3.6	S パラメータ測定の様子	21
3.7	最適化形状の電界分布	22
3.8	従来法 (PC-BPF) と提案法 (NGnet 法) で設計した MSBPF. 導体箔形状の二つの画像の縮尺は同じ (原寸ではない). 青が導体箔, 白が空気を表す.	23
3.9	幾何射影法を用いた MSBPF の最適化の概要 [30] ©2024 IEEE	24
3.10	制約条件 [30] ©2024 IEEE	25
3.11	目的関数 F_2 の収束履歴 [30] ©2024 IEEE	26
3.12	MSBPF の最適化結果 [30] ©2024 IEEE	26
3.13	最適化形状とスタブを削除した形状の比較 [30] ©2024 IEEE	27
3.14	NGnet 法と幾何射影法における設計変数 [30] ©2024 IEEE	28
3.15	目的関数 F_3 の収束履歴 [30] ©2024 IEEE	28
3.16	最適化結果 (図 3.15 に対応) [30] ©2024 IEEE	29
3.17	最適化形状の解析メッシュ (図 3.16a, 図 3.16b に対応)	31
3.18	MSPD の最適化モデル [24] ©2024 IEEE	32

3.19	MSPD のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している. 三層とも同じ配置. [24] ©2024 IEEE	32
3.20	目的関数 F_4 の収束履歴	33
3.21	MSPD の最適化結果. 青が導体箔, 白が空気を表す. [24] ©2024 IEEE	33
3.22	最適化形状の電界分布 ($f = 4.2$ GHz). 左から順に Top layer, Middle layer, Bottom layer を表す.	34
4.1	導体箔形状の微細な変化による特性の変化. すこしの形状の変化で特性が大きく変化していることがわかる. [40] ©2025 IEICE	38
4.2	代替モデルの予測誤差に起因する誤誘導	38
4.3	提案法で用いる二つの DNN [40] ©2025 IEICE	40
4.4	精度予測器の作成手順	40
4.5	従来法と提案法の最適設計手法. 本研究では二通りの手法を提案している.	41
4.6	事前最適化の最適化モデル (MSBPF) [24] ©2024 IEEE	42
4.7	事前最適化のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している. [24] ©2024 IEEE	42
4.8	事前最適化の結果. 上段は設計領域の導体箔形状を表し, 下段はその S パラメータを表す. [40] ©2025 IEICE	43
4.9	代替モデルの CNN 構造 [40] ©2025 IEICE	43
4.10	代替モデルの学習の損失曲線 [40] ©2025 IEICE	44
4.11	テストデータに対して S パラメータを予測した結果 [40] ©2025 IEICE	44
4.12	事前最適化により生成されたデータセットの分布	45
4.13	代替モデルによる特性の予測が成功した例	45
4.14	代替モデルによる特性の予測が失敗した例	46
4.15	データセットサイズの増加による代替モデルの精度向上 [40] ©2025 IEICE	46
4.16	精度予測器の CNN 構造 [40] ©2025 IEICE	46
4.17	精度予測器の学習の損失曲線 [40] ©2025 IEICE	47
4.18	テストデータに対して代替モデルの RMSE を予測した結果	47
4.19	提案法 (ii) の最適化結果. S パラメータは測定結果, 代替モデルによる予測結果および FEA により再解析した結果を比較している. [40] ©2025 IEICE	49
5.1	さまざまな ζ の値のプレイヒステロン [60], CC BY	53
5.2	台形近似による磁気エネルギーの計算 [60], CC BY	54
5.3	磁気ヒステリシスに関する性質 [60], CC BY	55
5.4	提案するヒス損解析手法の概要 [60], CC BY	56
5.5	最適化モデル ($a = 4$ mm $b = 20$ mm, $c = 12$ mm, $d = 11$ mm) [60], CC BY	57
5.6	最適化モデルの磁性体コアの初磁化特性 [64, 65], [60], CC BY	58

5.7	インダクタの等価回路 [60], CC BY	58
5.8	インダクタの入力電圧とコイル電流 [60], CC BY	58
5.9	FEM により解析した磁性体コアにおける磁束密度分布 ($t = 2.93 \mu\text{s}$) [60], CC BY	59
5.10	各有限要素から抽出した磁束密度波形 [60], CC BY	59
5.11	プレイモデルで計算した BH 曲線 [64, 65], [60], CC BY	60
5.12	磁気エネルギーを予測する NN の構造 [60], CC BY	60
5.13	学習時の損失曲線 [60], CC BY	61
5.14	テストデータに対する磁気エネルギーの予測結果 [60], CC BY	62
5.15	図 5.10 の波形に対して従来法と提案法でヒス損解析した結果 [60], CC BY	62
5.16	異なる D に対するインダクタのコイル電流波形 [60], CC BY	63
5.17	異なる D から得られた磁束密度波形 [60], CC BY	64
5.18	損失曲線	64
5.19	異なる波形に対してヒス損を計算した結果 [60], CC BY	65
5.20	インダクタの最適化モデル	65
5.21	FEM により得られた磁束密度波形	66
5.22	損失曲線	67
5.23	テストデータに対する磁気エネルギーの予測結果	67
5.24	図 5.21 の波形に対して従来法と提案法でヒス損解析した結果	68
5.25	目的関数 F の収束履歴	69
5.26	磁性体コアのヒス損分布（再解析）.	69
5.27	最適化に要する時間の内訳	70
A.1	平行結合線路帯域通過フィルタ（PC-BPF）の構造 [24] ©2024 IEEE	85

表 目 次

2.1	AREX/JGG のパラメータの推奨値 [7] (n を最適化変数の次元とする)	12
3.1	周波数関連の設定	20
3.2	最適化設定	20
3.3	従来法で設計した MSBPF との比較 ©2024 IEEE	23
3.4	周波数関連の設定	25
3.5	最適化設定 [30] ©2024 IEEE	25
3.6	通過帯域の設定 [31]	27
3.7	周波数関連の設定	27
3.8	最適化設定 [30] ©2024 IEEE	29
3.9	最適化結果	30
3.10	周波数関連の設定	33
3.11	最適化設定	33
4.1	事前最適化の最適化設定 [24] ©2024 IEEE	42
4.2	解析設定	43
4.3	代替モデルの学習設定 [40] ©2025 IEICE	44
4.4	精度予測器の学習設定 [40] ©2025 IEICE	46
4.5	最適化の通過帯域の設定 [40] ©2025 IEICE	48
4.6	従来法と提案法の最適化結果の比較 (異なる乱数シードで 6 回実行した平均値) [40] ©2025 IEICE	48
5.1	最適化モデル	57
5.2	磁束密度分布の解析設定	58
5.3	プレイモデルの設定	59
5.4	磁気エネルギーを予測する NN の学習設定 [60], CC BY	61
5.5	ヒス損解析に要する時間	63
5.6	最適化設定	68
5.7	最適化結果	68

5.8	最適化過程において一個体あたりの評価に要する時間	70
5.9	最適化時間（波形抽出処理を無視）.	71
5.10	予測器の作成時間も考慮した最適設計の所要時間（波形抽出処理を無視）. . .	71
A.1	プロトタイプフィルタの素子値	86
A.2	調整後の信号ライン寸法 [24] ©2024 IEEE	86

第 1 章

序論

1.1 研究背景

情報化社会の進展に伴って通信トラフィックが急速に増大しており、ネットワーク機器の高性能化、小型化が要求されていることから、無線通信に使われるマイクロ波回路の新たな設計手法が必要とされている。本研究ではマイクロ波回路の中でも基本的な要素であり応用範囲の広いマイクロストリップライン（MSL: microstrip line）で構成される回路を対象とする。従来の設計では集中定数素子からなる回路を出発点として等価な回路パターンに段階的に変換し、最後に寸法を調整する方法がとられることが多い。しかしこの方法では多数の極をもつ高次の特性を実現しようとする回路サイズが大きくなってしまいうえに、回路を小型化しようするとパターン間に望まない磁気結合が生じて設計が難しくなる問題がある。

電磁デバイスの設計では、目標の特性と電磁界シミュレーションで計算した特性の差を目的関数として定義し、これを最小化する形状を求めることで設計を行う最適設計のアプローチがよく用いられる。最適設計の一手法であるトポロジー最適化（TO: topology optimization）は寸法の変化だけでなく穴の生成や消滅も許容する高い自由度の設計が可能であり、革新的な構造を見出すことができる。モータや非接触給電装置、アンテナ等の設計に対して TO の有効性が示されているが、MSL で構成される回路への適用例は少なくその有効性は不明である。また最適設計、特に進化計算を用いた手法は集団探索により最適な形状を探索するため多数の電磁界シミュレーションが必要であり、大域的な探索が可能な代わりにその計算コストが問題となっている。

電気電子機器の小型化のためにインダクタやモータなどのデバイスが高周波化しており、周波数に比例して増加するヒステリシス損失（ヒス損）を正確に考慮した設計が重要となっている。ヒス損を正確に求めるには、プレイモデルなどの磁気ヒステリシスモデルを用いてヒステリシス曲線上の状態遷移を追いかけて数値積分を実行する必要があるが、近似式を用いた簡便な解析手法と比べて計算コストが大幅に増大する。したがって多数のヒス損解析が必要となるインダクタやモータなどの最適設計ではヒス損解析の計算コストの増大が問題となる。

上記の最適設計における計算コストの問題に対処するために、時間のかかる計算を機械学習

により置き換える代替モデル法が知られており、トポロジー最適化では永久磁石モータの設計に適用された例などが報告されている。MSL で構成されるフィルタ回路については、信号ライン形状の微細な変化によってその特性が急激に変化するため、高精度な代替モデルの作成が難しいことが指摘されている。時間のかかるかかる計算を単純に置き換えるだけの典型的な代替モデル法に基づく最適化手法では、代替モデルによって特性を精度よく予測できることが前提となっている。したがって精度が不十分な代替モデルで最適化を実行すると、予測誤差に起因して最適化が誤った方向に進んでしまう誤誘導が発生し、最適化が失敗してしまう問題がある。

1.2 研究目的

本研究では電磁デバイス、特にマイクロ波回路と電気機器を対象にその最適設計の高度化（TO 法の開発および高速化）を目的とし、以下の 3 つの課題を考える。

1. マイクロ波回路へのトポロジー最適化の適用例が少なく、その有効性は不明である
2. マイクロ波のフィルタ回路はその特性の正確な予測が難しく、MSL 回路の TO に典型的な代替モデル法が適用できない
3. ヒステリシス特性を正確に考慮できる既存のヒス損解析手法は実行に時間を要するため、最適設計などの多数のヒス損解析が必要な際に問題となる

上記の課題を解決するために、本研究では以下の 3 つの手法について提案・検討する。

- マイクロストリップラインのトポロジー最適化
- 精度予測に基づく代替モデル法によるトポロジー最適化の高速化
- 機械学習を用いたヒステリシス損失の高速解析

1.2.1 マイクロストリップラインのトポロジー最適化

1. の課題を解決するために、MSL で構成されるフィルタ回路および電力分配回路を TO により設計し、その有効性を検証する。本研究ではガウス基底関数法（NGnet 法）および幾何射影法の二つの TO 手法を検討する。前者は電磁デバイスの TO、後者は梁などの構造力学の分野の TO に用いられる手法であり、両者ともに MSL 回路にははじめて適用する。はじめに NGnet 法でマイクロ波の帯域通過フィルタ回路と電力分配回路を設計し、前者については従来法で設計した結果との比較および実測により有効性を検証する。次に幾何射影法をベースとした TO 手法で同様に帯域通過フィルタの設計、測定を行う。最後に両手法を比較する。

1.2.2 精度予測に基づく代替モデル法によるトポロジー最適化の高速化

2. の課題を解決するために、代替モデルの精度を予測する手法およびそれを用いた最適設計手法を提案する。提案法では深層学習により代替モデルの精度を予測し、その予測結果に基づいて電磁界解析と代替モデルを切り替えて最適設計を行う。代替モデルおよび精度の予測には、画像認識など広い分野で用いられる深層学習、特に畳み込みニューラルネットワーク（CNN: convolutional neural network）を使用する。提案法の有効性は、代替モデルを使用しない TO、および典型的な代替モデル法による TO との比較により検証する。

1.2.3 機械学習を用いたヒステリシス損失の高速解析

3. の課題を解決するために、機械学習により電磁デバイスのヒス損解析を高精度かつ高速に実行する手法を提案する。ヒステリシス特性は入力波形の極値によって特徴づけられるという性質を利用し、提案法では入力波形を極値で分割した区間ごとに代替モデルを適用する。代替モデルはその汎用性の高さからニューラルネットワーク（NN: neural network）により作成する。代替モデルの学習には、プレイモデルを用いてヒステリシス特性を考慮して解析した磁気エネルギーを使用し、入力波形から磁気エネルギーを直接予測する。提案法の有効性は、ヒス損を考慮したインダクタの最適設計により検証する。

1.3 本論文の構成

以下に本論文の構成を示す。

第1章 序論

本研究の背景、目的、および本論文の構成について述べる。

第2章 最適設計手法

本研究の基本技術となる電磁デバイスの最適設計手法について述べる。はじめに従来からよく用いられているパラメータ最適化と、第3章で用いるトポロジー最適化について述べる。トポロジー最適化については勾配ベースの手法と確率ベースの手法に大別されるが、ここでは後者を扱う。次に最適設計に用いられる最適化アルゴリズムについて、制約の取り扱いと併せて述べる。

第3章 マイクロストリップラインのトポロジー最適化

進化計算を用いた MSL 回路の TO について述べる。二つの TO 手法を用いて MSL からなる帯域通過フィルタ回路および電力分配回路を設計する。

第4章 精度予測に基づく代替モデル法によるトポロジー最適化の高速化

MSL 回路の TO のための、精度予測に基づく代替モデル法について述べる．はじめに CNN ベースの代替モデルによる反射特性の予測と、正確な特性予測の難しさについて述べる．次に代替モデルの精度を予測する精度予測器について述べ、最後に精度予測器を利用した TO 手法について述べる．

第5章 機械学習を用いたヒステリシス損失の高速解析

プレイモデルを用いたヒス損解析を NN によって高速に実行する手法について述べる．はじめに本研究で磁気ヒステリシスモデリングに用いるプレイモデルについてその概要を簡単に述べる．次に提案するヒス損解析手法について述べ、数値シミュレーションの結果を示す．最後に提案法を用いたインダクタの最適設計について述べる．

第6章 結論

本研究の成果と今後の展望を述べる．

第 2 章

最適設計手法

2.1 はじめに

トポロジー最適化 (TO: topology optimization) は橋梁などの構造物やモータなどの電気機器の最適設計に広く用いられる。事前に構造を定めてその寸法パラメータを最適化するパラメータ最適化 (PO: parameter optimization) に対して、TO は寸法だけでなくトポロジーの変化 (穴の生成や消滅など) も許容するため形状表現の自由度が高く、設計者が想像していなかったような革新的な形状が発見できる。

TO の手法は様々なものが提案されているが、設計変数の最適化手法によって勾配を用いた手法 [1] と進化的アルゴリズムを用いた手法の二つに大別できる。前者は計算コストが低い代わりに局所解に陥りやすい、後者は大域的な探索が可能な代わりに計算コストが高いといった特徴がある。2.2 節では後者の手法のうち、特にガウス基底関数法および幾何射影法について述べる。設計変数を最適化する手法については、進化的アルゴリズムに着目して 2.3 節で述べる。

2.2 トポロジー最適化

本節で述べる TO 手法では設計領域を多数の小さな要素 e に分割し、各要素の材料 M_e を定めることで設計対象の形状を表現する。ここでは二種類の材料を考え、それぞれ material 1, material 2 と表記する^{*1}。以降、要素 e の中心座標を $\mathbf{x}_e$ で表す。本節で述べる手法で設計対象の形状の表現方法を定めた後に、目的関数が最小となる形状を探すことで TO が実現される。

^{*1} たとえばマイクロストリップラインであればそれぞれ空気と導体に相当する。




図 2.1: NGnet 法の概要

2.2.1 ガウス基底関数法 (NGnet 法)

ガウス基底関数法 (NGnet 法^{*2}) では (2.1) により形状を表現する [2,3].

$$M_e(\mathbf{w}) = \begin{cases} \text{material 1,} & y(\mathbf{x}_e, \mathbf{w}) \geq 0 \\ \text{material 2,} & \text{otherwise} \end{cases} \quad (2.1)$$

$$y(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^N w_i b_i(\mathbf{x}) \quad (2.2)$$

$$b_i(\mathbf{x}) = \frac{G_i(\mathbf{x})}{\sum_{j=1}^N G_j(\mathbf{x})} \quad (2.3)$$

$$G_i(\mathbf{x}) = \frac{1}{2\pi\sigma^2} \exp \left\{ -\frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{x}_i\|^2 \right\} \quad (2.4)$$

ここで, b_i は (2.3) で定義される規格化されたガウス基底関数 (以降, 単に基底関数と呼ぶ) であり, N は基底関数の個数, σ と $\mathbf{x}_i$ はそれぞれガウス関数 G_i の標準偏差と平均を表す. N , σ , $\mathbf{x}_i$ は NGnet 法におけるハイパーパラメータであり, 最適化を実行する前に決めておく. y は形状関数と呼ばれ, $\mathbf{w} = (w_1, \dots, w_N)$ を重みとした基底関数 b_i の線形結合によって (2.2) で定義される. 形状関数 y および設計領域の形状は $\mathbf{w}$ によって定まるため, TO の際には $\mathbf{w}$ を設計変数として最適化する. 形状が定まる過程を図 2.1 に示す. NGnet 法では滑らかに変化する形状関数 y を使用するため, 滑らかで製造可能性の優れた形状が得られやすいといった特徴がある. また, ここでは二種類の材料を考えているが, 三種類以上の材料に拡張することも可能である [3].

^{*2} Normalized Gaussian network




図 2.2: 幾何射影法の概要. 離散要素として円を採用した場合の例.

2.2.2 幾何射影法 (geometry projection method)

幾何射影法では離散要素と呼ばれる単純な図形を設計領域に複数配置し、それらの大きさや位置に関するパラメータを最適化することにより TO を実現する [4]. もともとは勾配法の使用を前提に提案された手法だが、進化的アルゴリズムを使用した TO にも適用されている [5]. 本節では進化的アルゴリズムを用いる文脈で幾何射影法について述べる.

幾何射影法では (2.5) により形状を表現する.

$$M_e(\mathbf{p}) = \begin{cases} \text{material 1,} & \mathbf{x}_e \in \mathcal{D} \\ \text{material 2,} & \text{otherwise} \end{cases} \quad (2.5)$$

ここで、 $\mathcal{D}$ は離散要素の和集合を表す. $\mathbf{p}$ は離散要素を特徴づけるパラメータであり、TO の際の設計変数となる. たとえば図 2.2 のように離散要素として N 個の円を考える場合、 x と y をそれぞれ円の中心座標、 r を円の半径として $\mathbf{p} = (x_1, y_1, r_1, \dots, x_N, y_N, r_N)$ のように定義する方法が考えられる. 式 (2.5) はいずれかの離散要素の内部に含まれる要素は material 1 に、そうでないものは material 2 に設定すると言い換えることができる.

2.3 最適化アルゴリズム

本節では進化的アルゴリズムを用いた最適化について述べる.

進化的アルゴリズム (EA: evolutionary algorithm) は人工知能の一分野であり、確率ベースの集団探索により近似解を得ることを目的とした最適化アルゴリズムの総称である. EA では解の候補点を複数用いて目的関数を最小化 (最大化) する解を探索する. EA の文脈では解の候補点を**個体 (individual)**、その集合を**集団 (population)**と呼ぶ. EA による最適化は図 2.3 に示す通り、終了条件を満たすまで個体の性能評価 (目的関数の計算) と集団の更新を繰り返す. 集団の更新では、個体の性能評価の結果に基づいてより優れた解が存在しそうな方向に集団を移動させる. この際に乱数を用いることで解の悪化が許容されるため局所解に陥りづらく、大域的な探索が可能となる. さまざまな EA が提案されているが、本節では TO で頻繁に用いられる遺伝的アルゴリズムと共分散行列適応進化戦略について述べる. 両者の違いは集団




図 2.3: 進化的アルゴリズムによる最適化の流れ

の表現方法と集団の更新方法にある。

2.3.1 正規分布

EA で頻繁に登場する正規分布について、その基礎事項を述べる。正規分布は確率密度関数が (2.6) の形で与えられる確率分布である。

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n \det \Sigma}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\} \quad (2.6)$$

ここで、 n は次元 (変数の数) を表し、 $\boldsymbol{\mu}$ は $\mathbf{x}$ の平均 (期待値)、 Σ は分散共分散行列である。確率変数 $\mathbf{x}$ が (2.6) の正規分布に従うとき

$$\mathbf{x} \sim \mathcal{N}(\boldsymbol{\mu}, \Sigma) \quad (2.7)$$

と表す。特に n を限定しない場合は多変量正規分布と呼ばれる。式 (2.6) において、確率変数 $x_1, \dots, x_n$ が独立であり、同じ分散 σ^2 を持つとき、 $\Sigma = \sigma^2 \mathbf{I}$ ($\mathbf{I}$ は単位行列) となる。このとき、1 変数および 2 変数の正規分布は

$$f(x_1) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(x_1 - \mu_1)^2}{2\sigma^2} \right\} \quad (2.8)$$

$$f(x_1, x_2) = \frac{1}{2\pi\sigma^2} \exp \left\{ -\frac{(x_1 - \mu_1)^2 + (x_2 - \mu_2)^2}{2\sigma^2} \right\} \quad (2.9)$$

となり、その分布は図 2.4 になる。 $\mathbf{x} = \boldsymbol{\mu}$ で最大値をとり、そこから離れるにつれて滑らかに減少していく分布であることがわかる。

2.3.2 遺伝的アルゴリズム

遺伝的アルゴリズム (GA: genetic algorithm) は自然界における生命の進化から着想を得た EA である。GA は下記の手順を繰り返すことで進行する。




図 2.4: 正規分布

1. 複製選択 (reproduction) : 集団から個体を選択する
2. 交叉 (crossover) : 選択した複数の個体から新たな個体を生成する
3. 生存選択 (survival selection) : 増えた個体を規定の数まで減らす

複製選択と生存選択は合わせて世代交代モデルと呼ばれる。GA はさまざまなバリエーションがあるが、ここでは実数値関数を対象とする実数値 GA、特に世代交代モデルとして JGG^{*3}、交叉オペレータとして AREX^{*4} を用いる AREX/JGG について述べる。

世代交代モデル JGG

JGG を下記に示す [6]。親個体群と子個体群が完全に入れ替わるのが特徴。

複製選択 集団から n_p 個の個体をランダムに非復元抽出して、交叉に用いる親個体群とする

子個体の生成 親個体群に対し交叉を繰り返し適用して、 n_c 個の子個体を生成する

生存選択 子個体群から評価値が上位の n_p 個の個体を選び、集団に加える

交叉オペレータ (REX と AREX)

段階的な説明のために、AREX の前に REX^{*5} について述べる。REX を下記に示す。

^{*3} Just generation gap

^{*4} Adaptive real-coded ensemble crossover

^{*5} Real-coded ensemble crossover




図 2.5: 稜構造を持つ関数の例 (Rosenbrock 関数)

REX [6, 7]

式 (2.10) にしたがって子個体 $\mathbf{x}_i$ を n_c 個生成する.

$$\mathbf{x}_i = \mathbf{m} + \sum_{j=1}^{n_p} \epsilon_{i,j} (\mathbf{y}_j - \mathbf{m}), \quad \epsilon_{i,j} \sim \varphi(0, 1/(n_p - 1)) \quad (2.10)$$

$$\mathbf{m} = \frac{1}{n_p} \sum_{j=1}^{n_p} \mathbf{y}_j \quad (2.11)$$

ここで, $\mathbf{y}_j$ は親個体, n_p は親個体の数, n_c は子個体の数, φ は平均 0, 分散 $1/(n_p - 1)$ の任意の対称な確率分布を表す*6.

REX では親個体群の重心 $\mathbf{m}$ を中心として, 親個体により囲まれる領域に乱数で子個体を生成するため, 集団分布の内部を重点的に探索することになる. このような交叉オペレータを用いると移動中に集団が初期収束を起こしやすく, 適用する問題によっては探索が困難になる場合がある. REX による探索が難しい例として, 稜構造 (ridge structure) がある. 稜構造は図 2.5 のように細長く湾曲した谷の形をしており, このような問題に対して集団は比較的長い重心移動を必要とする.

上記のような問題に対応するために, REX に対して改良を加えた AREX が提案されている. AREX では集団の初期収束を防ぐために拡張率適応と交叉中心降下の二つの考え方を導入する. 前者は 2.3.3 節で述べる CMA-ES から, 後者は REX の派生の一つである REX^{star} [6] から着想を得ている. AREX を下記に示す.

*6 子個体群の分散共分散行列は $\frac{1}{n_p-1} \sum_{j=1}^{n_p} (\mathbf{y}_j - \mathbf{m})(\mathbf{y}_j - \mathbf{m})^T$ であり, これは不偏分散の意味での親個体群の分散共分散行列に他ならない. したがって φ の分散を $1/(n_p - 1)$ とすることで, 親個体群と子個体群の間で統計量が遺伝する [7]. なお, 標本分散の意味で統計量を遺伝させる定義も存在する [6].

AREX [7, 8]

1. 式 (2.12) にしたがって子個体 $\mathbf{x}_i$ を n_c 個生成する.

$$\mathbf{x}_i = \mathbf{m}' + \alpha \sum_{j=1}^{n_p} \epsilon_{i,j} (\mathbf{y}_j - \mathbf{m}), \quad \epsilon_{i,j} \sim \mathcal{N}(0, \sigma^2) \quad (2.12)$$

$$\mathbf{m} = \frac{1}{n_p} \sum_{j=1}^{n_p} \mathbf{y}_j \quad (2.13)$$

$$\mathbf{m}' = \sum_{j=1}^{n_p} w_j \mathbf{y}_{j:n_p} \quad (2.14)$$

$$w_j = \frac{2(n_p + 1 - j)}{n_p(n_p + 1)} \quad (2.15)$$

ここで, α は拡張率, $\mathbf{y}_j$ は親個体, n_p は親個体の数, n_c は子個体の数, $(j : n_p)$ は上位 j 番目に評価値の良い親個体のインデックス, $\mathcal{N}$ は平均 0, 分散 σ^2 の正規分布を表す.

2. 式 (2.16) にしたがって拡張率 α を更新する.

$$\alpha \leftarrow \max \left(\alpha \sqrt{(1 - c_\alpha) + c_\alpha \frac{L_{\text{cdp}}}{L_{\text{avg}}}}, 1 \right) \quad (2.16)$$

$$L_{\text{cdp}} = \alpha^2 (n_p - 1) \left(\sum_{j=1}^{n_p} \bar{\epsilon}_j^2 - \frac{1}{n_p} \left(\sum_{j=1}^{n_p} \bar{\epsilon}_j \right)^2 \right) \quad (2.17)$$

$$L_{\text{avg}} = \frac{\alpha^2 \sigma^2 (n_p - 1)^2}{n_p} \quad (2.18)$$

$$\bar{\epsilon}_j = \frac{1}{n_\alpha} \sum_{i=1}^{n_\alpha} \epsilon_{i:n_c,j} \quad (2.19)$$

ここで, c_α は学習率, n_α は後述する CDP に利用する子個体数, $(i : n_c)$ は上位 i 番目に評価値の良い子個体のインデックスを表す.

式 (2.10) と (2.12) を比較すると大きな相違点が二つある. 一つ目は第一項が親個体の重み付き重心 $\mathbf{m}'$ になっている点である. 式 (2.15) で定義される $\mathbf{m}'$ の重み係数は評価値のよい親個体ほど大きくなっており, これは交叉中心が有望な領域に移動することを意味する. 二つ目は第二項に拡張率 α が導入されている点である. 拡張率には L_{cdp} に基づいて探索範囲の広さを調整する役割がある. 簡単のために $\max$ を無視して $c_\alpha = 1$ とすると, (2.16) は次式になる.

$$\alpha \leftarrow \alpha \sqrt{L_{\text{cdp}} / L_{\text{avg}}} \quad (2.20)$$

ここで, $\langle \mathbf{x} \rangle_{n_\alpha}$ を評価値上位 n_α 個の子個体の重心とすると CDP^{*7} は $\langle \mathbf{x} \rangle_{n_\alpha} - \mathbf{m}$ で定義され, そ

^{*7} crossover descent path

表 2.1: AREX/JGG のパラメータの推奨値 [7] (n を最適化変数の次元とする)

交叉に参加する親数	$n_p = n + 1$
生成子個体数	$n_c = 4n (\approx 4n_p)$
乱数の分散	$\sigma^2 = 1/(n_p - 1)$
初期拡張率	$\alpha^{(0)} = 1$
学習率	$c_\alpha = 1/5n$
利用する子個体数	$n_\alpha = n_p$

の長さの二乗として L_{cdp} が定義される^{*8}。 L_{cdp} が大きいとき、有望な領域 $\langle \mathbf{x} \rangle_{n_\alpha}$ は現在の集団分布 $\mathbf{m}$ から離れた場所にあり、逆に L_{cdp} が小さいとき、現在の集団分布は有望な領域を捉えられていると解釈できる。この考え方に基づいて (2.20) では、 L_{cdp} が大きいときは拡張率を大きくして探索範囲を広げ、 L_{cdp} が小さいときは拡張率を小さくして探索範囲を狭める。ベンチマーク関数を用いた実験により、AREX を用いることで探索効率の向上および REX では難しかった稜構造関数等への有効性が示されている [7]。

AREX/JGG において n_p, n_c, c_α などさまざまなパラメータが存在するが、適用する対象に応じてそれらのパラメータをチューニングすることで高い探索性能を発揮し得る。しかしそれは使用者からすると大きな負担になるため、表 2.1 に示す推奨値が与えられている。

2.3.3 共分散行列適応進化戦略 (CMA-ES)

共分散行列適応進化戦略 (CMA-ES: covariance matrix adaptation evolution strategy) は正規分布を用いた集団探索アルゴリズムであり、正規分布の共分散行列を学習する。CMA-ES は個体群を多変量正規分布 $\mathcal{N}(\mathbf{m}, \sigma^2 \mathbf{C})$ から生成し、上位個体群を用いて $\mathbf{m}, \sigma, \mathbf{C}$ を更新する。ここで、 $\mathbf{m}, \sigma, \mathbf{C}$ はそれぞれ探索分布の平均値、ステップサイズ、共分散行列である。2.3.2 節で述べた GA では集団を構成する個体群を保持するが、CMA-ES では多変量正規分布 $\mathcal{N}(\mathbf{m}, \sigma^2 \mathbf{C})$ のパラメータを保持する。CMA-ES の大きな利点は目的関数の評価回数の少なさにある。GA では最適化変数の次元 n に比例した回数 of 評価が必要だが、CMA-ES で必要な評価回数は $O(\log n)$ であり、 n が大きくなるとその差は顕著になる。

CMA-ES にはいくつかバリエーションがあるが、 $(\mu/\mu_w, \lambda)$ -CMA-ES [9] が現在最もよく用いられている。したがって本節でも $(\mu/\mu_w, \lambda)$ -CMA-ES について述べる。以降、 $(\mu/\mu_w, \lambda)$ -CMA-ES を単に CMA-ES と呼ぶ。CMA-ES のおおまかな流れを以下に示す。

^{*8} CDP の長さとしてマハラノビス距離を用いることで (2.17), (2.18) が導出される [7]。

1. 探索分布にしたがって個体 $\mathbf{x}_i$ を生成
 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_\lambda \sim \mathcal{N}(\mathbf{m}, \sigma^2 \mathbf{C})$
2. 個体を評価（目的関数 f の値を計算）
 $f(\mathbf{x}_1), f(\mathbf{x}_2), \dots, f(\mathbf{x}_\lambda)$
3. 探索分布のパラメータを更新
 update $\mathbf{m}, \sigma, \mathbf{C}$
4. 終了条件を満たしていれば終了，満たしてなければ1に戻る．

上記の処理において，事前に設定すべきパラメータは以下の3つである．

- 個体数 λ
 $\lambda \geq 4 + \lfloor 3 \ln n \rfloor$ が推奨されている（ n は最適化変数の次元）．実際の問題では $\lambda = 4 + \lfloor 3 \ln n \rfloor$ としてしまうと個体数が足りず，十分な探索が行えない可能性があるため，計算コストとの兼ね合いを見ながらできるだけ大きな値を設定するとよい．
- 探索分布の平均値（中心）の初期値 $\mathbf{m}_0$
 最適解が初期探索区間 $[a, b]^n$ の内部に存在すると想定できる場合， $[a, b]^n$ の範囲から一様乱数で $\mathbf{m}_0$ を選ぶと良いと推奨されている．
- ステップサイズ初期値 σ_0
 最適解が初期探索区間 $[a, b]^n$ の内部に存在すると想定できる場合， $\sigma = 0.3(b - a)$ とするのが推奨されている．

探索分布の更新

CMA-ES における探索分布のパラメータ $\mathbf{m}, \sigma, \mathbf{C}$ は (2.21), (2.22), (2.23) にしたがって更新される [9]．

$$\mathbf{m}^{(g+1)} = \mathbf{m}^{(g)} + c_m \sum_{i=1}^{\mu} w_i \left(\mathbf{x}_{i:\lambda}^{(g+1)} - \mathbf{m}^{(g)} \right) \quad (2.21)$$

$$\sigma^{(g+1)} = \sigma^{(g)} \exp \left\{ \frac{c_\sigma}{d_\sigma} \left(\frac{\|\mathbf{p}_\sigma^{(g+1)}\|}{E\|\mathcal{N}(0, \mathbf{I})\|} - 1 \right) \right\} \quad (2.22)$$

$$\begin{aligned} \mathbf{C}^{(g+1)} = & \left(1 - c_1 - c_\mu \sum_{i=1}^{\lambda} w_i \right) \mathbf{C}^{(g)} \\ & + c_1 \mathbf{p}_c^{(g+1)} \mathbf{p}_c^{(g+1)T} + c_\mu \sum_{i=1}^{\lambda} w_i \mathbf{y}_{i:\lambda}^{(g+1)} \left(\mathbf{y}_{i:\lambda}^{(g+1)} \right)^T \end{aligned} \quad (2.23)$$

ここで， g は世代番号を表す．探索分布の平均 $\mathbf{m}$ は (2.21) によって更新され，上位 μ 個の個体が更新に用いられる．ステップサイズ σ は (2.22) によって更新され，進化パスと呼ばれる $\mathbf{m}$ の変化の累積が用いられる．探索分布の共分散行列 $\mathbf{C}$ は (2.23) によって更新される．式 (2.23) の右辺第2項と第3項はそれぞれ rank-one update, rank- μ update を表している．rank-one update




図 2.6: ペナルティ関数により緩和された目的関数

は σ の更新と同様に進化パスが用いられる更新であり, rank- μ update は上位 μ 個の個体によって行われる更新である.

2.4 進化計算における制約の取り扱い

進化計算で最適設計を行う際にたとえば事前に定めた範囲内で最適な寸法を求めたい, といった状況が多々ある. 一方で多くの進化計算は制約無しの最適化アルゴリズムであるため, 制約を考慮できるように手を加える必要がある. 本節ではペナルティ関数を用いて進化計算で制約を取り扱う方法を述べる [9, 10].

説明のために (2.24) の最適化問題を考える.

$$\begin{aligned} & \text{minimize } f(x) \\ & x \in \mathbb{R}, f(x) \in \mathbb{R} \\ & \text{s.t. } x_l < x < x_r \end{aligned} \quad (2.24)$$

実際の最適化ではたとえば x が寸法, x_l, x_r がそれぞれ許容される寸法の最小値, 最大値, $f(x)$ が損失などの最小化したい物理量に相当する. x_l より大きく x_r より小さい範囲で $f(x)$ を最小化する x を求めたいが, 2.3 節で述べた最適化アルゴリズムのままでは制約を考慮できないため, (2.25) の緩和問題を考える.

$$\text{minimize } F(x) = \begin{cases} f(x), & x_l < x < x_r \\ g(x), & \text{otherwise} \end{cases} \quad (2.25)$$

ここで, $g(x) = \Delta + |x - x_0|$, $x_0 = (x_r + x_l)/2$ であり, Δ は制約を満たす $f(x)$ の上界である. 式 (2.25) では $f(x)$ をもとにあらたな目的関数 $F(x)$ を定義することで, 制約なしの最適化問題に緩和している. $F(x)$ の概形を図 2.6 に示す. x が制約を満たすときは $f(x)$, 満たさないときは $g(x)$ が目的関数として使用される. $g(x)$ は制約を満たす領域 (実行可能領域) の中心 x_0 で最小値 Δ をとり, x_0 からの距離に対して単調増加する関数である. したがって制約を満たさない個体が生成されても $g(x)$ の勾配により制約を満たす方向に進化が進み, いずれは制約を満たす解が得られると期待できる.

式 (2.25) の手法は (2.26), (2.27) のように多次元に拡張できる.

$$\begin{aligned} & \text{minimize} \quad f'(\mathbf{x}) \\ & \mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n, \quad f'(\mathbf{x}) \in \mathbb{R} \\ & \text{s.t.} \quad x_i^l < x_i < x_i^r, \quad i = 1, 2, \dots, n \end{aligned} \tag{2.26}$$

$$\begin{aligned} & \text{minimize} \quad F'(\mathbf{x}) = \begin{cases} f'(\mathbf{x}), & \mathbf{x} \text{ is feasible} \\ g'(\mathbf{x}), & \text{otherwise} \end{cases} \\ & g'(\mathbf{x}) = \Delta' + \sum_{i \in \text{infeasible}} |x_i - x_0^i| \end{aligned} \tag{2.27}$$

ここで, $\mathbf{x}_0 = (x_0^1, x_0^2, \dots, x_0^n)$ は実行可能領域の中心, Δ' は制約を満たす $f'(\mathbf{x})$ の上界である. 式 (2.27) 中の $i \in \text{infeasible}$ は最適化変数ベクトル $\mathbf{x}$ のうち, 制約を満たさない成分のインデックスを意味する.

2.5 まとめ

本章では電磁デバイスの最適設計に用いられる手法を TO に着目して述べた. 2.2 節では TO 手法のうち, 本研究で使用するガウス基底関数法および幾何射影法について述べた. 両者ともに EA と相性がよく, 勾配計算が不要で大域的な探索が可能な汎用性の高い TO 手法だが, 集団探索を行うため計算コストが問題となる. 2.3 節では最適な設計変数の値を求めるのに使用される最適化アルゴリズムについて, EA に着目して特に GA と CMA-ES について述べた. 両手法ともに前述の TO 手法に使用できるが, 本研究の最適設計では計算コストの観点から集団サイズを小さくできる CMA-ES を使用する. 2.4 節では設計変数の最小値と最大値で与えられる矩形制約を EA で扱う方法について簡単に述べた. この方法は第 3 章の幾何射影法による最適設計および第 5 章におけるインダクタの最適設計で使用される.

第 3 章

マイクロストリップラインのトポロジー最適化

3.1 はじめに

マイクロストリップ線路 (MSL: microstrip line) は板状の誘電体表面に線状の導体箔を形成した図 3.1 のような伝送路である。その構造の単純さから高周波回路において広く使われており、基地局においても重要な役割を担っている。情報化社会の進展に伴って通信トラフィックが急速に増大しており、ネットワーク機器の高性能化が要求されていることから、MSL 回路の新たな設計手法の開発が必要とされている。

トポロジー最適化 (TO: topology optimization) を用いた最適設計は高い自由度での形状表現が可能ため革新的な構造を見出すことができる。TO 手法は設計変数の勾配を用いる手法と、進化的アルゴリズムを用いる手法の二つに大別できる。前者の手法は最適化の収束が早い、局所的な最適性が保証される、計算コストが比較的低いといった長所があるが、局所解に陥りやすいという短所がある [11–14]。一方で後者の手法は計算コストが高い代わりに、広域探索




図 3.1: マイクロストリップラインの構造

が可能, 多目的最適化が容易, 勾配計算が不要といった長所がある [15]. 進化的アルゴリズムを用いる手法の中でも特にガウス基底関数法 (NGnet 法^{*1}) を利用した TO は材料境界が滑らかに変化する形状が得られやすい^{*2}という特徴があり, 永久磁石モータ [3, 16, 17] や非接触給電装置 [18], マイクロ波デバイス [19, 20] 等の設計に対してその有効性が示されている. しかしながら NGnet 法を MSL 回路の設計に適用した結果は報告されておらず, その有効性は不明である. そこで本章では一つ目の目的として NGnet 法による TO で MSL 回路を設計し, その有効性を確かめる.

MSL 回路の設計では狭い間隔をあけて導体を配置するギャップと, 細長い長方形の形をしたスタブと呼ばれる構造が重要であり, 頻繁に使用される [21, 22]. ギャップはキャパシタンスを発生させるため, スタブは共振器として動作させるために使用される. 一方で前述の NGnet 法では材料境界が滑らかに変化する形状が得られるという特徴がある. これは製造可能性の観点で有利なこともあるが, 一方で直線的な構造の表現は苦手なため細長い構造を含む形状の表現が難しいという問題がある. そこで本章では二つ目の目的として細長い構造を活用できる MSL 回路の TO 手法を提案する. 具体的には TO 手法の一つである幾何射影法 [4, 5]^{*3}を MSL 回路に適用する. 幾何射影法において離散図形を長方形とし, 回転は考えずに高さ, 幅, 位置のみを最適化することで, 上記の目標の達成を目指す.

なお, 本研究で取り扱うトポロジー最適化とは異なるが, ピクセルパターン最適化によるモザイク状素子の設計についてはベイズ最適化を用いた Direct Binary Search (DBS) 法が有効であることが示されている [23].

本章では MSL 回路として具体的にはマイクロストリップ帯域通過フィルタ (MSBPF: microstrip bandpass filter) とマイクロストリップ電力分配器 (MSPD: microstrip power divider) の二種類の回路を考える. 3.2 節では MSBPF を NGnet 法, 幾何射影法, および TO を使用せずに集中定数素子の等価回路を起点とする従来法の 3 つの手法により設計し, 結果を比較する. 3.3 節では通過帯域を二つもつ二重帯域 MSBPF を NGnet 法および幾何射影法により設計し, 結果を比較する. 3.4 節では MSPD を NGnet 法により設計し, NGnet 法の汎用性の高さを示す.

3.2 マイクロストリップ帯域通過フィルタの設計

3.2.1 問題設定

MSBPF はマイクロストリップラインで構成する帯域通過フィルタであり, 特定の範囲の周波数帯の信号のみを取り出すのに使用される. 最適化モデルを図 3.2 に示す. 最適化形状をもとに基板を作製, 測定するため製造可能性を考慮して最適化モデルを決定した. 誘電体の材料

*1 2.2.1 節を参照.

*2 製造可能性の観点で有利なことがある

*3 2.2.2 節を参照.




図 3.2: MSBPF の最適化モデル




図 3.3: MSBPF のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している.

は FR-4 を想定し, 電磁界解析での比誘電率と誘電正接は図中の値を使用した. ポートについては特性インピーダンスが 50Ω となるようにライン幅を決定した.

3.2.2 NGnet 法による設計

最適化の設定と結果

NGnet 法を用いた TO により MSBPF を設計する. 本最適化では (2.1) における material 1 および material 2 をそれぞれ (3.1) のように割り当てることで銅箔形状を表現する.

$$M_e(\mathbf{w}) = \begin{cases} \text{Conductor,} & y(\mathbf{x}_e, \mathbf{w}) \geq 0 \\ \text{Air,} & \text{otherwise} \end{cases} \quad (3.1)$$

ガウス基底の配置を図 3.3 に示す. 設計領域には対称制約を課しており, 半分の領域に 55 個のガウス基底を配置する. 本節で考える最適化問題を (3.2) に示す.

$$F_1(\mathbf{w}) = -\frac{1}{4} \sum_{f \in \text{passband}} \max(S_{11,\text{dB}}(f), -20)^2 + \sum_{f \in \text{stopband}} S_{11,\text{dB}}(f)^2 \rightarrow \min. \quad (3.2)$$

表 3.1: 周波数関連の設定

中心周波数	2.0 GHz
比帯域幅	40%
評価周波数	1.2~2.8 GHz
サンプリング間隔	0.1 GHz

表 3.2: 最適化設定

ガウス基底の標準偏差 σ	2.12 mm
設計変数の数	55
最適化アルゴリズム	CMA-ES
集団サイズ λ	16
世代数	200
設計領域の格子メッシュの数	18×20
設計領域の格子メッシュサイズ s	1.8×1.5 mm
平均値ベクトルの初期値 $\mathbf{m}_0$	$\mathbf{0}$
ステップサイズの初期値 σ_0	0.3




図 3.4: 目的関数 F_1 の収束履歴

ここで、 $\mathbf{w}$ は基底関数の重み、 $S_{11,\text{dB}}$ はデシベル形式の S パラメータの大きさ、 f はサンプリング周波数を表す。周波数関連の設定を表 3.1、最適化設定を表 3.2 に示す。集団サイズは CMA-ES の開発者によって提案されている推奨値を使用している [9]。

最適化を実行した結果、目的関数 F_1 は図 3.4 に示すとおり約 150 世代で収束した。最適化結果をもとに作製した MSBPF とその特性を図 3.5 に示す。 S パラメータについて、通過帯域で $S_{11,\text{dB}}$ が小さくなっているおり、BPF の特性が得られていることが確認できた。計算結果と測定結果はおおよそ一致している。ピークでずれが生じた要因としては製造時の誤差（寸法、比誘電率、誘電性正接）および、計算時に吸収境界により解析モデルを有限の大きさに切り捨てる際の誤差が考えられる。 S パラメータは図 3.6 のようにネットワークアナライザ (Agilent E5061B) により測定した。最適化形状の電界分布を図 3.7 に示す。通過帯域の周波数である図 3.7a では入力ポートに与えられた電界が出力ポートまで伝わっている一方で、阻止帯域の周波数である図 3.7b では与えられた電界が出力ポートで減衰している。このことから最適化形状が BPF として動作していることが確認できる。

NGnet 法と従来法の比較

NGnet 法の有効性を調べるために従来手法で設計した結果および他の論文と比較する。MSBPF を設計する手法はいくつか存在するが、最も基本的な実装である平行結合線路帯域通




図 3.5: 最適化結果をもとに作製した MSBPF とその特性 [24] ©2024 IEEE




図 3.6: S パラメータ測定の様子

過フィルタ (PC-BPF: parallel-coupled bandpass filter) を採用した [25–27]. PC-BPF の設計の詳細は付録 A を参照. 以降, 本節では NGnet 法を提案法, PC-BPF を従来法と呼ぶ.

提案法で得られた結果と同じ特性を示す MSBPF を従来法で設計した. その結果を提案法の結果と一緒に図 3.8 に示す. PC-BPF は図 3.8a のように, 信号ラインを狭い間隔で配置してライン間の磁気結合を積極的に利用する結合線路によって構成されている. 回路長は従来法が 114.0 mm, 提案法が 32.4 mm であり, 提案法によって回路の特性を維持したまま回路長を 72% 短縮することができた. PC-BPF では信号ラインを狭い間隔で配置するため寸法誤差が特性に与える影響が大きいと予想されるが, 一方で提案法の結果はそのような構造を持たないた




図 3.7: 最適化形状の電界分布

め製造可能性の観点でも優れている。

回路長，比帯域幅および平均挿入損失の三つの観点で提案法，従来法および他の論文 [28,29] の MSBPF を比較する．回路長はポート部を無視した長さを考える．比較するフィルタは周波数帯および比誘電率が異なるため，(3.3) で計算される誘電体中の電磁波の波長 λ を基準に比較する．

$$\lambda = \frac{1}{f_c \sqrt{\mu_0 \varepsilon_0 \varepsilon_r}} \quad (3.3)$$


ここで， f_c はフィルタの中心周波数， μ_0 は真空の透磁率 ($= 4\pi \times 10^{-7} [\text{H/m}]$)， ε_0 は真空の誘電率 ($= 8.854 \times 10^{-12} [\text{F/m}]$)， ε_r は誘電体基板の比誘電率を表す．比帯域幅 FBW は BPF の帯域幅を中心周波数 f_c との比で表した値であり，(3.4) で計算される．

$$\text{FBW} = \frac{f_h - f_l}{f_c} \quad (3.4)$$


ここで， f_l と f_h はそれぞれ BPF の低周波側と高周波側の遮断周波数を表しており， $S_{11,\text{dB}}$ と $S_{21,\text{dB}}$ が交差する周波数を計算に使用している．MSBPF の場合，一般に比帯域幅が大きくなるほど設計が難しくなる．最後に，平均挿入損失 IL_{ave} は (3.5) で計算される．

$$\text{IL}_{\text{ave}} = -\frac{1}{N} \sum_{f_i \in \text{passband}} T(f_i) \quad (3.5)$$


ここで， T はポート間の透過係数 ($= S_{21,\text{dB}}$)， f_i はサンプリング周波数， N は通過帯域内の周波数サンプリング点の数を表す．上述の指標値を各 MSBPF で計算した結果を表 3.3 にまとめる．提案法で設計した MSBPF は回路長の短さ，帯域幅の広さ，挿入損失の少なさで優位性があることがわかった．



(a) 導体箔形状（従来法）[24] ©2024 IEEE



(b) 導体箔形状（提案法）[24] ©2024 IEEE



(c) S パラメータ

図 3.8: 従来法（PC-BPF）と提案法（NGnet 法）で設計した MSBPF. 導体箔形状の二つの画像の縮尺は同じ（原寸ではない）. 青が導体箔, 白が空気を表す.

表 3.3: 従来法で設計した MSBPF との比較 ©2024 IEEE

	回路長 [mm]	比帯域幅 [%]	平均挿入損失 [dB]
	最小化	最大化	最小化
提案法 (図 3.8b)	32.4 (0.45 λ)	46.3	1.4
PC-BPF (図 3.8a)	114.0 (1.58 λ)	40.0	1.3
Four-pole PC-BPF [28]	119.3 (1.10 λ)	2.8	2.9
Cascade quadruplet filter [29]	14.5 (0.21 λ)	3.8	2.8




図 3.9: 幾何射影法を用いた MSBPF の最適化の概要 [30] ©2024 IEEE

3.2.3 幾何射影法による設計

幾何射影法を用いた TO により MSBPF を設計する．導体の形状は図 3.9 に示すように幾何射影法によって表現される．本最適化では (3.6) で表される N 個の長方形の離散要素を設計領域にランダムに配置する．

$$\mathbf{p} = (x_1, y_1, w_1, h_1, \dots, x_i, y_i, w_i, h_i, \dots, x_N, y_N, w_N, h_N) \quad (3.6)$$

ここで, x_i, y_i は離散要素の長方形の中心位置, w_i と h_i はそれぞれ長方形の幅と高さを表す．簡単のため, 要素の回転は本研究では考慮しない (もちろん必要があれば考慮できる)．次に要素 e の材料 M_e を (3.7) で決定する．

$$M_e(\mathbf{p}) = \begin{cases} \text{Air}, & \mathbf{x}_e \in \mathcal{D} \\ \text{Conductor}, & \text{otherwise} \end{cases} \quad (3.7)$$

ここで, $\mathbf{x}_e$ は要素 e の中心, $\mathcal{D}$ は離散要素の和集合を表す．図 3.9 にも示したように最初は設計領域全体を導体箔とし, $\mathbf{p}$ で表される離散要素を配置したときに $\mathbf{x}_e$ が $\mathcal{D}$ の内部に存在すればその要素を空気, それ以外の場合は導体とする．一般的な幾何射影法では離散要素の内部を導体などの物体とするが, 本研究では反対に離散要素の内部を空気とする．これは入力ポートと出力ポートが直流的に接続された形状を得られやすくするためである．最後に目的関数を最小化することで最適形状が得られる．この方法は直線的な構造の組み合わせで形状を表現できるため, 細長い構造を活用したマイクロ波回路の設計に適していると考えられる．




図 3.10: 制約条件 [30] ©2024 IEEE

表 3.4: 周波数関連の設定

中心周波数	2.0 GHz
比帯域幅	20%
評価周波数	1.2~2.8 GHz
サンプリング間隔	0.1 GHz

表 3.5: 最適化設定 [30] ©2024 IEEE

離散要素の数 N	10
設計変数の数	40
ペナルティ定数 Δ	$70^2 \times 17$
最適化アルゴリズム	CMA-ES
集団サイズ λ	15
世代数	200
設計領域の格子メッシュの数	432×400
設計領域の格子メッシュのサイズ s	$75 \mu\text{m}$

本項で考える最適化問題を (3.8) に示す.

$$F_2(\mathbf{p}) = \sum_{f \in \text{passband}} S_{21,\text{dB}}(f)^2 + \sum_{f \in \text{stopband}} S_{11,\text{dB}}(f)^2 \rightarrow \min. \quad (3.8)$$

$$s.t. \begin{cases} X_1 \leq x_i \leq X_2 \\ Y_1 \leq y_i \leq Y_2 \\ s \leq w_i \leq (X_2 - X_1)/2 \\ s \leq h_i \leq (Y_2 - Y_1)/2 \end{cases} \quad (i = 1, 2, \dots, N)$$

ここで, $S_{ij,\text{dB}}$ はデシベル形式の S パラメータの大きさ, f はサンプリング周波数, s はメッシュサイズを表し, X_1, Y_1 および X_2, Y_2 は図 3.10 に示すように矩形の設計領域の左下と右上の座標を表す. 離散要素が設計領域からはみでた部分は無視する. 本最適化では制約を取り扱うために (2.27) の手法を (3.8) に適用する. 周波数関連の設定を表 3.4, 最適化設定を表 3.5 に示す. 集団サイズ λ , CMA-ES の平均値ベクトル $\mathbf{m}$ およびステップサイズ σ の初期値は推奨値^{*4}を使用した. 設計領域の格子メッシュサイズ s は製造可能な最小のサイズとなるように設定した.

Intel®Xeon®W-2135, 3.70 GHz を使用して 4 並列で電磁界解析を実行した結果, 最適化に 17 時間 20 分かかった. 目的関数 F_2 の収束履歴を図 3.11, 最適化結果を図 3.12 に示す. 第 20 世代ごろから制約を満たす形状が生成され始め, その後 F_2 は急速に減少し, 最小値は 37.7 だった. これはペナルティ関数の効果によるものである. 図 3.12b に関して, 通過帯域で $S_{11,\text{dB}}$

^{*4} 2.3.3 項を参照.




図 3.11: 目的関数 F_2 の収束履歴 [30] ©2024 IEEE




図 3.12: MSBPF の最適化結果 [30] ©2024 IEEE

が反射率 0.1% を表す -30 dB 程度まで下がっており、BPF の特性が得られていることが確認できた。図 3.12a に関して、細長いライン構造、いわゆるスタブが左上に二個生成された。これは 3.2.2 節の NGnet 法による TO では得られにくい構造である。

上述のスタブの特性への寄与を調べるために、スタブを削除した形状と特性を比較する。最適化形状とスタブを削除した形状について、電界分布と S パラメータを図 3.13 に示す。電界分布に関して、スタブの先端に電解が集中しており、共振器として動作していることがわかる。右側に配置されている出力ポートに着目すると、スタブがない場合よりもある場合の方が電界を減衰できており、阻止帯域における BPF として望ましい動作をしていることがわかる。S パラメータに関してもスタブの削除することで通過帯域、および高周波側の阻止帯域において特性が悪化しており、スタブがある方がよい特性となっている。以上のことから幾何射影法により生成されたスタブ構造が特性に大きな影響を与えることが確かめられた。




図 3.13: 最適化形状とスタブを削除した形状の比較 [30] ©2024 IEEE

表 3.6: 通過帯域の設定 [31]

帯域 1	中心周波数 f_1	2.45 GHz
	比帯域幅 Δ_1	12 %
帯域 2	中心周波数 f_2	5.80 GHz
	比帯域幅 Δ_2	7 %

表 3.7: 周波数関連の設定

評価周波数	1.0 GHz ~ 8.0 GHz
サンプリング間隔	0.1 GHz

3.3 マイクロストリップ二重帯域通過フィルタの設計

3.3.1 問題設定

本項では通過帯域を二つ持つ、二重帯域通過フィルタ（二重帯域 BPF）をトポロジー最適化により設計する。目標とする通過帯域を表 3.6，周波数関連の設定を表 3.7 に示す。最適化モデルは 3.2.1 項と同様のものを使用する。本節で考える最適化問題を (3.9) に示す。

$$F_3(\mathbf{x}) = k \sum_{f \in \text{passband}} S_{21, \text{dB}}(f)^2 + \sum_{f \in \text{stopband}} S_{11, \text{dB}}(f)^2 \rightarrow \min. \quad (3.9)$$




図 3.14: NGnet 法と幾何射影法における設計変数 [30] ©2024 IEEE




図 3.15: 目的関数 F_3 の収束履歴 [30] ©2024 IEEE

ここで、 $\mathbf{x}$ は設計変数を表し、NGnet 法では基底関数の重み $\mathbf{w}$ 、幾何射影法では離散要素の形状パラメータ $\mathbf{p}$ に相当する。 k は重み係数であり、定数を設定する。本最適化では阻止帯域のサンプリング点の数が通過帯域の約 9 倍であり、(3.9) の第 1 項と第 2 項、すなわち通過帯域と阻止帯域が等しく評価されるように $k = 9$ とする。


3.3.2 NGnet 法および幾何射影法による設計

NGnet 法および幾何射影法を用いた TO により二重帯域 BPF を設計し、結果を比較する。NGnet 法は (3.1)、幾何射影法は (3.7) に基づいて導体形状を決定する。幾何射影法では (3.8) と同様の制約を課す。両手法の設計変数を図 3.14 に示す。NGnet 法の設計変数はガウス基底関数の重み係数、幾何射影法は離散要素の幾何学的パラメータ (x_i, y_i, w_i, h_i) であり、両手法ともに設計変数の数が 36 個となるように設定した。最適化設定を表 3.8 に示す。


目的関数 F_3 の収束履歴を図 3.15、最適化結果を図 3.16 および表 3.9 に示す。ただし、

表 3.8: 最適化設定 [30] ©2024 IEEE


	NGnet 法	幾何射影法
離散要素の数 N	–	9
ペナルティ定数 Δ	–	$70^2 \times 71$
ガウス基底の標準偏差 σ	3.85 mm	–
設計変数の数		36
最適化アルゴリズム		CMA-ES
集団サイズ λ		14
世代数		500
設計領域の格子メッシュの数		432×40
設計領域の格子メッシュのサイズ s		$75 \times 75 \mu\text{m}$




(a) 最適化形状 (NGnet 法)



(b) 最適化形状 (幾何射影法)



(c) S パラメータ (NGnet 法, $F_3 = 529$)



(d) S パラメータ (幾何射影法, $F_3 = 477$)

図 3.16: 最適化結果 (図 3.15 に対応) [30] ©2024 IEEE


表 3.9: 最適化結果 *

	NGnet 法	幾何射影法
最適化形状の F_3	617	546
最適化時間	83 時間 43 分	51 時間 44 分


* 異なる乱数シードで最適化を 5 回実行した結果の平均.

図 3.15 および図 3.16 の結果は異なる乱数シードで複数回最適化を実行した結果の一つであること、また表 3.9 における NGnet 法の結果および図 3.16c の計算結果については後述の理由から解析メッシュを細かく切りなおして再解析していることに注意されたい。最適化の計算では Intel®Xeon®W-2135, 3.70 GHz を使用し、市販の CAE (computer aided engineering) ソフトである Femtet® によって電磁界解析を 4 並列で実行した。図 3.15 に関して、最適化の序盤では NGnet 法の方が速く F_3 が減少しているが、最終的には表 3.9 に示すとおり幾何射影法の方が F_3 が小さくなっている。幾何射影法を使用することで F_3 が平均で 11.5 % 改善された。図 3.16c および図 3.16d に関して、両者ともに $S_{11,\text{dB}}$ のピークが二つの通過帯域中に生じており、二重帯域 BPF の特性を示している。幾何射影法により得られた図 3.16d の方がピーク間の $S_{11,\text{dB}}$ が平坦になっており望ましい特性となっている。計算結果と測定結果の誤差要因としては、製造誤差（銅箔の寸法、誘電率、基板厚み）および計算時のコネクタの効果の未考慮が挙げられる。図 3.17 に示す最適化形状の解析メッシュは Femtet® のアダプティブメッシュで生成しており、NGnet 法によって生成される形状は極端に扁平なメッシュが多く生成されている（図 3.17a, 図 3.17b）。NGnet 法の最適化結果に対してメッシュを細かくして再解析していると前述したが、それはこのためである。再解析時の細かいメッシュを図 3.17c に示す。扁平なメッシュが生成されてしまうのは材料境界が湾曲しているためである。扁平なメッシュが多い結果、電磁界解析の収束性が悪化し、表 3.9 において NGnet 法の方が最適化時間が長くなっている^{*5}。この問題に対処する方法として implicit domain meshing (IDM) [32] がある。IDM はレベルセット関数の等高線に沿ってメッシュを生成する手法であり、モータの TO に適用した結果が報告されている [33]。一方で直線的な構造からなる幾何射影法では極端に扁平なメッシュは生成されず、IDM のような特殊なメッシュ生成手法は不要である（図 3.17d）。


^{*5} 最適化時間の差の要因はメッシュ以外に、幾何射影法での制約の取り扱いにある。NGnet 法では CMA-ES により生成されたすべての個体に対して電磁界解析を実行するが、幾何射影法では (2.27) の手法を使うため制約を満たさない個体に対しては電磁界解析が実行されない。




(a) NGnet 法（最適化時），メッシュ数 14,671



(b) 図 3.17a の拡大図



(c) NGnet 法（再解析時），メッシュ数 43,760



(d) 幾何射影法，メッシュ数 4,435

図 3.17: 最適化形状の解析メッシュ（図 3.16a, 図 3.16b に対応）

3.4 マイクロストリップ電力分配器の設計

3.4.1 問題設定

MSPD は電力を分配するために用いられる回路であり，入力信号を複数のより小さな電力の出力信号に分配する．MSPD の最適化モデルを図 3.18 に示す [12]．本最適化モデルは二層の誘電体と三層の導体箔からなり，三つのポートを持つ．ポート 1 から入力した信号をポート 2 とポート 3 に等分配する動作を目指して設計する．設計領域は三層の 10 mm 四方の導体箔である．

3.4.2 NGnet 法による設計

NGnet 法を用いた TO により MSPD を設計する．ガウス基底の配置を図 3.19 に示す．設計




図 3.18: MSPD の最適化モデル [24] ©2024 IEEE




図 3.19: MSPD のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している. 三層とも同じ配置. [24] ©2024 IEEE

領域には対称制約を課しており, 各層の半分の領域に 18 個のガウス基底を配置するため, 設計変数は合計で 54 個となる. 本節で考える最適化問題を (3.10) に示す.

$$F_4(\mathbf{w}) = \sum_{f \in \text{passband}} 2 \left(S_{21,\text{dB}}(f)^2 + S_{31,\text{dB}}(f)^2 \right) + \sum_{f \in \text{stopband}} S_{11,\text{dB}}(f)^2 \rightarrow \min. \quad (3.10)$$

ここで, $\mathbf{w}$ は基底関数の重み, $S_{ij,\text{dB}}$ はデシベル形式の S パラメータの大きさ, f はサンプリング周波数を表す. 周波数関連の設定を表 3.10, 最適化設定を表 3.11 に示す. 目的関数 F_4 の収束履歴を図 3.20, 最適化結果を図 3.21 に示す. S パラメータについて, 目標の周波数帯域で $S_{21,\text{dB}}$ と $S_{31,\text{dB}}$ が -3dB の値とっている. これはポート 1 から入力された信号がポート 2 とポート 3 に等分割されていることを意味しており, 所望の特性が得られた. 最適化形状の電界分布を図 3.22 に示す. Bottom layer の上部に位置するポート 1 から入力された信号が Top layer まで伝わり, ポート 2 とポート 3 に分配されていることが図 3.22 から読み取れる.

表 3.10: 周波数関連の設定

中心周波数	4.0 GHz
比帯域幅	25 %
評価周波数	2.0~6.0 GHz
サンプリング間隔	0.2 GHz

表 3.11: 最適化設定

ガウス基底の標準偏差 σ	1.33 mm
設計変数の数	54
最適化アルゴリズム	CMA-ES
集団サイズ λ	15
世代数	80
設計領域の格子メッシュの数	10×10
設計領域の格子のメッシュサイズ	1×1 mm
平均値ベクトルの初期値 $\mathbf{m}_0$	$\mathbf{0}$
ステップサイズの初期値 σ_0	0.3




図 3.20: 目的関数 F_4 の収束履歴




図 3.21: MSPD の最適化結果. 青が導体箔, 白が空気を表す. [24] ©2024 IEEE




図 3.22: 最適化形状の電界分布 ($f = 4.2 \text{ GHz}$). 左から順に Top layer, Middle layer, Bottom layer を表す.

3.5 まとめ

本章では MSL 回路の設計に NGnet 法および幾何射影法を適用し、シミュレーションと試作回路の測定によりその有効性を検証した。

NGnet 法については MSBPF、二重帯域 MSBPF、MSPD の 3 種類の回路の設計に適用した。MSBPF については等価回路を起点とする従来法と比較した結果、回路長の短さ、帯域幅の広さ、挿入損失の少なさの観点で有利であることを確かめた。MSPD については信号を等分配するような所望の特性が得られた。以上から NGnet 法のマイクロ波回路への適用可能性および汎用性の高さが明かになった。一方で NGnet 法は湾曲した材料境界が得られるため解析メッシュが扁平になり、FEM の収束性および解析精度の観点で問題となる可能性がある。

MSBPF については NGnet 法と集中定数素子の等価回路による従来法の二つの手法で設計し、NGnet 法で設計した MSBPF については実際に回路を作製し、測定結果がシミュレーションと一致することを確認した。また、等価回路をベースとした従来法で設計した MSBPF と比較し、回路長の短さ、帯域幅の広さ、挿入損失の少なさの観点で有利であることを確かめた。さらに NGnet 法は MSBPF だけでなく MSPD の設計にも適用しており、NGnet 法を用いた設計手法の汎用性の高さを示した。一方で NGnet 法は湾曲した材料境界が得られるため、解析メッシュを非常に細かくしない限りは扁平なメッシュが生じてしまい、FEM の収束性および解析精度の観点で問題となる可能性がある。

幾何射影法についても MSBPF の設計に適用し、測定により設計の有効性を示した。幾何射影法ではスタブやギャップなどの細長い構造が得られており、シミュレーションによりそれらの構造が特性に大きく寄与していることを示した。これらの細長い構造は NGnet 法では得られない構造である。また、二重帯域の MSBPF については NGnet 法と比較して評価値および最適化速度の観点で優れているうえに、材料境界が直線的なため解析メッシュが扁平にならないことがわかった。

提案法では集団ベースの最適化アルゴリズムを使用するため電磁界解析の実行回数が多く、最適化に時間を要する。この問題については機械学習により最適化を高速化する手法を第 4 章で検討する。

第 4 章

精度予測に基づく代替モデル法によるトポロジー最適化の高速化

4.1 はじめに

第 3 章ではトポロジー最適化 (TO: topology optimization), 特にガウス基底関数法 (NGnet 法) や幾何射影法を用いた手法がマイクロストリップライン (MSL: microstrip line) で構成される回路の設計に有効であることを示した. これらの手法を進化的アルゴリズムと組み合わせて使用する場合, 性能評価のために有限要素解析 (FEA: finite element analysis) などによる電磁界解析を何度も実行する必要がある, 最適化の実行に時間を要するという問題がある. この問題の解決策の一つとして, 深層学習で作成した**代替モデル (surrogate model)**によって性能評価の処理を置き換えるアプローチがある [34–38]. 設計領域の材料分布などからその性能を正確に予測できる代替モデルを構築することができれば, 代替モデルの順方向計算は FEA よりも短時間で完了するため, 最適化を高速化できる.

しかしながら, MSL 回路の特性は導体箔形状の微細な変化によって大きく変化し得るため, 予測が難しいことが指摘されている [39]. MSL 回路の特性が急激に変化する例を図 4.1 に示す. 図 4.1a と図 4.1b は非常によく似た二つの形状を表しており, 図 4.1c はそれらの S パラメータを表している. これら二つの形状は二か所を除いて同一だが, その特性は大きく異なったものとなっており, 正確な性能予測を困難にしている. 事前に構造を定めてその寸法パラメータを最適化する PO とは異なり, TO ではこのような状況にたびたび遭遇する. したがって高精度な代替モデルを作成するには大量の学習データと計算コストが必要となる.

精度が不十分な代替モデルで最適化を実行すると, 図 4.2 に示すような誤誘導 (misleading) が問題となる. 図 4.2 のグラフは縦軸が性能, 横軸が設計変数 (形状) を表しており, 最適設計では性能が最も高くなる形状を探す. ただし性能を知るためには電磁界解析が必要であり, 愚直に実行すると時間がかかりすぎてしまう. そこで性能を予測する代替モデルを機械学習により作成し (図中の破線), 代替モデルを使って最適設計を行う. このとき, 代替モデルの精度が十分に高ければ実際の最適解に近い解が得られる (図 4.2a). 一方で代替モデルの予測精度




図 4.1: 導体箔形状の微細な変化による特性の変化. すこしの形状の変化で特性が大きく変化していることがわかる. [40] ©2025 IEICE




図 4.2: 代替モデルの予測誤差に起因する誤誘導

が不十分な場合、性能予測の誤りにより最適化が誤った方向に進んでしまい（誤誘導）、最適化が失敗する（図 4.2b）。

本研究では、代替モデルの誤差に起因する誤誘導を回避しつつ、最適設計を高速化することを目的とする。そのために、二つの深層ニューラルネットワーク（DNN: deep neural network）を用いた最適化フレームワークを提案する。一つ目の DNN は MSL 回路の S パラメータを予測し、二つ目の DNN は一つ目の DNN の精度を予測する。二つ目の DNN の出力をもとに最適化中の性能評価を FEA により正確に実行するかを判断する。

DNN を代替モデルとして用いてマイクロ波デバイスの最適設計を高速化する手法はいくつか提案されている [41, 42]。[41] では膨大なデータ生成プロセス（30 万個以上）と転移学習を用いた DNN によりマイクロ波デバイスの高精度な代替モデルを作成している。[42] では DNN が良好な性能だと予測した形状に対してのみ FEA を実行する手法が提案されている。一方で提案法は 2 つの DNN を使用し、2 つ目の DNN が精度が低いと予測した形状に対してのみ FEA を実行する。なお、[42] と類似した手法は、TO を DNN で高速化する最初の取り組みとしてすでに電気モータの TO に適用されている [34]。

本研究では代替モデルを用いて最適化を高速に実行しつつ、誤誘導を回避できる手法の開発を目的としている。そのために深層学習を用いた MSL 回路の代替モデルの精度を予測する手法、およびそれを用いた MSL 回路の設計手法を提案する。代替モデルの精度を予測することで、適化の際に FEA を実行するかの判断基準とする。

4.2 提案する最適設計手法

代替モデルの精度を予測する手法、およびそれを用いた最適設計手法を説明する。

4.2.1 代替モデルの精度の予測

MSL 回路の代替モデルとして図 4.3 のように設計領域の導体箔形状を表す画像を入力、MSL 回路の特性を表す散乱係数（S パラメータ）を出力とする DNN を考える。次にこれとは別に設計領域の導体箔形状を表す画像を入力、代替モデルの二乗平均平方根予測誤差（RMSE: root mean squared error）を出力とする DNN を作成することで、任意の導体箔形状に対する代替モデルの精度（誤差）を予測できる。以降、前者の DNN を代替モデル、後者の DNN を**精度予測器（accuracy predictor）**と呼ぶ。代替モデルおよび精度予測器は畳み込みニューラルネットワーク（CNN: convolutional neural network）により作成する。代替モデルの学習には事前最適化を実行してその過程で得られたデータを使用する。学習データはランダムに形状を生成した方がより広範囲のデータを収集できるが、その場合は望ましい特性からかけ離れた意味のないデータばかり生成されてしまうため、事前最適化によりデータを生成する。精度予測器を作成する手順を図 4.4 にまとめる。




図 4.3: 提案法で用いる二つの DNN [40] ©2025 IEICE




図 4.4: 精度予測器の作成手順

4.2.2 精度予測に基づく最適化

精度予測器を用いた最適設計手法を説明する．従来法と提案法の最適化の流れを図 4.5 に示す．ここで，上付き文字の g と下付き文字の i は第 g 世代目の i 番目の個体を表す． $\hat{L}_i^g$ は精度予測器の出力， L_{th} は閾値， $\hat{F}_i^g$ は代替モデルで予測した評価値を表し， $\hat{\mathbf{F}}^g = \{\hat{F}_1^g, \hat{F}_2^g, \dots\}$ である．本手法は進化的アルゴリズムによる最適化を想定しているため，図 4.5a のように集団の生成（更新）と評価を繰り返し行うことで最適化が進行する．提案法の特徴は図 4.5b に示す性能評価の処理にある．従来法 (i) ではすべての個体の評価を FEA で，従来法 (ii) では代替モデルで行う．一方で提案法では精度予測器の出力に応じて FEA と代替モデルを切り替えて個体の評価を行う．本研究では二通りの方法を提案している．提案法 (ii) では精度が悪くかつ良い性能と予測された個体に限定して詳細な解析を行うことで，誤誘導を回避しつつ高速化を図る．




図 4.5: 従来法と提案法の最適設計手法。本研究では二通りの手法を提案している。

4.3 提案法を適用した結果

提案法によってマイクロストリップ帯域通過フィルタ（MSBPF: microstrip bandpass filter）を設計した結果について述べる。

4.3.1 事前最適化

代替モデルの学習に使用するデータを生成するための事前最適化について説明する。図 4.6 に示す MSBPF に対して NGnet 法による TO を適用して (4.1) の最適化問題を解く^{*1}。

$$F(\mathbf{w}) = \sum_{f \in \text{passband}} S_{21, \text{dB}}(f)^2 + \sum_{f \in \text{stopband}} S_{11, \text{dB}}(f)^2 \rightarrow \min. \quad (4.1)$$

^{*1} NGnet 法による MSBPF の TO の詳細は 3.2.2 節を参照。




図 4.6: 事前最適化の最適化モデル (MSBPF) [24] ©2024 IEEE




図 4.7: 事前最適化のガウス基底の配置. 赤い円がガウス基底を表しており, 標準偏差 σ を半径として描画している. [24] ©2024 IEEE

表 4.1: 事前最適化の最適化設定 [24] ©2024 IEEE

設計変数の数	55
最適化アルゴリズム	CMA-ES
世代数	80
集団サイズ λ	$4 + \lfloor 3 \ln 55 \rfloor = 16$
平均値ベクトルの初期値 $\mathbf{m}_0$	$\mathbf{0}$
ステップサイズの初期値 σ_0	0.3

ここで, $\mathbf{w}$ は基底関数の重み, $S_{ij,\text{dB}}$ はデシベル形式の S パラメータの大きさ, f はサンプリング周波数を表し, 中心周波数は 2.0 GHz, 比帯域幅は 20% である. ガウス基底の配置, 最適化設定, 電磁界解析の設定をそれぞれ図 4.7, 表 4.1, 表 4.2 に示す. 集団サイズは CMA-ES の開発者によって提案されている推奨値を使用している [9]. 同様の最適化を異なる乱数シードで複数回実行することで, 24 日間で約 7 万個のデータが生成された. ポート同士が導体箔で接続されていない形状は望ましい特性が得られないことが経験上わかっているため, そのような形状を除外することで最終的な学習データ数は 66,973 個となった. 得られたデータの例を図 4.8 に示す. 最適化過程も学習データに含めるため, 帯域通過フィルタとはかけ離れた特性のものも存在する.

表 4.2: 解析設定

計算機	Intel®Xeon®W-2135 CPU @ 3.70 GHz
解析ソフト	Femtet®
並列数	4




図 4.8: 事前最適化の結果. 上段は設計領域の導体箔形状を表し, 下段はその S パラメータを表す. [40] ©2025 IEICE




図 4.9: 代替モデルの CNN 構造 [40] ©2025 IEICE

4.3.2 代替モデル

代替モデル作成のために図 4.9 の構造の CNN モデルを表 4.3 の設定で学習した. 損失曲線を図 4.10 に示す. 検証損失の最小値が 100 エポック連続で更新されなかったときのモデルパラメータを採用した. Intel®Core™i9-10940X CPU @ 3.30 GHz + NVIDIA RTX™A5000 を使用して 73 分かけて学習した結果, 最小検証損失は 0.26 となった. CNN モデルの構造は, 画

表 4.3: 代替モデルの学習設定 [40] ©2025 IEICE

データ総数	66,973
データ分割比率（訓練：検証：テスト）	7:1:2
更新手法	Adam [43]
損失関数	平均二乗誤差
バッチサイズ	128
初期学習率	0.001
エポック数	140




図 4.10: 代替モデルの学習の損失曲線 [40] ©2025 IEICE




図 4.11: テストデータに対して S パラメータを予測した結果 [40] ©2025 IEICE

像認識のために開発されたシンプルな CNN である VGG を参考に決定した [44]. 層数, ノード数, ドロップアウト, バッチノーマライゼーションなどの異なる設定を試したが結果に大きな影響はなかった. より多くのパラメータを持つモデルや, Vision Transformer [45] などの最新のモデルにより結果が改善される可能性は残されている. テストデータに対して予測を行った結果を図 4.11 に示す. $S_{11,\text{dB}}$ の 1.9~2.1 GHz, $S_{21,\text{dB}}$ の 2.5~2.6 GHz は特に形状に対する感度が高いため予測が難しく, 予測誤差が大きくなっている. 予測誤差に周波数依存性があるの




図 4.12: 事前最適化により生成されたデータセットの分布




図 4.13: 代替モデルによる特性の予測が成功した例

は、図 4.12 に示すように学習データの分散が周波数に依存しているためである。作成した代替モデルを用いて MSBPF の特性を予測した例を図 4.13 および図 4.14 に示す。特性をそれなりに精度よく予測できる場合もあれば、まったく予測できない場合もある。

図 4.15 は異なるデータセットサイズで代替モデルを学習したときの最小検証損失を示している。データセットサイズのべき乗におおよそ比例して学習時の最小検証損失が低下しており、これは言語モデルの学習におけるスケーリング則と同じ傾向を示している [46]。以上の結果から、学習データを増やすことで代替モデルの精度を向上させるにはデータ数をべき乗で増加させる必要があり、莫大な計算コストが必要となることがわかる。

4.3.3 精度予測器

精度予測器の CNN 構造を図 4.16 に示す。畳み込み層は代替モデルと同一で、全結合層はノード数を変更して出力を一次元の実数値としている。精度予測器は図 4.11 の誤差データをもとに学習する。学習設定を表 4.4 に示す。データ総数とエポック数以外は代替モデルの学習設定と同一である。損失曲線を図 4.17 に示す。代替モデルと同様の計算機環境を使用して学習




図 4.14: 代替モデルによる特性の予測が失敗した例




図 4.15: データセットサイズの増加による代替モデルの精度向上 [40] ©2025 IEICE




図 4.16: 精度予測器の CNN 構造 [40] ©2025 IEICE

表 4.4: 精度予測器の学習設定 [40] ©2025 IEICE

データ総数	13,395
データ分割比率（訓練：検証：テスト）	7:1:2
更新手法	Adam [43]
損失関数	平均二乗誤差
バッチサイズ	128
初期学習率	0.001
エポック数	117




図 4.17: 精度予測器の学習の損失曲線 [40] ©2025 IEICE




図 4.18: テストデータに対して代替モデルの RMSE を予測した結果

に 5 分かかった。5 分割の交差検証の結果、平均最小検証損失は 0.39 となった。テストデータに対して予測を行った結果を図 4.18 に示す。図 4.18a は横軸に真値、縦軸に予測値をプロットした散布図で、図中の斜線にデータが集中するほど予測精度が高いことを意味する。図 4.18b は予測誤差のヒストグラムであり、0 にデータが集中するほど予測精度が高いことを意味する。

4.3.4 最適化結果

提案法を MSBPF の設計に適用する。代替モデルと精度予測器はそれぞれ 4.3.2 節、4.3.3 節で作成したものを使用する。本最適化で設計する MSBPF の通過帯域を表 4.5 に示す。学習データ生成のための事前最適化と同一の設定だと代替モデルを用いて最適化を実行する意味がないため、通過帯域を変更している。本最適化の最適化モデル、目的関数、ガウス基底の配置、最適化設定は事前最適化と同様で、それぞれ図 4.6、(4.1)、図 4.7、表 4.1 に相当する。

図 4.5b に示す従来法 (i)、従来法 (ii)、提案法 (i)、提案法 (ii) の四つの方法で最適化を実行した結果を表 4.6 に示す。なお、閾値 L_{th} を 2.0 とし、Intel®Xeon®W-2135 CPU @ 3.70 GHz

表 4.5: 最適化の通過帯域の設定 [40] ©2025 IEICE

		中心周波数	比帯域幅
事前最適化 (4.3.1 節)		2.0 GHz	20.0%
	A	1.6 GHz	25.0%
代替モデルを用いた最適化 (本節)	B	2.1 GHz	28.6%
	C	1.9 GHz	31.6%

表 4.6: 従来法と提案法の最適化結果の比較 (異なる乱数シードで 6 回実行した平均値) [40] ©2025 IEICE

目標の設定 (表 4.5)	最適化手法	目的関数 (最小化)	予測 RMSE (dB)	所要時間 (min)	高速化率
A	従来法 (i)	34.48	N/A	641	N/A
	従来法 (ii)	3378	8.87	3	214
	提案法 (i)	65.00	2.66	239	2.68
	提案法 (ii)	56.75	1.82	121	5.30
B	従来法 (i)	45.89	N/A	538	N/A
	従来法 (ii)	2648	7.20	3	179
	提案法 (i)	53.78	1.83	250	2.15
	提案法 (ii)	53.48	2.05	44	12.2
C	従来法 (i)	49.98	N/A	575	N/A
	従来法 (ii)	4263	9.23	3	192
	提案法 (i)	53.01	0.97	181	3.18
	提案法 (ii)	54.02	1.86	62	9.27

により 4 並列で FEA を行った。「目的関数」の項目に関して、代替モデルを使用している手法 (提案法 (i) 以外) については最終世代を FEA で再解析した結果を示している。また、「所要時間」の項目に関して、CNN を利用した手法については学習データ生成および学習に要する時間は含めていない。設定 A に着目すると、すべての個体の評価を FEA で行う従来法 (i) は一度の最適化に約 10 時間かかっていたが、代替モデルに置き換えることで約 200 倍の高速化になった (従来法 (ii))。しかしながら図 4.11 に示したとおり、代替モデルの精度が不十分なため誤誘導が生じてしまい、目的関数が小さくなっていない。一方で提案法 (i) は高速化倍率が約 3 倍にとどまっている代わりに目的関数の悪化を 2 倍程度に抑えることができた。上位 50% の個体のみを FEA する提案法 (ii) は、提案法 (i) と同程度の目的関数および RMSE を維持しつつ約 2 倍の高速化となり、従来法 (i) と比較すると 5 倍の高速化となった。上述の提案法による目的関数の悪化が許容できない場合は全世代のエリート個体に対して FEA を行い、その中から最適解を選ぶ方法がある (表 4.6 の結果は最終世代のエリート個体のみ FEA を行っ




図 4.19: 提案法 (ii) の最適化結果. S パラメータは測定結果, 代替モデルによる予測結果および FEA により再解析した結果を比較している. [40] ©2025 IEICE

ている). この方法を設定 A に適用すると目的関数が 35.31 となり, 従来法 (i) の結果 (34.48) と遜色ない結果となる. ただし FEA の回数の増加により高速化率は 5.30 から 3.98 に減少する. 表 4.6 の結果から提案法は設定 B および C にも有効であり, すべてを平均すると提案法 (ii) は 9 倍の高速化となっていることがわかる.

提案法 (ii) によって得られた設定 A の最適化結果の一つを図 4.19 に示す. S パラメータについて, 測定結果, 代替モデルによる予測結果および FEA により再解析した結果が一致することが確かめられた. また, 通過帯域で $S_{11,\text{dB}}$ が小さくなっており, 事前最適化とは異なった通過帯域を設定したにも関わらず所望通りの特性が得られた.

4.4 まとめ

本章では, 高精度な代替モデルの作成が難しい場合でも代替モデルを利用した最適設計を可能とするために, 代替モデルの精度を予測する手法およびそれを用いた最適設計手法を提案した. 提案法では深層学習により代替モデルの精度を予測し, その予測結果に基づいて電磁界解析と代替モデルを切り替えて最適設計を行う.

提案法で MSBPF の最適設計を行った結果, 代替モデルの予測誤差に起因する最適化の失敗 (誤誘導) を回避しつつ, 9 倍の高速化となった. 提案法を用いることで, 高精度な代替モデルの作成が難しい MSBPF についても代替モデルを利用した TO が可能であることを示した. 学習データの生成には時間がかかるものの, 一度学習が完了すればさまざまな最適化を高速に実行できることが明らかとなった.

第 5 章

機械学習を用いたヒステリシス損失の高速解析

5.1 はじめに

近年、小型化のためにインダクタの駆動周波数が高くなっており、周波数に比例して増加するヒステリシス損失（ヒス損）の正確な評価が重要となっている。この高精度なヒス損解析はインダクタ以外にもトランス、リアクトル、電動機、発電機等の設計においても必要となる。

もっとも広く使われるヒス損解析の手法は Steinmetz の式である [47–50]。この手法ではヒス損が $p_h = K_h f B^n$ の形式で表現できるという仮定のもとでヒス損を求める。ここで、 B は磁束密度の振幅、 K_h は係数、 n は定数であり通常は $1.5 \leq n \leq 2.5$ の範囲の値を使用する。この手法は時間波形 $B(t)$ を Fourier 級数に分解し、各成分に Steinmetz の式を適用することで高調波にも適用することができる。波形のマイナーループの振幅からヒス損を評価する improved-improved generalized Steinmetz equation (i²GSE) [51] では直流バイアスを考慮したヒス損解析ができる。これらの手法はシンプルでありヒス損の高速な解析に有効だが、マイナーループを含む材料固有の特性を考慮するのが難しく、精度に限界がある。

磁気ヒステリシス特性はプライザツハモデル [52] やプレイモデル [53, 54] によって高精度にモデリングできる。これらのモデルを使うことで磁化履歴を考慮した材料固有のヒステリシスループを表現し、マイナーループや直流バイアスなどの効果を正確に考慮することができる。しかし、これらのヒステリシスモデルはヒステリシス曲線上の詳細な状態遷移を考慮するため、前述の Steinmetz の式に基づく手法より複雑であり、ヒス損解析に時間を要する。

磁気ヒステリシスは機械学習（ML: machine learning）、特に外部メモリ付きのフィードフォワードニューラルネットワーク（NN: neural network）[55–57] や回帰型 NN（RNN: recurrent neural network）[58] などの NN によってもモデリングされてきた。前者の NN は入力ノードから出力ノードまでデータが一方向に流れ、外部メモリに保存した過去の出力が現在の入力と合わせて入力ノードに渡される構造となっている。一方で後者の NN は出力データに学習可能な重み行列を乗じて前の層に送るような再帰的構造を持っている。その他のアプローチと

して、連続する一次元のパターンを読み取る temporal convolutional networks (TCN) [56] や、Jiles-Atherton モデルとプライザッハモデルからなる NN ベースのハイブリッドモデル [59] もある。これら ML を使った手法では、ヒス損ではなくヒステリシス特性をモデリングしている。

本章ではヒス損解析の精度をプライザッハモデルやプレイモデルと同等に保ちつつ、ヒス損解析の計算を単純化して計算負荷を下げることを目的とする。この目的を達成するために、磁束密度の波形とプレイモデルで事前に計算したヒス損の関係を NN により表現する。本研究の新規性は、プレイモデルで計算したヒス損を学習した NN によってヒス損を求める点にある。上述の ML による手法とは異なり、提案法は磁気ヒステリシスはモデリングせずにヒス損を直接予測する。本研究ではその汎用性の高さから NN を採用したが、応答曲面法や回帰木 [48] などの手法も有効だろう。提案法ではプレイモデルと同程度の精度で磁束密度波形 $B(t)$ からヒス損を高速に評価できることが期待される。提案法はヒステリシス曲線上の状態遷移を考慮する必要もなければ、ヒス損解析のために数値積分をする必要もない。

本章では 5.2 節で提案するヒス損解析手法を説明し、5.3 節で提案法でヒス損を解析した結果を示す。5.4 節では提案法を使ったインダクタの最適設計を行い、5.5 節で本章を総括する。

5.2 定式化

提案法において使用するプレイモデルと磁気エネルギーの計算方法、および提案法において考える仮定を説明した後に提案法の詳細を説明する。

5.2.1 プレイモデル

プレイモデルはヒステリシス特性をプレイヒステロンの重ね合わせで表現するヒステリシスモデルの一つである。プレイモデルは任意のマイナーループを表現し、直流バイアスのかかったループをモデル化することができる。プレイヒステロンは次のように定義される [53, 54]。


$$p(H, p_0) = \max(\min(p_0, H + \zeta), H - \zeta) \quad (5.1)$$

ここで、 H は磁界、 p_0 はひとつ前のステップでのプレイヒステロンの値、 ζ はプレイヒステロンの幅を与える非ゼロのパラメータである。磁気飽和を考慮するために $\zeta = 0$ 以外の場合について (5.1) を次のように修正する。

$$p(H, p_0) = \begin{cases} -H_s + \zeta & \text{if } H < -H_s, \\ p & \text{if } -H_s \leq H \leq H_s, \\ H_s - \zeta & \text{if } H_s < H. \end{cases} \quad (5.2)$$

ここで、 H_s は飽和磁界を表す定数である。 ζ をさまざまな値に変えたときのプレイヒステロンを図 5.1 に示す。プレイモデルの出力は次のように定義される。

$$B(H) = \sum_{n=1}^{N_p} f_n(p_n(H)) \quad (5.3)$$


 図 5.1: さまざまな ζ の値のプレイヒステロン [60], CC BY

ここで, N_p は重ね合わされるプレイヒステロンの数, p_n は $\zeta = (n-1) \times H_s / N_p$ のプレイヒステロンである. p_n を引数として持つ f_n は形状関数と呼ばれ, 材料特性を表現する役割がある. プレイモデルは測定によって得られるメジャーロープ群からこの形状関数 f_n を求めることで同定される.

磁界解析のために, 未知数をベクトルポテンシャル A とする有限要素法 (FEM: finite element method) を使用する. ヒス損の計算では, H ではなく A から計算される B を入力とするプレイモデルを使用する. これは与えられた B に対して (5.3) を満たすような H を求めなければならないことを意味する. そのために, 次の二分法を使用する.

プレイモデルの二分法

探したい H を H^* , 与えられた B を B^* とする.

1. $H_{\text{left}} \leftarrow -H_0$, $H_{\text{right}} \leftarrow H_0$ とする. ここで, H_{left} と H_{right} はそれぞれ H^* の存在範囲の下限と上限, H_0 は H の最大値よりも大きな正の定数である. もし H_0 が H の最大値よりも小さい場合, プレイモデルは H_0 よりも大きな H を出力できなくなる.
2. プレイモデルを用いて次式で定義される H_{mid} に対応する B_{mid} を計算する.

$$H_{\text{mid}} = (H_{\text{left}} + H_{\text{right}}) / 2 \quad (5.4)$$

このとき, プレイモデルで B_{mid} を計算する際に (5.1) の中の p_0 は更新しない点に注意されたい.

3. 次の条件を満たしたら H_{mid} を H^* として終了し, 満たさない場合は次のステップに進む.

$$|B^* - B_{\text{mid}}| < \varepsilon \quad (5.5)$$

ここで, ε は小さな正の定数であり, 本研究では $\varepsilon = 10^{-4} \text{T}$ とした.




図 5.2: 台形近似による磁気エネルギーの計算 [60], CC BY

4. もし $B_{\text{mid}} > B^*$ なら $H_{\text{right}} \leftarrow H_{\text{mid}}$ とし, そうでないなら $H_{\text{left}} \leftarrow H_{\text{mid}}$ とし, ステップ 2 に戻る.

5.2.2 磁気エネルギーの計算

磁気エネルギー密度は次のようにあらわされる.

$$w_m = \int_0^B \mathbf{H} \cdot d\mathbf{B} \quad (5.6)$$

ここで, $\mathbf{H}$ と $\mathbf{B}$ はそれぞれ磁界と磁束密度をあらわす. 積分経路が閉じているとき, (5.6) は次のようにあらわされるヒス損と等価になる.

$$w_h = \oint \mathbf{H} \cdot d\mathbf{B} \quad (5.7)$$

磁気エネルギー (ヒス損) は BH 曲線によって囲まれる領域を図 5.2 のように小さな台形で近似することで, 次式で計算できる.

$$w_m \approx \sum_i S_i, \quad (5.8)$$

$$S_i = (H_i + H_{i+1})(B_{i+1} - B_i)/2.$$

磁束密度波形が与えられたとき, (5.8) 中の H_i および H_{i+1} はプレイモデルによって B_i と B_{i+1} から求める. 式 (5.8) を使うことでマイナーループを考慮したヒス損解析を行うことができるが, 数値積分の各ステップにおいて (5.3) の計算が必要となる. したがって特に大きな要素数のモデルに対して何度もヒス損解析を実行するような場面^{*1}においては計算負荷が大きくなってしまう. 以降, (5.8) によるヒス損解析を従来法と呼ぶ. 一方, 提案法であればこのような計算プロセスの必要はなく, 従来法よりも高速にヒス損解析を実行できる.

^{*1} 例えば最適設計 (ヒス損解析を含む最適設計の例は 5.4 節にて示す).




図 5.3: 磁気ヒステリシスに関する性質 [60], CC BY

5.2.3 仮定

後処理でのヒス損解析

ヒステリシス特性を無視した初磁化特性によって磁場を近似的に解析できると仮定し、ヒス損は後処理で評価する。つまり磁場の計算は初磁化特性に基づいて実行し、得られた磁束密度波形に対してヒス損を求めるときのみヒステリシス特性を考慮する。ヒス損は後処理によって十分な精度で効果的に評価されることが示されており [61, 62]、本仮定はこの事実に基づいている。

プレイモデルによるヒス損解析の精度

ヒス損は合同性 (congruency property) や記憶の消去性 (wiping-out property) といった性質を持つプレイモデル (またはプライザッハモデル) によって正確に評価できると仮定する [47, 63]。提案法ではプレイモデルによって作成したデータを使って NN を学習する。プレイモデルの未知パラメータは測定されたメジャーループ群によって良く同定されていると仮定する。

磁束密度波形の極値でヒス損が定まる

磁束密度 B が B_1 から B_2 まで単調増加するような経路は図 5.3a のように無数に存在する。これらの経路に対応する BH 曲線はすべて図 5.3b に示すような同一の BH 曲線となる。したがって B がある点から別の点まで単調増加 (減少) するとき、生じるヒス損は経路によらず始点と終点の値で決まる、つまりヒス損は B の極値によって決まることになる。

5.2.4 提案法の手順

提案法の概要を図 5.4 に示す。提案法は二つのステップからなる。一つ目のステップは図 5.4a のように、単調増加 (減少) する BH 曲線の始点 B_j, H_j と終点 B_{j+1} を入力とし、その間に变化する磁気エネルギー w_m^j を出力とする NN を構築する。前述のとおり、その汎用性から本研




図 5.4: 提案するヒステリシス解析手法の概要 [60], CC BY

究では NN を採用しているが、NN 以外の回帰手法であっても原理上は適用可能である。また、本研究では H_j も NN の入力に含めているが、プレイモデルの合同性により下と上がそれぞれ B_j と B_{j+1} のピークを持つマイナーループに対するヒステリシス損失は一意に定まるため [47, 63], H_j は NN の入力に含める必要がない可能性がある。NN の出力を次式であらわす。

$$w_m^j = f(H_j, B_j, B_{j+1}) \quad (5.9)$$

ここで、 f は NN により表現される非線形の関数を表す。一つ目のステップの詳細な手順を下記にまとめる。

1. 与えられたコイルの電流波形に対して、磁束密度分布 $\mathbf{B}$ を FEM で計算する。この磁束密度分布の計算においては磁性体コアに初磁化特性を仮定し、磁気ヒステリシス特性を無視する^{*2}。
2. $\mathbf{B}$ を計算した結果から磁束密度波形 $B(t) = |\mathbf{B}(t)|$ を要素ごとに抽出し、保存する。

^{*2} 5.2.3 項を参照




表 5.1: 最適化モデル

磁性体コアの厚み	5 mm
コイルの巻き数	90
コイル内径	7.4 mm
コイル外径	10 mm

図 5.5: 最適化モデル ($a = 4$ mm
 $b = 20$ mm, $c = 12$ mm, $d = 11$ mm)
 [60], CC BY

3. 前述のプレイモデルの二分法を用いて $B(t)$ から $H(t)$ を計算する。
4. $B(t)$ が極値 B_j, B_{j+1} をとるとき、 B が B_j から B_{j+1} まで変化する間の磁気エネルギーの変化 w_m^j を (5.8) で計算し、保存する。
5. 手順 4 で作成したデータを使って NN を学習する。

二つ目のステップとして、与えられた $B(t)$ を図 5.4b のように極値で分割し、分割した各区間に対して前述の学習済み NN を使用して磁気エネルギー w_m^j を計算する。本計算に必要な H_j は対応する B_j と初磁化曲線から求める。ヒス損 w_h は次式のようにすべての区間の w_m^j を足し合わせることで求まる。

$$w_h = \sum_j w_m^j \quad (5.10)$$

5.3 提案法によるヒス損解析

5.3.1 学習データの生成

提案する高速ヒス損解析手法を図 5.5 および表 5.1 に示すインダクタのモデルに適用する。最適化モデルの磁性体コアの初磁化特性を図 5.6 に示す [64, 65]。コイル電流を計算するためにインダクタの簡単な等価回路として、図 5.7 に示す RL 直列回路を考える。図 5.7 の回路にパルス幅変調（PWM: pulse width modulation）正弦波電圧 $e(t)$ を入力したときのコイル電流 $i(t)$ を図 5.8 に示す。 $i(t)$ の計算には回路シミュレータ LTspice を使用した。上記の $i(t)$ をインダクタの有限要素モデルに与え、磁性体コアの磁束密度分布を解析する。表 5.2 の設定で解析を行い、12 分で解析が完了した。ある時刻における磁束密度分布と各有限要素の磁束密度波形を図 5.9 および図 5.10 に示す。コア形状の対称性を考慮しながら磁性体コアの各有限要素から




図 5.6: 最適化モデルの磁性体コアの初磁化特性 [64,65], [60], CC BY




図 5.7: インダクタの等価回路
[60], CC BY

図 5.8: インダクタの入力電圧とコイル電流 [60], CC BY

表 5.2: 磁束密度分布の解析設定

時間ステップ数	301
要素数	91,640
計算機	Intel®Xeon®W-2135 CPU @ 3.70 GHz
解析ソフト	Femtet®

波形を抽出した結果、4,983 個の波形が得られた。上記のデータは図 5.8 に示した一つの PWM 電圧に対して得られるデータである。

式 (5.3) の計算に用いるプレイモデルの設定を表 5.3, プレイモデルで計算した BH 曲線の例を図 5.11 に示す [64,65]。入力波形が高調波成分を含んでおり、図 5.11b のようにマイナーループが生じている。プレイモデルを用いて (5.8) で磁気エネルギーを計算しながら、5.2 節で述べたように $B(t)$ の極値で分割することで 94,660 個のデータ (H_j, B_j, B_{j+1} と w_m^j の対) が得られた。式 (5.8) における数値積分のステップサイズを 1 mT として Intel®Core™i9-10940X




図 5.9: FEM により解析した磁性体コアにおける磁束密度分布 ($t = 2.93 \mu\text{s}$) [60], CC BY




図 5.10: 各有限要素から抽出した磁束密度波形 [60], CC BY

表 5.3: プレイモデルの設定

メジャーグループ群のステップサイズ ΔH_m	0.5 kA/m
飽和磁界強度 H_s	35 kA/m
プレイヒステロンの数 N_p	70





図 5.11: プレイモデルで計算した BH 曲線 [64, 65], [60], CC BY



Number of nodes 3 12 48 48 48 12 1

図 5.12: 磁気エネルギーを予測する NN の構造 [60], CC BY

CPU @ 3.30 GHz を使用したところ、30 分で計算が完了した。

5.3.2 NN の学習

式 (5.9) の磁気エネルギーの予測に使用した NN の構造を図 5.12 に示す。本構造には隠れ層が 5 層あり、各層のノード数は入力層側から順にそれぞれ 12, 48, 48, 48, 12 である。出力層以外の層に対して活性化関数として次式で定義される Leaky ReLU (rectified linear unit) を使用した。

$$\text{LeakyReLU}(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & \text{otherwise} \end{cases} \quad (5.11)$$

表 5.4: 磁気エネルギーを予測する NN の学習設定 [60], CC BY

Number of data	Total	94,660
	Training data	56,796
	Validation data	18,932
	Test data	18,932
Batch size	128	
Loss function	MSE(5.12)	
Optimization algorithm	Adam	
Initial learning rate	0.001	




図 5.13: 学習時の損失曲線 [60], CC BY

ここで, α は正の定数であり, 本研究では 0.01 とした. 本構造では隣接する層間のノード数が急激に変化しないように, かつ中心の隠れ層のノード数が最も大きくなるようにノード数を決定した. はじめは隠れ層が 3 層の構造を使用していたが十分な予測精度が得られなかったため, 最終的には隠れ層の層数を 5 層とした. NN の学習設定を表に示す. データセットは訓練データ, 検証データ, テストデータに 6:2:2 の割合でランダムに分割し, ホールドアウト検証を行う. NN モデルの学習に使用する誤差関数には次式で定義される平均二乗誤差 (MSE: mean squared error) を使用する.

$$\text{MSELoss}(x, y) = \frac{1}{N} \sum_{n=1}^N (x_n - y_n)^2 \quad (5.12)$$

ここで, $\mathbf{x} = [x_1, \dots, x_N]$ および $\mathbf{y} = [y_1, \dots, y_N]$ はそれぞれ予測値と真値を表し, N は訓練データの総数を表す. NN の学習は検証誤差の最小値が 100 エポック連続で更新されなかった時点で終了し, 最小の誤差となった重みを採用した. なお, NN はオープンソースの深層学習フレームワークである PyTorch を用いて実装した. 学習データの生成時に使用した計算環境に NVIDIA RTX™A5000 を加えて学習を行った. その結果, 29 分で学習が完了し, 最小の検証損失は $3.15 \times 10^{-6} (\text{J}/\text{m}^3)^2$ となった. 損失曲線およびテストデータに対する予測結果を図 5.13 および図 5.14 に示す. 磁気エネルギーは高い精度で予測できている.




図 5.14: テストデータに対する磁気エネルギーの予測結果 [60], CC BY




図 5.15: 図 5.10 の波形に対して従来法と提案法でヒス損解析した結果 [60], CC BY

5.3.3 ヒス損解析の結果


従来法と提案法でヒス損解析した結果を図 5.15 に示す。従来法と提案法で結果に若干のずれがあるが、両者の相関係数は 0.99985 という高い値をとっている。ヒス損解析に要した時間を表 5.5 の中段に示す。提案法によって計算時間を約 2000 分の 1 に短縮できた。ただ、上記の計算時間には NN の学習に必要な時間が含まれていない点に注意されたい。一度 NN を学習してしまえば異なる波形であったり、同一材料の異なる形状のインダクタにも再利用できる可能性がある。前者については 5.3.4 項で検証し、後者については 5.4.3 項で一例を示す。たとえば遺伝的アルゴリズムのような集団探索ベースの最適化アルゴリズム^{*3}を用いてインダクタの最適設計を行う場合を考える。設計対象のインダクタの磁性体コアの要素数を 10,000、集団サイズ

^{*3} 2.3 節を参照。

表 5.5: ヒス損解析に要する時間

予測器の作成	学習データ生成	30 min
	NN の学習	29 min
単一の波形に対するヒス損解析	従来法	390 ms
	提案法	0.20 ms [*]
インダクタの最適設計	従来法	226 days
	提案法	2.8 hours [*]

^{*} 予測器の作成に要する時間を除く


図 5.16: 異なる D に対するインダクタのコイル電流波形 [60], CC BY

を 50, 世代数を 100 と仮定したときのヒス損解析に要する時間の見積もりを表 5.5 の下段に示す. 若干極端な例ではあるが従来法と提案法の間には 7 か月以上の差が生じている. このように, 提案法はたくさんのヒス損解析を実行しなければならない場合に特に大きな効果を発揮する.

5.3.4 異なる波形への適用

一度学習した NN を学習時とは異なる波形に対して再利用できるか検証する. はじめにデューティー比 D が 0.7 と 0.9 の PWM 正弦波電圧によって生成される磁束密度波形をもとに, (5.9) の磁気エネルギーを予測する NN を学習する. 次に $D = 0.8$ の電圧指令で生成された磁束密度波形に対して上記の学習済み NN を使って提案法でヒス損を計算する.

図 5.16 に示すコイル電流に対して FEM を実行し, 形状の対称性を考慮しながら磁性体コアの各有限要素から抽出した磁束密度波形を図 5.17 に示す. 磁束密度分布の解析には Femtet® を使用した. 合計で 14,949 (= 4,983 × 3) 個の波形が得られ, $D = 0.7, 0.9$ の波形に対して 5.3.1 項と同じようにデータセットを生成した. 合計で 189,321 個のデータが得られ, 訓練データ, 検証データ, テストデータに 6:2:2 の割合でランダムに分割してホールドアウト検証を行




図 5.17: 異なる D から得られた磁束密度波形 [60], CC BY




図 5.18: 損失曲線

う。インダクタモデル，プレイモデル，NN の構造，学習設定，計算環境は 5.3.1 項と同様である。学習は 72 分で完了し，最小の検証損失は $1.31 \times 10^{-5} (\text{J/m}^3)^2$ となった。損失曲線を図 5.18 に示す。テストデータに対して磁気エネルギーを予測した結果を図 5.19a に示す。真値と予測値が一直線に並んでおり，精度よく予測できている。 $D = 0.8$ の磁束密度波形に対してヒス損を計算した結果を図 5.19b に示す。従来法と提案法で計算した結果の相関係数は 0.99 を超えており，若干の誤差はあるもののおよそ一致している。 $D = 0.8$ の波形は NN の学習に使ったデータセットに含まれていない点に注意されたい。したがって提案法で学習した NN は，学習時の波形とは大きく異ならないという条件のもとで異なる波形に再利用できると考えられる。




図 5.19: 異なる波形に対してヒス損を計算した結果 [60], CC BY




図 5.20: インダクタの最適化モデル

5.4 提案法によるインダクタの最適設計

提案する高速ヒス損解析手法は最適設計のようなヒス損解析を何度も実行しなければならない場合に大きな効果を発揮する。本節では提案法の応用例として、ヒス損を考慮したインダクタの最適設計を行う。

5.4.1 問題設定

最適化モデルを図 5.20 に示す。磁性体コアの厚みや初磁化特性は表 5.1, 図 5.6 と同様である。磁性体コアの形状は x_1, x_2, x_3 の 3 つの寸法パラメータで表現され、一定のインダクタン




図 5.21: FEM により得られた磁束密度波形

ス値を持ちつつヒス損が最小となるような寸法を最適設計により求める．そのような設計を実現するために次の最適化問題を考える．

$$F(x_1, x_2, x_3) = \frac{w_h}{w_h^{\text{ref}}} + c \frac{|L - L^{\text{ref}}|}{L^{\text{ref}}} \rightarrow \min. \quad (5.13)$$

$$\text{s.t.} \quad 3.6 \text{ mm} \leq x_1, x_2, x_3 \leq 4.4 \text{ mm}$$

ここで、 w_h は磁性体コアのヒス損、 L はインダクタンスをあらわす． w_h^{ref} および L^{ref} は目的関数を正規化するための参照値であり、 $w_h^{\text{ref}} = 951.2 \mu\text{J}$, $L^{\text{ref}} = 133.9 \mu\text{H}$ である^{*4}． c は重み係数であり、本研究では $c = 1.0$ とした．設計変数（磁性体コアの寸法）は一定の範囲内に収まるように制約を課しており、最適化時には (2.27) の方法で制約を扱う．

5.4.2 学習データの生成

図 5.16 の $D = 0.9$ の電流波形を用いて FEM により磁束密度分布を計算する．5.3 節では単一の磁性体コア形状しか考慮しなかったが、本節では形状の最適化を行うためさまざまな形状の磁性体コア形状に対応しなければならない．そこで、設計変数 (x_1, x_2, x_3) の値をそれぞれ 3.6, 4.0, 4.4 mm に設定して合計 27 ($= 3^3$) 種類の形状に対して FEM を実行して磁束密度波形を抽出し、図 5.21 に示す計 9,271 個の波形が得られた．磁束密度分布の解析には Femtet® を使用した．図 5.21 の波形に対して 5.3.1 項と同一のプレイモデルを用いて波形の極値で分割しながら磁気エネルギーを計算し、計 176,146 個のデータが得られた．

^{*4} $(x_1, x_2, x_3) = (4.0, 4.0, 4.0) \text{ mm}$ を参照モデルとしており、そのヒス損とインダクタンスをそれぞれ w_h^{ref} , L^{ref} としている．





図 5.22: 損失曲線



(a) 真値 - 予測値のプロット

(b) 予測誤差のヒストグラム

図 5.23: テストデータに対する磁気エネルギーの予測結果

5.4.3 NN の学習

5.4.2 項で生成したデータを 5.3.2 項と同一の NN 構造、学習設定で学習した。損失曲線を図 5.22 に示す。最小の検証損失は $5.93 \times 10^{-6} (\text{J}/\text{m}^3)^2$ だった。学習済みの NN でテストデータに対して磁気エネルギーを予測した結果を図 5.23、提案法によって図 5.21 の波形に対してヒス損解析して従来法と比較した結果を図 5.24 に示す。両者ともに精度よく予測できている。5.3.4 項では学習データとは異なる電圧指令によって生じる磁束密度波形に対して予測器を再利用できるか検証した。一方、本節では最適化の過程でインダクタの磁性体コアをさまざまな形に変化させてヒス損解析を行うが、そこには学習データに含まれない形状も当然存在する。表 5.7 に示した最適化形状のヒス損の予測値に着目すると予測値が $866.0 \mu\text{J}$ 、真値が $864.2 \mu\text{J}$ であり、最適化形状は学習データに含まれていないがそのヒス損を 0.2% の誤差で予測できている。したがって提案法で学習した NN は、学習時の形状とは大きく異なるという条件のもとで異なる形状の磁性体コアにも再利用できると考えられる。




図 5.24: 図 5.21 の波形に対して従来法と提案法でヒス損解析した結果

表 5.6: 最適化設定

設計変数の数	3
ペナルティ定数 Δ	-4
最適化アルゴリズム	CMA-ES
集団サイズ λ	8
世代数	100

表 5.7: 最適化結果

	L	w_h (予測値)	w_h (再解析)
参照モデル	133.9 μH	947.1 μJ	951.2 μJ
最適化形状	133.9 μH	866.0 μJ	864.2 μJ
誤差率 (変化率)	-0.04 %	-8.6 %	-9.1 %

5.4.4 最適化結果

最適化設定を表 5.6 に示す。集団サイズ λ ，平均値ベクトルの初期値 $\mathbf{m}_0$ ，ステップサイズの初期値 σ_0 については CMA-ES の推奨値を採用した^{*5}。最適化中の磁束密度分布およびインダクタンスの解析には Femtet® を使用した。

目的関数 F の収束履歴を図 5.25，最適化結果を表 5.7 に示す。29 時間 54 分かけて 100 世代まで最適化を実行した結果，85 世代目のエリート固体である $(x_1, x_2, x_3) = (3.88, 4.34, 3.60)\text{mm}$ が最適解となった ($F = 0.9058$)。表 5.7 に関して，インダクタンスについては目標値と最適化

*5 2.3.3 項を参照。




 図 5.25: 目的関数 F の収束履歴


図 5.26: 磁性体コアのヒス損分布（再解析）

形状の誤差率が -0.04% であり、所望のインダクタンスとなっている。一方で、ヒス損については最適化によって 9.1% 削減できた。また、ヒス損の予測値と真値の間に大きな差はなく、提案法によってヒス損をうまく評価できていることがわかる。参照モデルと最適化形状のヒス損分布（再解析）を図 5.26 に示す。磁性体コアの中心部に集中しているヒス損に着目すると、最適化によってヒス損が低減していることがわかる。最適化形状では磁性体コアの中心部の部材の幅が狭くなっており、その結果磁束線が入りづらくなり、磁束密度の値が抑えられてヒス損が低減したと考えられる。一方でインダクタンスを一定に保つために外側の部材の幅が広くなっている。

最適化に要した時間の内訳を図 5.27a に示す。最も時間を要しているのは FEM で磁束密度分布を計算した結果から波形を抽出する処理であり、次が FEM で磁束密度分布を計算する処理である。本来であれば波形の抽出は 1 秒もかからない処理だが^{*6}、市販の解析ソフトを使用

^{*6} 電流が z 成分のみを持つとき、ある要素 e （位置 x ）、ある時刻 t におけるベクトルポテンシャルの z 成分 A_z




図 5.27: 最適化に要する時間の内訳

表 5.8: 最適化過程において一個体あたりの評価に要する時間

	波形抽出を考慮	波形抽出を無視
従来法 (推定)	231 s	120 s
提案法	153 s	42.6 s
高速化倍率	1.51	2.82

する都合上、解析ソフトのマクロ機能を使用する必要があり、非本質的な処理に時間がかかってしまっている。ヒス損解析については学習済みの NN を使用しているため平均 0.04 秒で完了している。一方で従来法でヒス損解析した場合、表 5.5 の結果から推定するとヒス損解析に要する時間は図 5.27b のように 77.4 秒となる。最適化過程において一個体あたりの評価に要する時間を表 5.8 に示す。実測値をもとに計算した提案法使用時の一個体あたりの評価の平均所要時間が 153 秒、従来法使用時の推定所要時間が 231 秒であり、提案法を使用することで最適化が 1.51 倍高速化される。また、前述の理由から波形抽出に要する時間を無視した場合は従来法が 120 秒、提案法が 42.6 秒であり、2.82 倍の高速化となる。最適化全体での所要時間を表 5.9 に示す。提案法によって所要時間が約 15 時間短縮されており、ヒス損解析のみに着目すると従来法では 15 時間かかる処理が提案法では 28 秒で完了している。予測器の作成 (学習

は次式で計算できる。

$$A_z(\mathbf{x}, t) = \sum_{j=1}^n a_j(t) N_j(\mathbf{x})$$

ここで、 $a_j(t)$ は e を構成する節点の未知数、 $N_j(\mathbf{x})$ は e を構成する節点の補間関数を表し、本節の FEM では三角形要素を使用するため $n = 3$ である。 $a_j(t)$ は FEM の結果から該当する節点番号の値を読み出せばよく、 $N_j(\mathbf{x})$ は e の節点の座標値から直ちに求まる。波形抽出の処理では上式の計算をすべての要素、すべての時刻において行う。本最適化では磁性体コアの要素数が 600 程度、時刻のステップ数が 300 のため、波形抽出に必要な計算回数は $3 \times 600 \times 300 = 540,000 < 10^6$ である。一般的に現代のコンピュータは 1 秒に 10^8 のオーダーの回数の計算ができるため、波形抽出の処理は 1 秒以内に実行可能である。

表 5.9: 最適化時間（波形抽出処理を無視）

	最適化全体	ヒス損解析のみ
従来法（推定）	23.3 h	15.0 h
提案法 *	8.27 h	28.0 s

* 予測器の作成に要する時間を除く

表 5.10: 予測器の作成時間も考慮した最適設計の所要時間（波形抽出処理を無視）

	所要時間	計算環境
学習データの生成 (FEM)	8 m 59 s	Intel®Core™i5-9500 CPU @ 3.00 GHz
学習データの生成 (磁気エネルギー計算)	2 m 39 s	Intel®Core™i9-10940X CPU @ 3.30 GHz, 14 コア 28 スレッド並列
NN の学習	36 m 36 s	Intel®Core™i9-10940X CPU @ 3.30 GHz + NVIDIA RTX™A5000
最適設計（提案法）	8.27 h	Intel®Core™i5-9500 CPU @ 3.00 GHz
計	9.07 h*	

* 従来法は 23.3 h のため提案法により 2.5 倍の高速化

データの生成および NN の学習）時間も考慮した最適設計の所要時間を表 5.10 に示す。予測器の作成に合計 48 分かかっているがそれを加味しても最適化に要した時間は合計 9.07 h であり、従来法の 23.3 h と比べて 2.5 倍の高速化となっている。本研究では二次元の単純なインダクタを考えたが、3 次元モデルになるなどして磁性体コアの要素数が増えれば高速化の効果はより顕著になる。

5.5 まとめ

本章では、電磁デバイスにおけるヒス損の解析を機械学習により高精度かつ高速に実行する手法を提案し、インダクタの最適設計によりその有効性を検証した。提案法ではプレイモデルにより解析したヒステリシス特性を考慮したヒス損を NN に学習させ、入力波形から磁気エネルギーを直接予測する回帰モデルを作成し、ヒス損の解析に利用する。

インダクタのヒス損解析に対して提案法を適用した結果、プレイモデルを用いた高精度なヒス損解析手法と同様の解析結果を得つつ、計算時間を約 2,000 倍高速化できた。さらに提案法を用いてヒス損を最小化するインダクタの最適設計を実行した結果、インダクタンス値の制約を満たしつつ参照モデルよりもヒス損を 9.1 % 低減できた。最適化時間に関しては NN の作成（学習データの生成、NN の学習）に要する時間を含めて 2.5 倍の高速化となった。また、提案

法で作成した NN は学習データと異なる入力波形，異なる磁性体コア形状に対してもヒス損（磁気エネルギー）を予測できることがわかった．ただし，これは学習データと“大きくは異なる”という前提があり，その限界は不明である．

第 6 章

結論

本研究では電磁デバイス，特にマイクロ波回路と電気機器を対象にその最適設計の高度化（TO 法の開発および高速化）を目的としており，従来は以下の課題が存在した．

- マイクロ波回路へのトポロジー最適化の適用例が少なく，その有効性は不明である
- マイクロ波のフィルタ回路はその特性の正確な予測が難しく，MSL 回路の TO に典型的な代替モデル法が適用できない
- ヒステリシス特性を正確に考慮できる既存のヒス損解析手法は実行に時間を要するため，最適設計などの多数のヒス損解析が必要な際に問題となる

上記の課題を解決するために本研究では MSL 回路のトポロジー最適化，ならびにマイクロ波回路およびヒス損解析のための代替モデル法の開発に取り組んだ．以下に本研究の成果と今後の展望をまとめる．

6.1 マイクロストリップラインのトポロジー最適化（第 3 章）

NGnet 法および幾何射影法を MSL 回路の設計に適用してその有効性を検証するとともに，二つの TO 手法を比較した．

NGnet 法に関して，従来の等価回路の方法で設計した回路よりも回路長を短くできるなど，いくつかの観点で優れた設計ができることがわかった．また，フィルタ回路だけでなく電力分配回路の設計にも適用することで，TO による設計手法の汎用性の高さを示した．二つの TO 手法を比較した結果，以下の理由から幾何射影法の方が MSL 回路の設計に適していると考えられる．

- 幾何射影法はスタブ構造を活用した設計が可能であり，フィルタ回路の設計では NGnet 法よりも優れた結果が得られた
- 幾何射影法は NGnet 法よりも扁平なメッシュが生成されやすく，電磁界解析の観点で有利である

今後の課題として，チップコンデンサなどの電子部品や，誘電体基板を貫通して信号ライン

とグランドをつなぐビア (via) を活用できる最適設計手法の開発が挙げられる。提案法では信号ラインの形状を変えることで回路を設計しているが、上記の要素も同時に考慮した最適設計が実現できれば回路サイズのさらなる小型化が望める。

6.2 精度予測に基づく代替モデル法によるトポロジー最適化の高速化 (第 4 章)

高精度な代替モデルの作成が難しい場合でも代替モデルを利用した最適設計を可能とするために、代替モデルの精度を予測する手法およびそれを用いた最適設計手法を提案した。提案法では深層学習により代替モデルの精度を予測し、その予測結果に基づいて電磁界解析と代替モデルを切り替えて最適設計を行う。

提案法で MSBPF の最適設計を行った結果、代替モデルの予測誤差に起因する最適化の失敗 (誤誘導) を回避しつつ、最適化時間を 9 倍高速化できた。提案法を用いることで、高精度な代替モデルの作成が難しい MSBPF についても代替モデルを利用した TO が可能であることを示した。また、提案法は学習データの生成には時間がかかるものの、一度学習が完了すればさまざまな最適化を高速に実行できることが明らかとなった。

今後の課題として代替モデルのアーキテクチャのさらなる検討が挙げられる。より多くのパラメータを持つモデルや、Vision Transformer などの最新のモデルにより代替モデルの予測精度結果が改善される可能性が残されている。

6.3 機械学習を用いたヒステリシス損失の高速解析 (第 5 章)

電磁デバイスにおけるヒス損の解析を機械学習により高精度かつ高速に実行する手法を提案し、インダクタの最適設計によりその有効性を検証した。提案法ではプレイモデルにより解析したヒステリシス特性を考慮したヒス損を NN に学習させ、入力波形から磁気エネルギーを直接予測する回帰モデルを作成し、ヒス損の解析に利用する。

インダクタのヒス損解析に対して提案法を適用した結果、プレイモデルを用いた高精度なヒス損解析手法と同様の解析結果を得つつ、計算時間を約 2,000 倍高速化できた。さらに提案法を用いてヒス損を最小化するインダクタの最適設計を実行した結果、NN の作成 (学習データの生成、NN の学習) に要する時間を含めて最適設計の所要時間を 2.5 倍高速化できた。

今後の課題として、本研究ではインダクタでしか提案法を検証しておらず、変圧器や電気モーターなどの他のデバイスへの有効性は不明である。また、本研究ではスカラーヒステリシスを考えており、ベクトルヒステリシスをモデル化するには改良が必要である。

謝辞

本研究を進めるにあたり、多くの方々からご支援とご指導を賜りましたことに深く感謝申し上げます。

学士過程からの5年間にわたり多大なるご指導をいただきました指導教員の五十嵐一教授に心より感謝申し上げます。五十嵐一教授には博士課程進学のお機会を与えてくださったとともに、研究の進め方や論文の執筆、発表の仕方など多くの面でご指導いただきました。私の至らなさをゆえに締切に余裕のない日程になってしまうことが多々ありましたが、ご多忙を極めるなか何度も速やかに添削していただきました。本当にありがとうございました。

野口聡教授、北裕幸教授には本論文の審査にあたりご指導、ご助言を頂きました。厚く御礼申し上げます。

技術職員の今井適氏には研究室の計算機サーバーや解析ソフトのライセンス等の管理において支援していただきました。厚く御礼申し上げます。事務補佐員の齊藤尚代氏には学会出張や試作基板の発注等の事務処理を補助していただきました。厚く御礼申し上げます。

本研究を進めるにあたり、住友電気工業株式会社の川崎健氏、田能村昌宏氏には学士過程からはじまった4年間の共同研究につきまして多大なるご協力をいただきました。深く感謝申し上げます。これまで私に投資してくださった以上のものを還元できるよう精進します。

本論文の第5章の執筆にあたり、株式会社JSOLの阿波根明氏には非常に有益なご助言をいただきました。厚く御礼申し上げます。

電磁工学研究室の皆様には、様々な助言と良い刺激をいただきました。感謝申し上げます。間藤昂允助教には研究だけでなく私生活に関する様々な助言をいただきました。厚く御礼申し上げます。研究室OBの林翔吾氏にはヒス損解析の研究に関して非常に有益なご助言をいただきました。また、私と似た境遇ということもありたくさんの励ましの言葉をいただきました。深く感謝申し上げます。

最後に、大学への進学のお機会を与えてくださり、勉学に専念できるよう支援していただきました両親に深く感謝いたします。

2025年2月
地引 琢人

参考文献

- [1] M. P. Bendsoe and O. Sigmund, Topology optimization: theory, methods, and applications, Springer Science & Business Media, 2003.
- [2] 五十嵐 一, 電磁界解析による最適設計, 森北出版, 2023.
- [3] T. Sato, K. Watanabe, H. Igarashi, "Multimaterial topology optimization of electric machines based on normalized gaussian network," *IEEE Trans. Magn.*, vol. 51, no. 3, 7202604, 2015.
- [4] J. A. Norato, B. K. Bell, D. A. Tortorelli, "A geometry projection method for continuum-based topology optimization with discrete elements," *Computer Methods in Applied Mechanics and Engineering*, vol. 293, pp. 306-327, 2015.
- [5] Y. Otomo, and H. Igarashi, "Topology optimization of magnetic cores for WPT using the geometry projection method," *COMPEL-The international journal for computation and mathematics in electrical and electronic engineering*, vol. 41, no. 3, pp. 889-899, 2022.
- [6] 小林, 実数値 GA のフロンティア, 人工知能学会論文誌, vol. 24, no. 1, pp. 147-162, 2009.
- [7] 秋本, 永田, 佐久間, 小野, 小林, 適応的実数値交叉 AREX の提案と評価, 人工知能学会論文誌, vol. 24, no. 6, pp. 446-458, 2009.
- [8] 上村健人, Exploration に着目した実数値遺伝的アルゴリズム, 東京工業大学, 博士論文, 2015.
- [9] N. Hansen, The CMA evolution strategy: A tutorial, 2016, arXiv:1604.00772.
- [10] C. A. C. Coello, "Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art," *Computer Methods in Applied Mechanics and Engineering*, vol. 191, no. 11, pp. 1245-1287, 2002.
- [11] E. Hassan, E. Wadbro, and M. Berggren, "Patch and ground plane design of microstrip antennas by material distribution topology optimization," *Progress In Electromagnetics Research B*, vol. 59, pp. 89-102, 2014.
- [12] T. Nomura, M. Ohkado, P. Schmalenberg, J. Lee, O. Ahmed, and M. Bakr, "Topology optimization method for microstrips using boundary condition representation and adjoint analysis," *Proceedings of 2013 European Microwave Conference*, pp. 632-635, 2013.
- [13] S. Yamasaki, T. Nomura, K. Sato, N. Michishita, Y. Yamada, A. Kawamoto, "Level set-based topology optimization targeting dielectric resonator-based composite right- and left-handed transmission lines," *International journal for numerical methods in engineering*, vol. 89, no.

- 10, pp. 1272-1295, 2012.
- [14] N. Aage, N. A. Mortensen, O. Sigmund, "Topology optimization of metallic devices for microwave applications," *Int. J. Num. Methods Eng.*, 83(2), 228-248, 2010.
- [15] N. Hieda, A. Iguchi, Y. Tsuji, K. Morimoto and T. Kashiwa, "Topology Optimization of NRD Guide Devices Using Covariance Matrix Adaptation Evolution Strategy," 2022 Asia-Pacific Microwave Conference (APMC), Yokohama, Japan, 2022, pp. 387-389, doi: 10.23919/APMC55665.2022.10000032.
- [16] S. Sato, T. Sato, H. Igarashi, "Topology Optimization of Synchronous Reluctance Motor Using Normalized Gaussian Network," *IEEE Trans. Magn.*, vol. 51, no.3, 8200904, 2015.
- [17] S. Hayashi, M. Yatsurugi, Y. Kubota, S. Soma, H. Igarashi, "Topology Optimization of a Surface Permanent Magnet Motor With High Torque Density," *IEEE transactions on magnetics*, 60(3), 1-5, 2023.
- [18] Y. Otomo, H. Igarashi, "A 3-D Topology Optimization of Magnetic Cores for Wireless Power Transfer Device," *IEEE Transactions on Magnetism*, vol. 55, no. 6, 8103005, 2019.
- [19] T. Mori, R. Murakami, Y. Sato, F. Campelo, H. Igarashi, "Shape optimization of wideband antennas for microwave energy harvesters using FDTD," *IEEE Trans. Magn.*, 51(3), 2015.
- [20] K. Itoh, H. Nakajima, H. Matsuda, M. Tanaka, and H. Igarashi, "Development of small dielectric lens for slot antenna using topology optimization with normalized Gaussian network," *IEICE Trans. Electron.*, vol.E101-C, no.10, pp.784-790, 2018.
- [21] D. K. Upadhyay, U. Kumar, G. K. Mishra, and B. L. Shahu, "Design of a Compact UWB Bandpass Filter using Via-Less CRLH TL," *J. Microw. Optoelectron. Electromagn. Appl.*, vol. 16, pp. 336-350, 2017.
- [22] C. C. Chen, Y. R. Chen, and C. Y. Chang, "Miniaturized microstrip crosscoupled filters using quarter-wave or quasi-quarter-wave resonators," *IEEE Trans. Microw. Theory Techn.*, vol. 51, no. 1, pp. 120-131, 2003.
- [23] T. Fujisawa and K. Saitoh, "Bayesian direct-binary-search algorithm for the efficient design of mosaic-based power splitters," *OSA Continuum*, vol. 4, no. 4, pp. 1258-1270, 2021.
- [24] T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microstrip Lines with Experimental Validation," *IEEE Transactions on Magnetism*, vol. 60, no. 3, pp. 1-4, March 2024.
- [25] J. S. Hong, *Microstrip Filters for RF/Microwave Applications*, 2nd ed., Wiley, 2011.
- [26] D. M. Pozar, *Microwave Engineering*, 4th ed., Wiley, 2011.
- [27] 谷口, マイクロ波電子回路—設計の基礎, 共立出版, 2004.
- [28] C. F. Chen, T. Y. Huang, and R. B. Wu, "Design of microstrip bandpass filters with multiorder spurious-mode suppression," *IEEE Trans. Microw. Theory Techn.*, vol. 53, no. 12, pp. 3788-3793, 2005.
- [29] C. C. Chen, Y. R. Chen, and C. Y. Chang, "Miniaturized microstrip cross-coupled filters using

- quarter-wave or quasi-quarter-wave resonators," *IEEE Trans. Microw. Theory Techn.*, vol. 51, no. 1, pp. 120-131, 2003.
- [30] T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microwave Devices with Thin Structure," *IEEE Transactions on Magnetics*, vol. 60, no. 12, pp. 1-4, Dec. 2024.
- [31] J-T Kuo, T-H Yeh, and C-C Yeh, "Design of microstrip bandpass filters with a dual-passband response," *IEEE Transactions on Microwave Theory Tech.*, 53(4), pp. 1331-1337, 2005.
- [32] C. Dapogny, C. Dobrzynski, and P. Frey, "Three-dimensional adaptive domain remeshing, implicit domain meshing, and applications to free and moving boundary problems," *J. Comput. Phys.*, vol. 262, pp. 358 – 378, 2014.
- [33] S.Hiruma, M.Ohtani, S.Soma, S.Kubota, H.Igarashi, "Novel hybridization of parameter and topology optimizations: Application to permanent magnet motor," *IEEE Trans. Magn.*, 57(7), 8204604, 2021.
- [34] H. Sasaki, H. Igarashi, "Topology optimization accelerated by deep learning," *IEEE Transactions on Magnetics*, vol. 55, no. 6, pp. 1-5, 2019.
- [35] H. Sasaki, Y. Hidaka, H. Igarashi, "Prediction of IPM machine torque characteristics using deep learning based on magnetic field distribution," *IEEE Access*, 10, 60814-60822, 2022.
- [36] S. Doi, H. Sasaki, H. Igarashi, "Multi-objective topology optimization of rotating machines using deep learning," *IEEE transactions on magnetics*, 55(6), 1-5, 2019.
- [37] H. Sasaki, Y. Hidaka, H. Igarashi, "Explainable deep neural network for design of electric motors," *IEEE Transactions on Magnetics*, 57(6), 1-4, 2021.
- [38] H. Sato, H. Igarashi, "Fast topology optimization for pm motors using variational autoencoder and neural networks with dropout," *IEEE transactions on magnetics*, 59(5), 1-4, 2023.
- [39] T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology optimization of a microstrip line with robustness consideration," *Proceedings of the 20th International IGTE Symposium on Computational Methods in Electromagnetics and Multiphysics*, p. 51, 2022.
- [40] T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microstrip Lines Using Twin Deep Neural Networks for Performance Prediction and Accuracy Evaluation," *IEICE Transactions on Electronics*, vol. E108-C, no. 9, pp. -, Sep. 2025.
- [41] E. A. Karahan, Z. Liu and K. Sengupta, "Deep-Learning-Based Inverse-Designed Millimeter-Wave Passives and Power Amplifiers," *IEEE Journal of Solid-State Circuits*, vol. 58, no. 11, pp. 3074-3088, 2023.
- [42] T. Akada and K. Fujimori, "Designing Microwave Circuits Using Genetic Algorithms Accelerated by Convolutional Neural Networks," 2020 50th European Microwave Conference (EuMC), Utrecht, Netherlands, pp. 61-64, 2021.
- [43] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," 2014, arXiv:1412.6980.

- [44] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv, 2014.
- [45] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. eeissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, and N. Houlsby, "An image is worth 16x16 words: Transformers for image recognition at scale," *International Conference on Learning Representations (ICLR)*, 2021.
- [46] J. Kaplan, S. McCandlish, T. Henighan, T. Brown, B. Chess, R. Child, S. Gray, A. Radford, J. Wu, D. Amodei, "Scaling laws for neural language models," arXiv:2001.08361, 2020.
- [47] G. Bertotti, *Hysteresis in Magnetism*. Academic Press, San Diego, CA, 1998.
- [48] H. Igarashi, *Topology Optimization and AI-based design of power electronic and electrical devices: principles and methods*. Academic Press, San Diego, CA, 2024.
- [49] K. Fujisaki Ed., *Magnetic Material for Motor Drive Systems*. Springer, Cham, 2019.
- [50] S. Yue, Y. Li, Q. Yang, X. Yu, C. Zhang, "Comparative analysis of core loss calculation methods for magnetic materials under nonsinusoidal excitations," *IEEE Trans. Magn.*, vol. 54, no. 11, Art no. 6300605, 2018.
- [51] J. Muhlethaler, J. Biela, J. W. Kolar, A. Ecklebe, "Improved core-loss calculation for magnetic components employed in power electronic systems," *IEEE Trans. Power Electronics*, vol. 27, no. 2, pp. 964-973, 2012.
- [52] I. Mayergoyz, "Mathematical models of hysteresis," *IEEE Trans. Magn.*, 22(5), pp.603-608, 1986.
- [53] S. Bobbio, G. Milano, C. Serpico, C. Visone, "Models of magnetic hysteresis based on play and stop hysterons," *IEEE Trans. Magn.*, vol. 33, no. 6, pp. 4417-4426, 1997.
- [54] T. Matsuo, M. Shimasaki, "An identification method of play model with input-dependent shape function," *IEEE Trans. Magn.*, vol. 41, no. 10, pp. 3112-3114, 2005.
- [55] S. Q. Antonio, F. R. Fulginei, A. Laudani, A. Faba, E. Cardelli, "An effective neural network approach to reproduce magnetic hysteresis in electrical steel under arbitrary excitation waveforms," *J. Magn. Magn. Mater.*, vol. 528, Art. no. 167735, 2021.
- [56] N. Vuokila, C. Cunning, J. Zhang, N. Akel, A. Khan, D. A. Lowther, "The Application of Neural Networks to the Modeling of Magnetic Hysteresis," *IEEE Trans. Magn.*, vol. 60, no. 3, pp. 1-4, 2024.
- [57] S. Quondam-Antonio, F. Riganti-Fulginei, A. Laudani, G.-M. Lozito, R. Scorretti, "Deep neural networks for the efficient simulation of macro-scale hysteresis processes with generic excitation waveforms," *Eng. Appl. Artif. Intell.*, vol. 121, Art. no. 105940, 2023.
- [58] C. Grech, M. Buzio, M. Pentella, N. Sammut, "Dynamic Ferromagnetic Hysteresis Modelling Using a Preisach-Recurrent Neural Network Model," *Materials*, vol. 13, no. 11, Art. no. 2561, 2020.
- [59] Y. Li, J. Zhu, Y. Li, L. Zhu, "A hybrid Jiles – Atherton and Preisach model of dynamic

- magnetic hysteresis based on backpropagation neural networks,” *J. Magn. Magn. Mater.*, vol. 544, Art. no. 168655, 2022.
- [60] T. Jibiki, H. Igarashi, ”A fast hysteresis analysis based on neural network and play model,” *IET Science, Measurement & Technology*, <https://doi.org/10.1049/smt2.12227>, Nov. 2024.
- [61] J. Kitao, Y. Takeda, Y. Takahashi, K. Fujiwara, A. Ahagon, T. Matsuo, ”Loss calculation method considering hysteretic property with play model in finite element magnetic field analysis,” *IEEE Trans. Magn.*, 50(2), 381-384, 2014.
- [62] Y. Takeda, Y. Takahashi, K. Fujiwara, A. Ahagon, T. Matsuo, ”Iron loss estimation method for rotating machines taking account of hysteretic property,” *IEEE Trans. Magn.*, 51(3), 7300504, 2015.
- [63] M. Gustav, M. Leijon, ”Review of play and Preisach models for hysteresis in magnetic materials,” *Materials*, 16(6), 2422, 2023.
- [64] X. Kong, Y. Uehara, N. Terauchi, N. Sato, Y. Matsuda, M. Nagano, H. Igarashi, ”Magnetic Property calibration for vibrating sample magnetometers based on magnetic field analysis,” *Proc. CEFC2024*, 2024.
- [65] S. Hayashi, Y. Uehara, N. Terauchi, N. Sato, Y. Matsuda, M. Nagano, H. Igarashi, ”A fast analysis of inductor core loss for arbitrary waveforms based on field clustering and its experimental validation,” to be submitted.

研究業績

査読付き原著論文

1. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microstrip Lines with Experimental Validation," *IEEE Transactions on Magnetics*, vol. 60, no. 3, pp. 1-4, March 2024.
2. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microwave Devices with Thin Structure," *IEEE Transactions on Magnetics*, vol. 60, no. 12, pp. 1-4, Dec. 2024.
3. T. Jibiki, H. Igarashi, "A fast hysteresis analysis based on neural network and play model," *IET Science, Measurement & Technology*, <https://doi.org/10.1049/smt2.12227>, Nov. 2024.
4. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microstrip Lines Using Twin Deep Neural Networks for Performance Prediction and Accuracy Evaluation," *IEICE Transactions on Electronics*, vol. E108-C, no. 9, pp. -, Sep. 2025.

国際学会発表

1. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of a Microstrip Line with Robustness Consideration," The 20th International IGTE Symposium (IGTE2022), P2-27, Graz, Austria, September 2022.
2. T. Kawasaki, T. Jibiki, M. Tanomura, H. Igarashi, "Hybridization of Parameter and Topology Optimizations Applied for Microwave Matching Circuits," 2022 Asia-Pacific Microwave Conference (APMC), pp. 199-201, Yokohama, Japan, November 2022.
3. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology Optimization of Microstrip Line with Experimental Validation," The 24th International Conference on the Computation of Electromagnetic Fields (Compumag 2023), PA-M3- 6, Kyoto, Japan, May 2023.
4. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "On predicting the accuracy of surrogate model based on deep learning for microstrip lines," The 21st International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF2023), OB-33, Pavia, Italy, September 2023.

5. T. Jibiki, T. Kawasaki, M. Tanomura, H. Igarashi, "Topology optimization of microwave devices with thin structure," The 21st Biennial IEEE Conference on Electromagnetic Field Computation (CEFC2024), MM_O3_04, Jeju, Korea, June 2024.

国内学会発表

1. 地引 琢人, 川崎 健, 田能村 昌宏, 五十嵐 一, 「深層学習によるマイクロストリップラインのトポロジー最適化の基礎検討」, 令和5年電気学会全国大会, 5-131, 名古屋, 3月, 2023.
2. 地引 琢人, 五十嵐 一, 「機械学習を用いたヒステリシス損失の解析」, 電気学会静止器・回転機合同研究会, SA-23-064, RM-23-063, 長岡, 8月, 2023.
3. 地引 琢人, 川崎 健, 田能村 昌宏, 五十嵐 一, 「深層学習によるマイクロ波フィルタの特性予測」, 2023年電気学会 電子・情報・システム部門大会, MC2-7, 札幌, 8月, 2023.
4. 地引 琢人, 五十嵐 一, 「機械学習によるヒステリシス損失の予測精度について」, 令和5年度 電気・情報関係学会北海道支部連合大会, 7, 函館, 10月, 2023.
5. 地引 琢人, 五十嵐 一, 「機械学習によるプレイモデルの近似表現について」, 第32回 MAGDA コンファレンス, OS-4-6, 金沢, 11月, 2023.
6. 地引 琢人, 林 翔吾, 阿波根 明, 五十嵐 一, 「機械学習を用いたヒステリシス損失の予測精度向上について」, 令和6年電気学会全国大会, 5-132, 徳島, 3月, 2024.

受賞

1. 北海道大学, 「クラーク賞」受賞, 2022年3月.
2. 日本 AEM 学会, 「第32回 MAGDA コンファレンス in 金沢 優秀講演論文賞」受賞, 2023年11月.
3. 公益社団法人 精密工学会北海道支部「精密工学会北海道支部 学生奨励賞」受賞, 2024年3月.
4. 一般社団法人 電気学会「令和6年電気学会全国大会優秀論文発表賞」受賞, 2024年8月.

付 録 A

平行結合線路帯域通過フィルタの設計

ここでは第 3.2.2 節において提案法との比較のために行った平行結合線路帯域通過フィルタの設計について、その詳細を述べる。

A.1 はじめに

平行結合線路帯域通過フィルタ（PC-BPF: parallel-coupled bandpass filter）はマイクロストリップライン（MSL: microstrip line）により実装する最も基本的な帯域通過フィルタ（BPF: bandpass filter）である。PC-BPF の構造を図 A.1 に示す。ここで、 $W_n, S_n, l_n (n = 1, \dots, N + 1)$ はそれぞれ信号ラインの幅、ギャップ、長さを表し、 Z_0 は信号ライン端部の特性インピーダンスを表す。PC-BPF では信号ラインを狭い間隔で配置して結合線路を構成し、ライン間の磁気結合を積極的に利用する。




図 A.1: 平行結合線路帯域通過フィルタ（PC-BPF）の構造 [24] ©2024 IEEE

表 A.1: プロトタイプフィルタの素子値

n	L'_n (nH)	C'_n (pF)	J_n (mS)
1	4.67	2.27	23.9
2	7.13	1.61	25.9
3	1.08	7.56	13.3
4	4.90	4.19	18.6
5	2.10	4.23	25.4
6	-	-	16.7

表 A.2: 調整後の信号ライン寸法 [24] ©2024 IEEE

n	l_n (mm)	W_n (μm)	S_n (μm)
1	13.310	617	69
2	11.548	46	118
3	17.604	360	187
4	22.102	124	199
5	13.836	29	129
6	20.744	596	68

A.2 設計手順

PC-BPF の設計手順の概要を以下に示す ($n = 1, \dots, N$).

1. プロトタイプフィルタを設計する (N, L'_n, C'_n を決定する)
2. アドミタンス変換器の定数 J_n を計算する
3. 結合線路の偶モードと奇モードの特性インピーダンス Z_{0e}^n, Z_{0o}^n を計算する
4. ポートのライン幅 W_0 , 誘電体厚さ d , 比誘電率 ϵ_r を決定する
5. 信号ラインの幅 W_n とギャップ S_n を求める
6. 信号ラインの長さ l_n を計算する
7. 理想の特性に近づくように寸法 W_n, S_n, l_n を調整する

最初に集中定数素子からなるフィルタの等価回路であるプロトタイプフィルタによって、所望のフィルタ特性を表現する．次にプロトタイプフィルタを分布定数回路、つまり MSL に変換し、各信号ラインの寸法を決定する．最後に信号ラインの寸法を調整することで、MSL に変換する際に生じる誤差を吸収する．

A.3 設計した結果

3.2.2 節においてガウス基底関数法 (NGnet 法) によって設計したマイクロストリップ BPF と同一の特性の PC-BPF を設計した結果を表 A.1, 表 A.2 に示す．

参考文献

- [A1] J. S. Hong, Microstrip Filters for RF/Microwave Applications, 2nd ed., Wiley, 2011.
[A2] D. M. Pozar, Microwave Engineering, 4th ed., Wiley, 2011.
[A3] 谷口, マイクロ波電子回路—設計の基礎, 共立出版, 2004.