



Title	深層学習を用いた回転機のトポロジー最適化に関する研究
Author(s)	佐々木, 秀徳
Citation	北海道大学. 博士(工学) 甲第14578号
Issue Date	2021-03-25
DOI	10.14943/doctoral.k14578
Doc URL	http://hdl.handle.net/2115/86869
Type	theses (doctoral)
File Information	Hidenori_Sasaki.pdf



[Instructions for use](#)

SSI-DT46195030

博士論文

深層学習を用いた回転機のトポロジー最適化に関する研究

佐々木 秀徳

2021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(工学)授与の要件として提出した博士論文である.

佐々木 秀徳

指導教員： 五十嵐 一 教授
審査委員： 主査 五十嵐 一 教授
副査 小笠原 悟司 教授
北 裕幸 教授
野口 聡 准教授

Copyright ©2021 by Hidenori Sasaki. All right reserved.

深層学習を用いた回転機のトポロジー最適化に関する研究*

佐々木 秀徳

概要

近年、世界的な環境規制によりエネルギーの高効率化が求められ、自動車、鉄道、船舶や航空機等の輸送機器や産業機器のエンジン機構及び油圧機構の電動化が図られている。電動機器の多くはモータを有しており、機器全体に占めるモータの消費電力が大きく、高効率化が求められる。また、機器の軽量化や小型化の要求も強く、高効率、高出力密度を両立した限界設計が必須となってきている。しかし、複数の因子を考慮しながらの設計は容易ではない。特に埋込型同期磁石 (IPM: Interior Permanent Magnetic) モータは設計の自由度が高く、より効率的な設計手法の確立が望まれている。

また、計算機技術の向上により、大規模計算が広く盛んに用いられている。それに伴い、数値シミュレーション技術に関する研究が盛んとなり、電磁界設計分野においても様々な解析技術が開発されている。特に有限要素法 (FEM: Finite Element Method) はコンピュータ支援設計 (CAD: Computer aided design) との親和性も高く、広く普及している。さらに、最適化技術を FEM と連成することで、より効率的に適切な磁気構造を探索する手法が研究、開発されている。最適化手法として設計パラメータを変数とし、遺伝的アルゴリズム (GA: Genetic Algorithm) を用いて所望の特性を有する形状を探索するパラメータ最適化が主流である。本手法は製品開発の下流である詳細設計において有効な手段であるが、上流である概念設計ではパラメータを設置できず、適用しにくい。そこで、設計パラメータを用いず、適切な材料分布を物性の増減も考慮しながら最適化するトポロジー最適化が注目されている。しかし、本手法は探索空間が多次元となり複雑になる場合が多い。そのため、探索に必要な FEM による解析回数が膨大となり、現実的な最適化時間で解が得られない場合がある。

そこで、電気機器磁気特性を同定するために FEM の代わりに深層学習 (DL: Deep Learning) を用い、トポロジー最適化時間を短縮することに注目している。DL は自動的に特徴量を抽出することができ、特徴量設計が困難なデータに対して有効である。特に畳込みニューラルネットワーク (CNN: Convolutional Neural Network) は画像の特徴量抽出能力に優れており、機械学習 (ML: Machine Learning) における物体認識精度向上の突破口となる技術で注目されている。しかし、回転機の二次元断面材料分布とトルク特性の関係を CNN に学習させた場合の推定値は FEM をはじめとした電磁界解析に代わる推定精度を有してはならず、更なる推定精度向上が求められる。また、様々な回転機への適用が望まれるが、形状汎化に関する検討は少ない。さらに、CNN を設計に適用するにあたり、推定結果に対する根拠が明確ではないため、最適化結果に対する信頼性が失われてしまう課題がある。

*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-DT46195030, 2021 年 2 月 12 日.

以上の背景から、以下の三点に関して検討を行った。

1. CNN のモータ磁気特性推定精度向上とトポロジー最適化への影響

本検討として磁束密度分布を入力とした学習手法を提案した。特に回転機の磁気特性は電磁鋼板の磁気的非線形特性が大きく影響される。磁束密度を用いることで磁気的非線形特性を CNN に学習させることが可能となり、二次元断面材料分布を学習させた場合よりも磁気特性の推定精度が向上することを示した。さらに、トポロジー最適化に CNN を用いる場合、推定精度の高い CNN を用いたほうが高い探索性能を持つことを示した。

2. CNN による推定可能形状汎化手法の提案

本検討として異なる磁石配置に対する汎化手法に関する検討を行った。IPM モータの場合、磁石配置が異なると磁気特性が大きく異なるため、同一 CNN へさせた際にトルク特性に対する特徴量抽出可能か不明である。そこで、様々な仕様のモータを同一 CNN へ学習し、形状汎化させる学習手法を提案した。その結果、同時学習によって異なる磁石配置を持つ形状の磁気特性を学習することが可能であることを示し、さらにその推定器を用いて複数磁石配置を考慮した新たなモータ形状トポロジー最適化手法の提案を行った。

3. CNN 推定根拠可視化技術のモータへの適用と新たな局所探索手法の提案

説明可能な CNN の磁気特性への適用に関する検討を行った。説明根拠を可視化する技術として CNN へ入力した画像の推定要因となる領域を可視化する Grad-CAM が提案されている。本手法によりトルク特性に寄与する領域の可視化が可能であることを示した。さらにトポロジー最適化に本手法を適用した二段階最適化手法の開発を行い、従来の最適化に比べ有用性があることを示した。

キーワード: トポロジー最適化, 深層学習, 回転機, 有限要素法

Study on topology optimization for electrical machine using deep learning[†]

Hidenori Sasaki

Abstract

This paper propose some new topology optimization method using convolutional neural network (CNN) and discuss search performance of the proposed methods.

Since the environmental regulations are required, actively developments of highly efficient electrical equipment has been important topics in manufacturing industries. There is a strong demand for lighter and smaller devices, and it is becoming essential to design limits with both high efficiency and high power density. Therefore, it is hard to design the equipment which satisfies required specification.

Topology optimization based on genetic algorithm has attracted significant attention and is becoming used for design and development, It is a breakthrough method to find novel shapes. However, if the analytical model has a fine mesh, the optimization time will increase because of analysis time of finite element method(FEM).

Therefore, the method of cleating a surrogate model for FEM and using it for optimization has been proposed. In particular, CNN can extract shape features from images by convolutional processing, which is considered to be compatible with topology optimization without shape parameters. However, there are several issues that need to be addressed for the general use CNNs within topology optimization.

From the above, this paper discuss the following three topics.

1. Improving the accuracy of CNN for motor magnetic property estimation and impact on topology optimization
2. Generalization methods for shapes which CNN can estimate
3. Local search method using explainable deep neural network for design of electric motors

Keywords: Topology optimization, Deep learning, Rotating machine, Finite element method

[†]Doctoral Thesis, Course of Systems Science and Informatics, Graduate School of Information Science and Technology, Hokkaido University, SSI-DT46195030, February 12, 2021.

目次

第1章 序論	1
1.1 研究背景	1
1.2 研究目的	4
1.2.1 CNNを用いたモータ特性推定精度向上手法	4
1.2.2 CNNによる推定可能形状汎化手法	5
1.2.3 CNN推定根拠可視化技術を用いた局所探索手法	5
1.3 本論文の構成	5
第2章 トポロジー最適化およびモータの基礎理論	7
2.1 はじめに	7
2.2 数値解析手法	7
2.2.1 概要	7
2.2.2 電磁界解析	7
2.2.3 二次元静磁場解析における有限要素法の定式化	8
2.2.4 モータ解析で用いる諸条件	10
2.3 数理計画問題	11
2.3.1 概要	11
2.3.2 定義	11
2.3.3 解法	12
2.3.4 遺伝的アルゴリズム	13
2.3.5 単目的最適化	17
2.3.6 多目的最適化	19
2.4 形状表現手法	25
2.4.1 概要	25
2.4.2 基底関数を用いたON/OFF法	25
2.5 モータ理論	29
2.5.1 概要	29
2.5.2 永久磁石同期モータ	29
2.5.3 モータ特性	30
2.5.4 数学モデル	31
2.5.5 三相二相変換	32
2.5.6 二相回転座標変換	32
2.5.7 理論トルク	34
2.5.8 電流位相	35
2.5.9 本研究で扱う最適化問題における理論的解釈	35

2.5.10	節点力法によるトルク導出	36
2.5.11	電気学会 D モデル	37
2.6	計算機環境	40
2.7	総括	40
第 3 章	CNN を用いたモータ特性	
	推定精度向上手法の提案	41
3.1	はじめに	41
3.2	深層学習	42
3.2.1	概要	42
3.2.2	ニューラルネットワーク	42
3.2.3	畳込みニューラルネットワーク	45
3.2.4	学習方法	47
3.3	磁気的非線形性を考慮した CNN による 特性推定	50
3.3.1	概要	50
3.3.2	学習対象モータ	50
3.3.3	有限要素モデル	50
3.3.4	NGnet の設定	52
3.3.5	学習ネットワーク	52
3.3.6	教師データ	53
3.3.7	磁束密度分布による精度への影響	56
3.3.8	学習条件	57
3.3.9	分類問題における推定結果	58
3.3.10	回帰問題における推定結果	58
3.3.11	異なるデータセットによる回帰問題推定結果	63
3.3.12	トルクリップル発生原理	64
3.3.13	トルク振幅の推定	66
3.3.14	磁束密度分布による推定精度の検証	67
3.3.15	回転子のみを学習した場合の効果	69
3.4	磁気的非線形性を考慮した CNN を用いた トポロジー最適化	71
3.4.1	概要	71
3.4.2	基本アルゴリズム	71
3.4.3	最適化設定	71
3.4.4	最適化結果	73
3.4.5	最適解形状の考察	73
3.4.6	CNN の教師データ種類の違いによる最適解への影響	76
3.4.7	最適化時間	76
3.5	総括	77

第 4 章 CNN による推定可能形状	
汎化手法の提案	79
4.1 はじめに	79
4.2 汎化方法	80
4.3 学習条件	81
4.3.1 概要	81
4.3.2 学習ネットワーク	81
4.3.3 学習対象	81
4.4 学習結果	82
4.4.1 単一学習	82
4.4.2 追加学習	82
4.4.3 同時学習	88
4.4.4 学習手法の比較	89
4.5 形状汎化 CNN を用いた回転子形状のトポロジー最適化	90
4.5.1 概要	90
4.5.2 提案手法	90
4.5.3 最適化条件	92
4.5.4 最適化結果	92
4.5.5 トポロジー最適化における CNN の効果	95
4.6 総括	95
第 5 章 CNN 推定根拠可視化技術を用いた	
局所探索手法の提案	97
5.1 はじめに	97
5.2 CNN 推定根拠可視化技術	98
5.2.1 概要	98
5.2.2 Grad-CAM	98
5.3 回転機特性推定根拠の可視化	99
5.3.1 概要	99
5.3.2 適用条件	99
5.3.3 Grad-CAM の適用対象	101
5.3.4 Grad-CAM に用いる畳込み層の決定	101
5.3.5 Grad-CAM の適用結果	104
5.4 CNN 推定根拠可視化技術を用いたトポロジー最適化	107
5.4.1 概要	107
5.4.2 最適化アルゴリズム	107
5.4.3 最適化設定	108
5.4.4 最適化結果	109
5.5 総括	117

第 6 章 結論	119
6.1 CNN を用いたモータ特性推定精度向上手法の提案 (第 3 章)	119
6.2 CNN による推定可能形状汎化手法の提案 (第 4 章)	119
6.3 CNN 推定根拠可視化技術を用いた局所探索手法の提案 (第 5 章)	120
6.4 今後の展望	120
参考文献	123
研究業績	131
謝辞	135

目 次

1.1	一般的な電動機の開発プロセス	2
2.1	浮き節点に対する処理	11
2.2	遺伝的アルゴリズム概要	14
2.3	遺伝子表現概要	14
2.4	BLX- α	15
2.5	REX ^{star}	16
2.6	Rastrigin 関数 ($n = 2$)	19
2.7	テスト関数を用いた単目的最適化結果	20
2.8	多目的最適化におけるパレート解	24
2.9	NSGA-II のフロー	24
2.10	NSGA-II におけるランク付け	24
2.11	テスト関数を用いた多目的最適化結果	25
2.12	正規化ガウス関数ネットワーク	27
2.13	基底関数を用いた ON/OFF 法	28
2.14	永久磁石同期モータの概要	29
2.15	永久磁石同期モータにおける回転子	30
2.16	トルク発生要因	31
2.17	永久磁石同期モータの物理モデル	33
2.18	三相 \rightarrow 二相変換	33
2.19	dq 変換	34
2.20	マグネットトルクおよびリラクタンストルクの概要	36
2.21	節点力法	37
2.22	電気学会 D モデル	38
2.23	電気学会 D モデルトルク波形	39
2.24	電気学会 D モデルトルク次数成分	39
2.25	電気学会 D モデル磁束分布	40
3.1	perceptron	43
3.2	sigmoid 関数	44
3.3	ReLU 関数	44
3.4	分類問題と回帰問題	45
3.5	畳込みニューラルネットワーク	45
3.6	畳込み処理	46
3.7	pooling 処理	47

3.8	トポロジー最適化対象形状	51
3.9	有限要素モデル	51
3.10	ガウス基底の配置	52
3.11	VGG16	53
3.12	入力データとして用いたビットマップ例	53
3.13	50A470 の BH カーブ	54
3.14	回転子コア部の連結制約 ($\Omega = 3$ の場合)	56
3.15	異なる推定値における材料分布と磁束密度分布の比較	57
3.16	I 字磁石配置 IPM の平均トルク回帰問題推定結果	61
3.17	I 字磁石配置 IPM のトルクリップル回帰問題推定結果	61
3.18	V 字磁石配置 IPM の平均トルク回帰問題推定結果	62
3.19	V 字磁石配置 IPM のトルクリップル回帰問題推定結果	62
3.20	回帰問題における推定器の損失関数推移	63
3.23	平均トルクとトルクリップルおよび振幅の関係	67
3.21	I 字磁石配置 IPM の振幅回帰問題推定結果	68
3.22	V 字磁石配置 IPM の振幅回帰問題推定結果	68
3.24	回転子領域のみを表した入力ビットマップ	70
3.25	I 字磁石配置 IPM の回転子領域のみを用いた平均トルク回帰問題推定結果	70
3.26	CNN を用いたトポロジー最適化アルゴリズム	72
3.27	CNN を用いたトポロジー最適化における最適解	74
3.28	CNN を用いたトポロジー最適化における評価値の推移	75
3.29	CNN を用いたトポロジー最適化における FEM 評価個体数の推移	75
3.30	材料分布および磁束密度分布を用いた CNN の平均トルクの推定例	76
3.31	CNN を用いたトポロジー最適化の最適化時間	77
4.1	CNN の形状汎化手法の例	80
4.2	テスト関数による α の効果検証	85
4.3	追加学習における第二段階学習における α とテストデータによる推定精度	86
4.4	追加学習における第二段階学習における α ごとの損失関数の推移	88
4.5	同時学習における損失関数の推移	89
4.6	形状汎化 CNN を用いたトポロジー最適化のフロー	91
4.7	形状汎化 CNN を用いたトポロジー最適化の最適解	93
4.8	形状汎化 CNN を用いたトポロジー最適化の評価値の推移	94
4.9	形状汎化 CNN を用いたトポロジー最適化の世代ごとの個体数の推移	94
4.10	形状汎化 CNN を用いたトポロジー最適化の世代ごとの FEM を用いた評価回数	95
5.1	Grad-CAM の概要	99
5.2	各クラスに対応したビットマップ例	102
5.3	各層に対する Grad-CAM 適用結果	105
5.4	各クラスに対する Grad-CAM 適用結果	106
5.5	Grad-CAM を用いたトポロジー最適化アルゴリズム	108

5.6	Grad-CAM を用いたトポロジー最適化における第一段階最適化の最適解 . . .	109
5.7	第一段階最適化の最適解に Grad-CAM を適用した結果	110
5.8	Grad-CAM を用いたトポロジー最適化における $\xi = 0.5$ の場合における第 二段階最適化の設計領域	110
5.9	Grad-CAM を用いたトポロジー最適化における $\xi = 0.5$ の場合における第 二段階最適化の最適解	111
5.10	Grad-CAM を用いたトポロジー最適化における第二段階最適化の評価値の 推移	112
5.11	Grad-CAM を用いたトポロジー最適化における第二段階最適化の平均トル クの推移	112
5.12	Grad-CAM を用いたトポロジー最適化における第二段階最適化のトルク リップルの推移	113
5.13	Grad-CAM を用いたトポロジー最適化における閾値 ξ を変更した場合の第 二段階最適化の設計領域	113
5.14	Grad-CAM を用いたトポロジー最適化における閾値 ξ を変更した場合の第 二段階最適化の最適解	114
5.15	Grad-CAM を用いたトポロジー最適化における第二段階最適化 $\xi=0.1$ で得 られた最適解のトルク波形	115
5.16	Grad-CAM を用いたトポロジー最適化における第二段階最適化の評価値の 推移	115
5.17	Grad-CAM を用いたトポロジー最適化における第二段階最適化の平均トル クの推移	116
5.18	Grad-CAM を用いたトポロジー最適化における第二段階最適化のトルク リップルの推移	116
5.19	提案手法と多目的最適化との比較	118

表 目 次

1.1	最適化の基本構成	3
2.1	数理計画解法	12
2.2	テスト関数を用いた単目的最適化設定	21
2.3	多目的最適化の最適化設定	23
2.4	電気学会 D モデル仕様	38
2.5	計算機環境	40
3.1	有限要素モデルの緒言	51
3.2	分類問題における平均トルクおよびトルクリップルの分類	55
3.3	教師データ生成時の単目的最適化の最適化設定	55
3.4	教師データ生成時の多目的最適化の最適化設定	55
3.5	分類問題および回帰問題における学習条件	57
3.6	I 字磁石配置 IPM の平均トルク分類問題推定結果	59
3.7	I 字磁石配置 IPM のトルクリップル分類問題推定結果	59
3.8	V 字磁石配置 IPM の平均トルク分類問題推定結果	60
3.9	V 字磁石配置 IPM のトルクリップル分類問題推定結果	60
3.10	I 字磁石配置 IPM の平均トルクおよびトルクリップルの回帰問題推定結果 の相関係数および誤差率	65
3.11	V 字磁石配置 IPM の平均トルクおよびトルクリップルの回帰問題推定結果 の相関係数および誤差率	65
3.12	CNN を用いたトポロジー最適化における最適化設定	72
3.13	CNN を用いたトポロジー最適化における FEM の解析確率設定	73
4.1	汎化学習条件	81
4.2	教師データ生成時の単目的最適化の最適化設定	82
4.3	単一学習における I 字磁石配置学習推定器のテスト結果	83
4.4	単一学習における V 字磁石配置学習推定器のテスト結果	83
4.5	追加学習における V 字 → I 字学習推定器 $\alpha=0.9$ のテスト結果	84
4.6	追加学習における I 字 → V 字学習推定器 $\alpha=0.9$ のテスト結果	84
4.9	追加学習における第二段階学習における α とテストデータによる推定精度	86
4.7	追加学習における V 字 → I 字学習推定器 $\alpha=0.0$ のテスト結果	87
4.8	追加学習における I 字 → V 字学習推定器 $\alpha=0.0$ のテスト結果	87
4.10	同時学習のテスト結果	89
4.11	形状汎化 CNN を用いたトポロジー最適化における最適化設定	92

4.12	形状汎化 CNN を用いたトポロジー最適化における解析確率	92
5.1	平均トルク最大化問題における最適化設定	100
5.2	分類問題における学習条件	100
5.3	Grad-CAM 適用時の平均トルクの分類	100
5.4	学習済み VGG16 の性能評価	101
5.5	学習済み VGG16 の分類誤差個体数	103
5.6	Grad-CAM を用いたトポロジー最適化設定	108
5.7	多目的最適化の最適化設定	117

第1章 序論

本章ではまずはじめに本研究の研究背景を述べる。続いて研究目的について述べ、最後に本論文の構成について述べる。

1.1 研究背景

近年、世界的な環境規制により自動車、鉄道、船舶や航空機等の輸送機器や産業機器のエンジン機構及び油圧機構の電動化や現在利用されているモータの高効率化、高性能化が強く求められている [1]。モータの代表例としてエアコンや冷蔵庫の圧縮機、鉄道の主電動機、エレベータの巻上機などが挙げられる [2]。自動車においてはエンジン効率向上のためのバブル調整機構の電動化、エンジンの代替として主動モータ、パワーステアリングの電動化が盛んである。また、産業界においても工場自動化 (FA: Factory Automation) が進められ、製造ラインにおいて多くのモータが用いられている。

モータには様々な駆動原理があり、用途に応じて多岐に渡る磁気構造、制御手法が用いられる [3]。モータの普及初期から用いられていた構造として、巻線界磁 DC モータが挙げられる。巻線界磁 DC モータは回転子にブラシ機構があり、回転に応じて回転子励磁巻線に流れる直流方向を切り換えることによって磁化方向を変動させ、回転子を駆動する [4]。本モータに用いられるブラシは金属が物理的に接触しているため、機械摩擦や電機摩擦による劣化が懸念される。そこで、ブラシを用いない交流モータが盛んに用いられている。交流モータは界磁巻線に通電する交流を制御することによって、回転磁界を発生させ、回転子を駆動する。近年はインバータの性能の向上に伴い、複雑な交流制御が可能である。交流モータの駆動原理として誘導モータや同期モータが挙げられる。さらに、同期モータにおいては、トルク出力向上や高効率化の観点から永久磁石を用いた永久磁石同期モータや永久磁石を用いないシンクロナスリラクタンスモータ、ステッピングモータなどの開発が盛んである [5]。

このように今日におけるモータの種類・用途は多種多様であり、それぞれの用途に対して求められる構造や特性が異なる。モータ単体で評価すべき項目は、平均トルク、トルクリップル等に対する回転速度特性や電流特性、電磁加振力、効率、振動、騒音など多岐に渡る。これらの特性はトレードオフな関係を持つ場合が多く、複数の特性の均衡点を狙ったモータ機器設計することは容易ではない。また、機器の軽量化や小型化の要求も強く、高効率、高出力密度を両立した限界設計が必須となってきている。また、永久磁石同期モータのような永久磁石を用いたモータの場合、磁石の配置・配向パターンまで考慮する必要があり、設計自由度が非常に高く、最適形状を人力で設計することは難しい。以上のことから、より効率的に最良な形状を設計可能な手法が求められている。

一般的な永久磁石モータの設計フローを図 1.1 に示す [6]。モータ設計の際には一般的に

仕様設計を行ったのち、極対数、永久磁石による電機子鎖交磁束を仮決定し、インダクタンス値や磁気抵抗等から各種特性計算を行う。各種特性が要求仕様を満たしているか確認したのち、前ステップに戻り再検討を行う。これらの特性値は理論式および磁気回路法等によって求めることが多い [7]。さらに高精度な特性値を得るため、複数の要素に分割し、偏微分方程式の近似解を求める有限要素法 (FEM: Finite Element Method) が広く用いられている [8]。

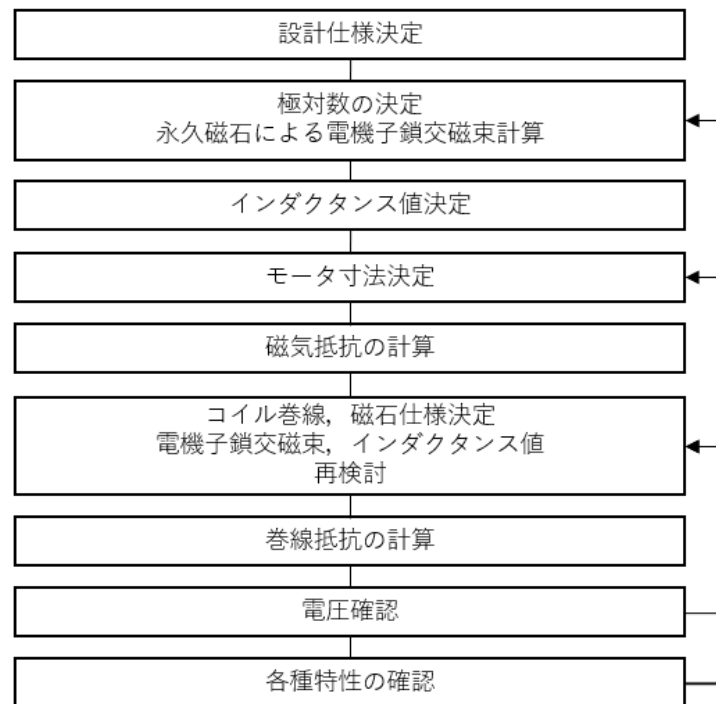


図 1.1: 一般的な電動機の開発プロセス [6]

その背景には、計算機技術の発展が挙げられる。計算機技術はハードウェアおよびソフトウェアの両面で飛躍的に向上している [9]。現在では数十年前には不可能であった規模の計算機を各研究機関および企業で簡単に利用可能な環境となっている。特に FEM はコンピュータ支援設計 (CAD: Computer Aided Design) との親和性も高く、実装も容易であることから広く普及している。本手法により、物理現象をより厳密に表現可能となり、設計精度が飛躍的に向上する。しかし、トレードオフ関係の均衡点探索には多数の条件における解析を行う必要があり、設計者にとって非常に苦勞を要する作業となっている。

さらに、所望の条件を満たす最適解を探索する最適化手法が情報工学分野で盛んに研究されている。探索アルゴリズムとして数理計画法に基づく最急降下法やニュートン法があるが、近年はメタヒューリスティクス手法として実装が容易な遺伝的アルゴリズム (GA: Genetic Algorithm) 等が有力な探索手法として注目されている [10]。

設計分野においては、本手法を応用した自動設計技術に関する研究開発が盛んである。さらに近年は再検討による工数増大を抑えることを目的にシミュレーション内で様々な物

理現象を考慮しつつ設計を行うモデルベース開発の考え方も普及しつつある [11]. 表 1.1 に最適化概要を示す. 自動設計技術は探索アルゴリズム, 形状表現手法, 数値解析を用い, 所望の特性を満たす機器仕様を導き出す. 文献 [12] では FEM を用いた自動設計技術をモータに適用している. 本手法は物性境界に対して設計パラメータを設定し, 探索アルゴリズムに応じて物性境界を変動させ, 適切なパラメータを得るパラメータ最適化である. 近年, パラメータ最適化は多くの現場で用いられており, 開発への適用例が多く報告されている [13]. 本手法はある程度設計指針が定まり, 形状がある程度決定している詳細設計段階で有効な手法であると考えられる.

一方, 詳細設計の前段階である概念設計段階では適切な材料分布が決定していない場合が多いため, 材料境界の個数や相対位置を規定することが難しく, パラメータ最適化の適用は難しい [14]. 本来, 概念設計段階で設計指針を明確にすることで, 設計の後戻りを防ぐことが可能である. そこで, 概念設計段階で用いることが可能な自動設計技術が求められている.

このような背景から, 本研究では設計パラメータを用いず最適化可能なトポロジー最適化に着目している [15]. トポロジー最適化はパラメータを設けず, 物性の増減を考慮して最適化を行うことができる. パラメータ最適化に比べ自由度の高い最適化を行うことが可能なため, 概念設計に有効であると考えられる.

文献 [16][17] において構造解析分野のトポロジー最適化手法の応用に関して検討されている. 文献 [18] においては on/off 法をベースとした最適化手法をインダクタの電磁気特性最適化に適用されている. さらに, 本手法のモータ設計への応用も試みられている. 文献 [19][20] においてはレベルセット関数を用いたモータトポロジー最適化手法を提案されている. また, 文献 [21] においてはガウス基底関数を用いたモータトポロジー最適化手法を提案されている.

これらの手法は過去の設計を凌駕する形状を生み出す可能性が高い. しかし, 探索空間が多次元となり複雑になる場合が多く, 探索に必要な FEM による解析回数が膨大となり, 現実的な最適化時間で解が得られない場合がある.

表 1.1: 最適化の基本構成

数理計画問題	形状表現手法	数値解析技術
・ヒューリスティクス	・ ON/OFF 法	・ 電磁界解析
- 遺伝的アルゴリズム (GA)	- NGnet-ON/OFF 法	- 磁界有限要素法
- 焼きなまし法 (SA)	- フーリエ級数-ON/OFF 法	- FDTD 等
- 粒子群最適化 等	- フィルタリング手法 等	・ 鉄損解析
・ 連続最適化問題	・ 密度法	- 1-D 法
- 最急降下法	・ レベルセット法 等	- プレイモデル 等
- 共役勾配法		・ 応力解析
- ニュートン法 等		- 力学有限要素法 等

また, 近年は CPU(Central Processing Unit) および GPU(Graphics Processing Unit) の性能向上が著しい. GPU は 3D グラフィック処理を行うために用いられる半導体チップ

であり、物体移動における大量の行列計算を並列に処理することが可能である。本特徴を応用し、大量の行列計算が必要な深層学習 (DL: Deep Learning) が台頭してきた [22][23]。DL は様々なデータの特徴量抽出を得意とするため、様々な事象の代理モデルとなり得る。特に畳込みニューラルネットワーク (CNN: Convolutional Neural Network) は画像の特徴量抽出能力に優れており、機械学習 (ML: Machine Learning) における物体認識精度向上の突破口となる技術で注目されている。Google による AlphaGO[24] の開発が話題となるなど、IT のみならず、医療、福祉、製造業などさまざまな分野で応用が期待されている。

DL は過去に得たデータベース (DB:Data Base) を用いて、必要な知見を抽出可能である。一方、最適化は未探索空間を開拓する技術である。しかし、探索の過程ですべてが未探索空間ではなく、過去に探索した空間を再度探索する場合もある。これらの観点から、電気機器磁気特性を同定するために FEM の代わりに DL を用い、最適化時間を短縮することに着目している [25][26]。しかし、モータの二次元断面材料分布とトルク特性の関係を CNN に学習させた場合の推定値は FEM をはじめとした電磁界解析に代わる推定精度を有してはおらず、最適化内では FEM の援用的利用をしている。CNN を用いた最適化により効率的に探索するためには更なる CNN の推定精度向上が求められる。また、本手法の更なる適用範囲の拡大には CNN を推定特性や形状の汎化も望まれる。さらに、DL を用いて推定を行った場合、推定根拠が不明であり、信頼性に難がある。そこで近年、推定根拠の明確化が可能な DL に関する研究が行われている [27]。最適化で得られた最適解の解釈も困難な場合があり、解の特性に対する説明性が求められている。

1.2 研究目的

本研究の目的は電気機器の設計に利用可能なトポロジー最適化手法のさらなる改善である。本研究では前節で述べた問題点を解決するために以下の 3 つの手法の検討・提案を行う。

- CNN を用いたモータ特性推定精度向上手法
- CNN による推定可能形状汎化手法
- CNN 推定根拠可視化技術を用いた局所探索手法

1.2.1 CNN を用いたモータ特性推定精度向上手法

本検討では磁束密度分布を入力とした学習手法を提案する [28][29]。特にモータの磁気特性は電磁鋼板の磁気的非線形特性が大きく影響される。したがって、磁束密度を用いることで磁気的非線形特性を CNN に学習させることが可能となり、二次元断面材料分布を学習させた場合よりも磁気特性の推定精度が向上することを示す。さらに、トポロジー最適化に CNN を用いる場合、磁束密度分布学習した CNN のほうが材料分布を用いた場合に比べ高い探索性能を持つことを示す。

1.2.2 CNNによる推定可能形状汎化手法

次に異なる磁石配置に対する汎化手法に関する検討を行う [30]. IPM モータの場合, 磁石配置が異なると磁気特性が大きく異なるため, 同一 CNN へさせた際にトルク特性に対する特徴量抽出可能か不明である. そこで, 様々な仕様のモータを同一 CNN へ学習し, 形状汎化させる学習手法を提案する. 本手法により, 同時学習によって異なる磁石配置を持つ形状の磁気特性を学習することが可能であることを示す. さらにその推定器を用いて新たな最適化手法の提案を行う.

1.2.3 CNN 推定根拠可視化技術を用いた局所探索手法

さらに, 説明可能な CNN の磁気特性への適用に関する検討を行う [31][32]. 説明根拠を可視化する技術として CNN へ入力した画像の推定要因となる領域を可視化する Grad-CAM が提案されている. 本手法によりトルク特性に寄与する領域の可視化が可能であることを示す. さらに最適化に適用し, 二段階最適化手法の開発を行い, 従来の最適化に比べ有用性があることを示す.

1.3 本論文の構成

以下に, 本論文の内容を各章ごとに概説する.

第1章 序論

本研究の背景について述べる. 次に, 本研究の目的について述べる. 最後に本論文の構成について述べる.

第2章 トポロジー最適化およびモータの基礎理論

本研究の対象となるモータのトポロジー最適化に関する基礎検討について述べる.

第3章 CNN を用いたモータ特性推定精度向上手法の提案

モータ磁気特性を推定する CNN の推定精度向上手法について述べる. さらに, トポロジー最適化に CNN を適用し, 探索性能への影響を述べる.

第4章 CNN による推定可能形状汎化手法の提案

CNN の推定可能形状汎化手法について述べる. さらに, 本手法を用いた新たなトポロジー最適化手法について述べる.

第5章 CNN 推定根拠可視化技術を用いた局所探索手法の提案

CNN による説明性をモータ磁気特性推定に用いる. さらに, 本手法をトポロジー最適化に利用し新たな二段階最適化手法を提案する.

第6章 結論

本論文の総括を行う.

第2章 トポロジー最適化およびモータの基礎理論

2.1 はじめに

モータの磁気構造トポロジー最適化は数理計画問題に形状表現手法, 数値解析技術を連成した手法である. 本章ではモータの磁気構造トポロジー最適化手法で用いる基礎理論に関して述べる.

2.2節では本研究で用いたFEMをはじめとする数値解析手法について述べる. 2.3節では探索アルゴリズムについて述べる. さらに, 本研究で用いた遺伝的アルゴリズム内の設定について述べ, それぞれの設定における性能をテスト問題で評価する. 2.4節ではトポロジー最適化手法の概要について述べる. また, 本研究で用いたNGnet-ON/OFF法について述べる. 2.5節では最適化対象であるモータの基礎理論について述べる. 2.6節では本研究における計算環境を示す. 2.7節では本章の総括を行う.

2.2 数値解析手法

2.2.1 概要

本節ではモータの磁気特性を求める際に用いた数値解析手法に関して述べる. 代表的な解析手法として磁気回路法およびFEMが挙げられる. 磁気回路法は起磁力, 磁束, 磁気抵抗の関係を電気回路におけるオームの法則と等価的に表すことができる性質を利用した手法である. 解析対象の磁路を想定して磁気抵抗および起磁力を設定することで, 想定した磁路に流れる磁束量を求める. 本手法は比較的簡易的なモデルに対しては高い精度で解析可能であるが, モータのようなモデルの場合, 素子の配置方法に工夫が必要である. また, トポロジー最適化のようなコア形状を大きく変更させる場合, 素子の増減を考慮する必要があるため, 適用しにくい. そこで, モータの磁気特性を求めるためにFEMを用いることを考える.

2.2.2 電磁界解析

電磁界解析は主に4本のマクスウェル方程式を用いて場を解くことにある. 電磁界解析は時間領域解析および周波数領域解析に大別され, 用途によって使い分けがなされる[33]. 電磁波などの高周波解析においては時間領域解析手法の一つであるFDTD(Finite Difference Time Domain)法が広く用いられている. 一方, モータの磁界解析においては周波数領域解析におけるFEMが用いられることが多い.

FEMとは解析領域内を複数の要素に分割し、偏微分方程式を用いて辺や面、節点に与えた未知数を求める手法である。要素は二次元であれば三角形や四角形要素、三次元であれば四面体や六面体要素が用いられ、要素内は補間関数によって表される [34]。

FEMによる電磁界解析はマクスウェル方程式を弱形式で表現した後、離散化し節点および辺に与えた未知数を求める。連立方程式の計算には不完全コレスキー分解共役勾配 (ICCG: Incomplete Cholesky Conjugate Gradient) 法 [35]、磁気非線形特性の計算にはニュートン・ラフソン法が用いられることが多い。モータ磁界解析の場合、本手法で得られた磁束密度分布を用い、節点力法等を用いることで電磁力分布を求め、トルク特性を算出する。FEMはICCG法やニュートン・ラフソン法のような反復計算を行うため、要素数、非線形性などによっては求解に時間を要する。本問題を解決するため、FEMの求解における反復計算の収束性に関する研究も報告されている [36]。

2.2.3 二次元静磁場解析における有限要素法の定式化

本節ではFEMで二次元静磁場を解くための支配方程式の導出を示す [37][38]。本研究では節点に未知数としてベクトルポテンシャルを与え、場を求める。Maxwell方程式は以下の4式で与えられる [39]。

$$\nabla \times \mathbf{E} = -\frac{\partial \mathbf{B}}{\partial t} \quad (2.1)$$

$$\nabla \times \mathbf{H} = \mathbf{J}_0 + \frac{\partial \mathbf{D}}{\partial t} \quad (2.2)$$

$$\nabla \cdot \mathbf{D} = \rho \quad (2.3)$$

$$\nabla \cdot \mathbf{B} = 0 \quad (2.4)$$

ここで、 $\mathbf{E}, \mathbf{H}, \mathbf{D}, \mathbf{B}, \mathbf{J}_0, \rho$ はそれぞれ、電界、磁界、電束密度、磁束密度、電流密度、電荷密度である。式2.1はファラデーの法則を示し、式2.2はアンペールの法則を示している。また、式2.3、式2.4はガウスの法則を示している。本研究における電磁界解析はモータの各回転角において正弦波電流を入力し、渦電流の効果を無視した電流源静磁場解析を行う。つまり、時間変化項を無視することができるため、式2.1、式2.2は以下のように書き換えることができる。

$$\nabla \times \mathbf{E} = 0 \quad (2.5)$$

$$\nabla \times \mathbf{H} = \mathbf{J}_0 \quad (2.6)$$

ここで、ベクトル公式

$$\nabla \cdot (\nabla \times \mathbf{A}) = 0 \quad (2.7)$$

より、式 2.4, 式 2.7 から以下のように定義できる.

$$\mathbf{B} = \nabla \times \mathbf{A} \quad (2.8)$$

ここで, \mathbf{A} はベクトルポテンシャルである. また, 磁界と磁束密度の関係は以下のようになる.

$$\mathbf{B} = \mu \mathbf{H} \quad (2.9)$$

ここで, μ は透磁率であり, 透磁率の逆数を磁気抵抗率 ν と定義する.

$$\nu = \frac{1}{\mu} \quad (2.10)$$

式 2.6, 式 2.8, 式 2.9 より以下の式を導出することができる.

$$\nabla \times (\nu \nabla \times \mathbf{A}) = \mathbf{J}_0 \quad (2.11)$$

また, ベクトル公式

$$\nabla \times (\mathbf{a} \times \mathbf{b}) = (\mathbf{b} \cdot \nabla) \mathbf{a} - (\mathbf{a} \cdot \nabla) \mathbf{b} + \mathbf{a} \nabla \cdot \mathbf{b} - \mathbf{b} \nabla \cdot \mathbf{a} \quad (2.12)$$

を用いると式 2.11 は以下のようにかける.

$$\nabla \times (\nu \nabla \times \mathbf{A}) = \nabla \cdot (\nu \nabla \mathbf{A}) \quad (2.13)$$

式 2.11 と式 2.13 より以下の二次元静磁場の支配方程式を得ることができる [37].

$$\nabla \cdot (\nu \nabla A) = -J \quad (2.14)$$

ここで, 今二次元静磁場を考えているので, A, J は z 軸方向成分を示している.

次に式 2.14 を有限要素方程式へ離散化することを考える. 式 2.14 に重み付き残差法を適用すると以下の式になる [37].

$$\int_{\Omega} \nabla w \cdot (\nu \nabla A) dS = - \int_{\Omega} w J dS \quad (2.15)$$

式 2.15 に磁界が境界と平行であることを条件とする固定境界条件, 境界と垂直であることを条件とする自然境界条件を課すと, 式 2.16 のように書ける.

$$\int_{\Omega} w \nabla \cdot (\nu \nabla A) dS = - \int_{\Omega} w J dS \quad (2.16)$$

本研究で用いる要素は四角形要素であるため, 一要素における節点数は 4 である. よって, 補間関数 N_i を用いてある要素のベクトルポテンシャル A は以下のように定義できる.

$$A = \sum_{i=1}^4 N_i A_i \quad (2.17)$$

式 2.16 にガラーキン法を適用し，重み w を N_i とすると以下のように離散化できる [37].

$$\sum_{i=1} \sum_{j=1} A_j \int_{\Omega} \nu \nabla N_j \cdot \nabla N_i dS = - \int_{\Omega} N_i \cdot J dS \quad (2.18)$$

すべての要素について式 2.18 式を考え，解析領域全体における要素行列を作成し，解くことで領域におけるベクトルポテンシャルを算出することができる。

本検討では永久磁石を有する IPM モータを解析対象とするため，式 2.18 を拡張させ，以下の式を解く。

$$\sum_{i=1} \sum_{j=1} A_j \int_{\Omega} \nu \nabla N_j \cdot \nabla N_i dS = - \int_{\Omega} N_i J dS + \int_{\Omega} N_i \cdot (\nabla \times \mathbf{M}) dS \quad (2.19)$$

ここで， \mathbf{M} は永久磁石による磁化ベクトルである。また，磁気抵抗率に関する非線形解析を行う際はニュートン・ラプソン法を用いて要素ごとの磁気抵抗率 ν を更新する。

2.2.4 モータ解析で用いる諸条件

周期境界条件

本問題で扱うモータは 4 極 24 スロットである。偏心や磁石位置ずれ等を想定しない理想的なモデルの場合，90 度ごとに周期的な磁束分布が生じる。そのため，360 度分の領域を解析する必要はなく，90 度分を解析したうえで周期境界条件を課して解析を行う。4 極 24 スロット場合，磁束分布は 90 度ごとにベクトル向きが反転して現れる。そのため，ベクトルポテンシャル \mathbf{A} も 90 度ごとに互いに符号が反転している。本検討では，0 度境界と 90 度境界上の対応する要素 e_0, e_{90} におけるベクトルポテンシャル $A_{e_0}, A_{e_{90}}$ に対し，以下のような対応付けを行う [38].

$$A_{e_0} = -A_{e_{90}} \quad (2.20)$$

このように課すことで，90 度モデルでの解析が可能となり，解析モデルが 1/4 となる。最適化では多数の FEM を行うため，モデルを小さくすることで最適化時間の短縮につながる。

浮き節点に対する処理

本検討で解析対象として扱うモータは固定子と回転子を有する。固定子は空間に対し固定されているが，回転子は解析条件に応じて回転角度が変動する。したがって，回転角度に応じて回転子のメッシュは移動するため，固定子メッシュとの整合性をとる必要がある。この場合，回転角度に応じてメッシュを生成する手法が考えられるが，本検討では四角形要素を用いており，四角形要素の自動分割アルゴリズムは複雑であることから，メッシュ生成にかなりの時間を要する。そこで，本検討では回転子と固定子の境界を独立させ，浮き節点を境界上のベクトルポテンシャルで補間する処理を行う [38].

本処理の概要を図 2.1 に示す。境界部分は回転子側，固定子側それぞれ節点を有している。回転子が回転し，回転子が有する境界上の節点 s_1 が浮き節点となった場合，隣接す

る固定子の節点 m_1, m_2 を用いてベクトルポテンシャルを線形補間する。以下に定義式を示す。

$$A_{s_1} = L_1 A_{m_1} + L_2 A_{m_2} \quad (2.21)$$

$$L_1 = \frac{l_{m_1, s_1}}{l_{m_1, s_1} + l_{m_2, s_1}} \quad (2.22)$$

$$L_2 = \frac{l_{m_2, s_1}}{l_{m_1, s_1} + l_{m_2, s_1}} \quad (2.23)$$

ここで、 $l_{a,b}$ は節点 a, b 間の距離を示す。このように補間することで、回転により生じた浮き節点を従来未知数のみを扱いつつ、計算が可能となる。




図 2.1: 浮き節点に対する処理

2.3 数理計画問題

2.3.1 概要

数理計画問題とは、1 または多次元で表された空間内においてある条件を満たす空間の最大点または最小点を求める問題をいう。本節ではその定義および本研究で用いる遺伝的アルゴリズムに関して詳細に述べる。

2.3.2 定義

最適化問題

数理計画問題において最適解が満たすべき条件を制約として表し、最大および最小を求める問題を目的関数として表す。制約がある場合、制約付き最適化問題、制約がない場合制約なし最適化問題である。例えば、変数 \boldsymbol{x} に関する目的関数を $f(\boldsymbol{x})$ 、制約条件を $\boldsymbol{x} \in S$ とすると最大化問題は以下のように表される。

$$f \rightarrow \max ., \quad \text{sub.to.} \quad \boldsymbol{x} \in S \quad (2.24)$$

ここで、 S は実行可能領域である。

大域的最適解と局所的最適解

最適解は大きく局所的最適解および大域的最適解に区別される [40]. 局所的最適解はある限られた範囲において最大および最小である解を指す. 一方, 大域的最適解は探索範囲全域において最大および最小である解を指す. ここで, 制約条件 $x \in S$ を満たす, すべての x に対して最大化問題の場合 $f(\hat{x}) \geq f(x)$, 最小化問題の場合 $f(\hat{x}) \leq f(x)$ を満たすとき, \hat{x} を大域的最適解である.

2.3.3 解法

表 2.1 に数理計画問題解法の例を示す. 数理計画問題は大きく離散最適化問題と連続最適化問題に分けられる. 離散最適化問題は離散的な配列の組み合わせを探索する. 連続最適化問題は探索空間が連続であり, 主に勾配を用いて空間を探索する. 離散最適化問題の解法として, メタヒューリスティクスアルゴリズムである遺伝的アルゴリズム (GA: Genetic Algorithm)[41], 焼きなまし法 (SA: Simulated Annealing)[43], 粒子群最適化 (PSO: Particle Swarm Optimization)[44] などが挙げられる. 一方, 連続最適化問題の解法として, 最急降下法や共役勾配法, ニュートン法などが挙げられる [45].

連続最適化問題の解法の多くは解の更新過程で導関数を要するため, 目的関数が微分可能な関数である必要がある. また, 本手法は最終的に得られる解は初期解に依存し, 局所最適解に陥る可能性が高い. そこで, 離散最適化問題に用いていたメタヒューリスティクスアルゴリズムを連続最適化問題に用いる手法が提案されている. 本手法は従来離散最適化問題で用いている手法であるため, 探索過程で導関数を必要としない. そのため, 目的関数の微分を必要とせず, 問題適用が簡単である. 特に GA の遺伝子として離散値ではなく実数値を用いた実数値 GA は幅広い研究開発に用いられている [10]. このことから, 本研究では実数値 GA に注目し, モータ形状トポロジー最適化に適用する.

表 2.1: 数理計画解法

離散最適化問題	遺伝的アルゴリズム 焼きなまし法 粒子群最適化 ... etc.
連続最適化問題	最急降下法 共役勾配法 ニュートン法 ... etc.

2.3.4 遺伝的アルゴリズム

概要

GA は Holland, J. H. により提唱された確率論的探索アルゴリズムである [41]. 図 2.2 に GA の概要を示す. GA は生物の進化, 遺伝学から着想を得ている. 生物は世代を追うごとに環境に適用し, 種が繁栄するように遺伝子が増え変化していくと考えられる. その仕組みを模倣して, 良好な特性を持つ解を探索する. GA 内では生物の個体と同様に 1 つの解を個体と表現する. 個体は遺伝子の概念を持ち, その遺伝子によって個体が特徴づけられている. GA の基本的な操作を以下に示す.

1. ランダムに個体生成
乱数的に複数の個体を生成し, 集団を形成する. 適切な個体数は交叉手法や問題の複雑さに応じて変動する.
2. 親個体の選択
集団中から交叉を行う親個体を複数選択する. 選択方法は世代交代モデルによって異なる.
3. 親個体を用いた交叉による子個体生成
選択した親個体の持つ遺伝子を交叉させ, 二個体の遺伝子を引き継いだ子個体を生成する. 子個体は親個体の遺伝子を引き継いでいるため, 親個体に類似した特徴を持つ. 最適解方向へ子個体を生成されるよう工夫された交叉手法が提案されている.
4. 子個体を含めた集団からの淘汰
子個体を含めた集団の中から悪解を削除し, 良好な解を次世代に残す. 淘汰により集団として良好な解が支配的となり, 最適解近傍へ探索範囲を移動させることができる.
5. 個体遺伝子の突然変異
複数個体の遺伝子の一部を交叉などのアルゴリズムと異なるアルゴリズムで唐突に変化させることで, 類似した個体が支配的な集団から逸脱した個体を生成する. 突然変異を用いることで集団にとらわれない個体を探索に用いることとなり, 個体の多様性を保つことができる. また, 局所的な最適解から脱却する効果がある. 本研究では突然変異は用いていない.

これらの操作の繰り返しによって目的に応じた最適解を得られる.

図 2.3 に遺伝子の表現手法を示す. 当初, 個体の遺伝子は図 2.3(a) に示すように, バイナリ記号列で示したものをを用いる手法が主流であった. 図 2.3(a) は 0 と 1 で物性を変動させることで, 場を表現している. 一方, 1990 年代から連続最適問題に適用するべく, 遺伝子を実数値ベクトルにする実数値 GA が広く研究されている [42]. 実数値を用いることで図 2.3(b) に示すように, 形状の寸法やある点の状態を直接遺伝子情報として扱うことが可能となる. 近年は空間に数多くの局所解を有する多峰性空間や変数間の強い結びつきによる変数間依存性を有する空間, 変数に応じてスケールが異なる悪スケール性を有する空間にも対応した実数値 GA 探索手法が提案されている [42].

GA は最適化手法の概念にしか過ぎず, 実際は選択手法, 交叉手法や淘汰手法を問題に応じて使用者が選び, 組み合わせて使用する. 次に本研究で用いた交叉方法および世代交代モデルについて述べる.

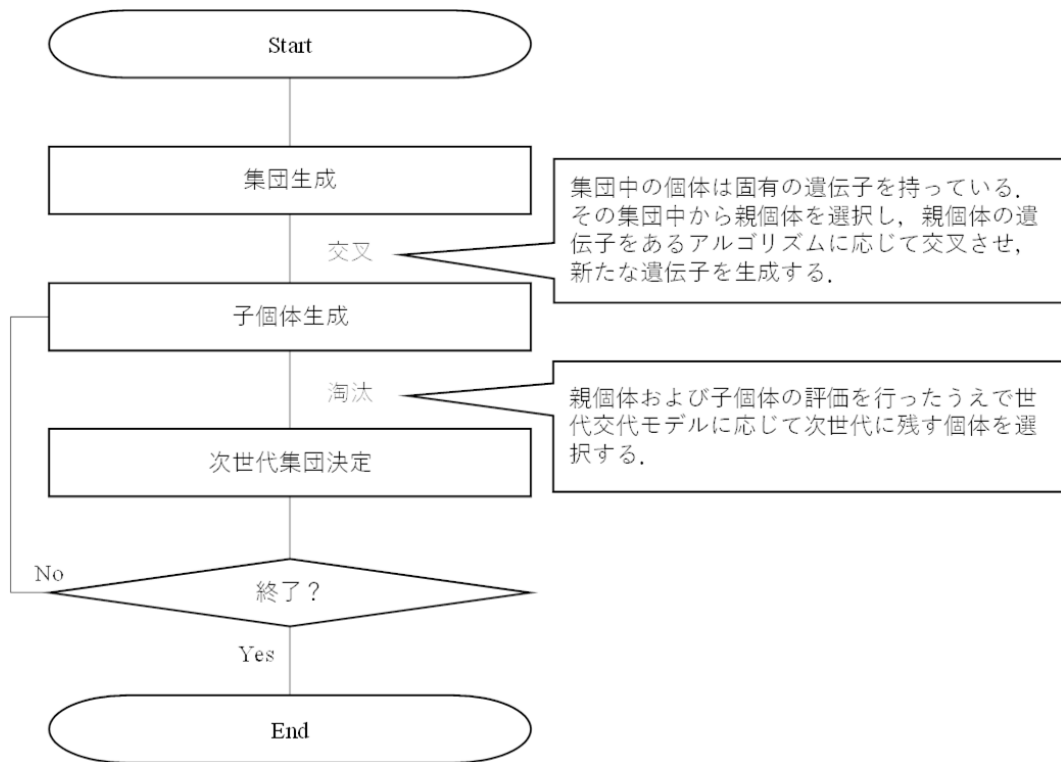


図 2.2: 遺伝的アルゴリズム概要

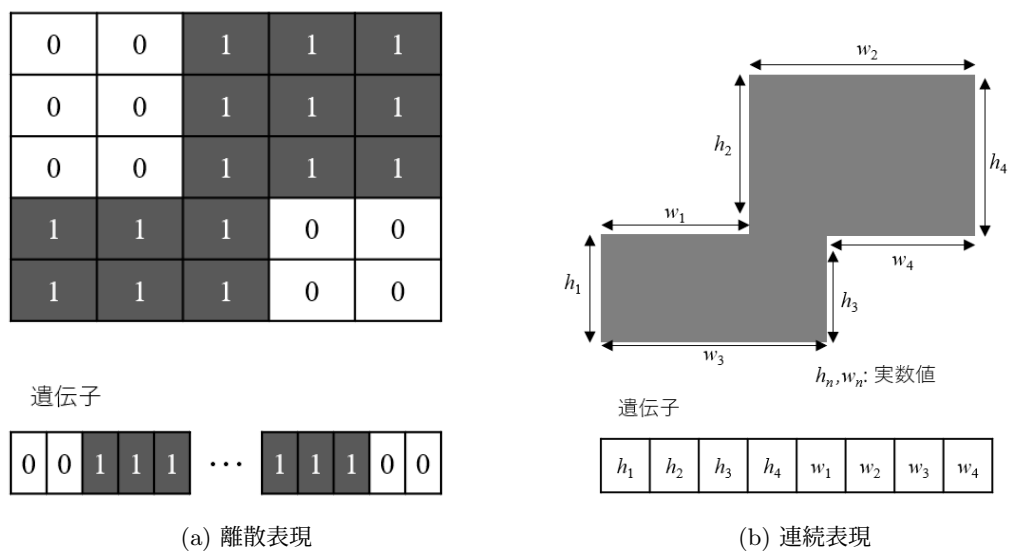


図 2.3: 遺伝子表現概要

交叉手法

GAの交叉手法は最適化性能を大きく決定するため、数多くの手法が研究されている。本節では本研究で用いた実数値GAの主要な交叉方法について述べる。

1. BLX- α [46]

代表的な交叉手法としてブレンド交叉 (BLX- α : Blend Crossover) がある。図 2.4 に概要を示す。集団中から二個体選択し、矩形領域を生成する。その矩形領域から二個体の距離に α を乗じた長さ分だけ広げた矩形領域中に個体を生成する。子個体生成アルゴリズムは以下のように定義される [42]。

(a) 二個体 $\mathbf{x}^1, \mathbf{x}^2$ を親個体として選択する。

(b) 子個体 \mathbf{x}_c を以下の範囲内における一様乱数で決定する。

$$X_i^1 \leq x_i^c \leq X_i^2 \quad (2.25)$$

$$X_i^1 = \min(x_i^1, x_i^2) - \alpha d_i \quad (2.26)$$

$$X_i^2 = \max(x_i^1, x_i^2) + \alpha d_i \quad (2.27)$$

$$d_i = |x_i^1 - x_i^2| \quad (2.28)$$

であり、 x_i^1, x_i^2 はそれぞれ $\mathbf{x}^1, \mathbf{x}^2$ の第 i 成分、 α は更新幅に影響するパラメータである。




図 2.4: BLX- α [42]

本手法は目的関数を各変数が強い結び付きを持つ変数依存性を有する問題に対応していない [47]。本研究で用いるモータ形状最適化問題は各パラメータ間に強い依存性を持つと考えられるため、適用が難しい。そこで、変数依存性、悪スケール性にも対応した交叉手法 REX^{star} に注目している。

2. REX^{star} [47]

本手法は交叉の際に複数の個体を用いてマクロにみて降下方向とみなせる方向を推定し、集団の移動方向を求める手法である。図 2.5 に REX^{star} の概要を示す。子個体を生成する際に大域的降下方向を集団の重心に対して点対称な個体を用いて、その方向に子個体を生成する。以下に REX^{star} のアルゴリズムを示す [42]。

- (a) N 個の親個体 $\mathbf{x}^1, \dots, \mathbf{x}^N$ を選択し、重心を \mathbf{x}^g とする。
- (b) 親個体 \mathbf{x}^i の \mathbf{x}^g を中心対称とする鏡像個体 \mathbf{x}^i を生成する。
- (c) 重心 \mathbf{x}^g まわりの計 $2N$ 個の個体の中で、評価値が上位 N の個体の重心を \mathbf{x}^b とする。
- (d) 子個体 \mathbf{x}^c を以下のように生成する。

$$\mathbf{x}^c = \mathbf{x}^g + \text{diag}(\xi_1^t, \dots, \xi_n^t)(\mathbf{x}^b - \mathbf{x}^g) + \sum_{i=1}^N \xi^t(\mathbf{x}^i - \mathbf{x}^g) \quad (2.29)$$

ここで、 $\xi_j^t \sim U(0, t)$, $j = 1, \dots, n$, であり、 $\xi^i \sim U(-\sqrt{3/N}, \sqrt{3/N}, i = 1, \dots, N)$, とする。 t は探索ステップサイズであり、探索性能に影響するパラメータである。

本手法は鏡像個体を用いて、選択した個体群の重心を算出している。しかし、鏡像個体を用いると、その分考慮すべき個体数が増加する。本研究で対象とするモータの形状最適化問題では、個体の評価値を算出するため FEM を用いるため、計算コストが増加する。そこで、文献 [14] で用いられているように鏡像個体を用いない簡易的な REX^{star} を検討する。




図 2.5: REX^{star} [42]

2.3.5 単目的最適化

概要

単目的問題は1目的関数に対する最適解を得る最適化問題である。本研究で用いる単目的最適化問題は制約付き最適化問題である。以下、単目的最適化で用いられるアルゴリズムについて述べる。

世代交代モデル

GAで交叉を行う際には親個体を選択する必要がある。その親個体の抽出方法、生成された子個体を含めた選択方法を含めて世代交代モデルと呼ばれる。本節では単目的最適化における代表的な世代交代モデルを示す。ここでは、MGG[48]およびJGG[47]について述べる。

1. MGG(Minimal Generation Gap)[48]

MGGは以下に示すアルゴリズムで個体の選択される。

- (a) 探索空間内への集団生成
探索空間内に複数の個体をランダムに生成する。
- (b) 集団中から親個体選択
集団内から評価値をもとに親個体を複数個選定する。
- (c) 親個体を用いて子個体生成
選択した親個体の遺伝子を用いて交叉を行い、新たな個体を生成する。
- (d) 子個体を含めて生存選択
親個体および子個体を含めたすべての個体中から最も評価値の高い個体と、ルーレット選択した個体を次世代に残すため、親集団中の個体と入れ替える。ルーレット選択は評価値 f に応じて選択確率 r を変動させる。以下の式で定義される。

$$r(\mathbf{x}_i) = \frac{f(\mathbf{x}_i)}{\sum_j^N f(\mathbf{x}_j)} \quad (2.30)$$

ここで N は集団の個体数を示す。

本手法によりすべての個体を用いて探索すべき空間を的確に絞り込むことが可能である。本アルゴリズムを終了条件を満たすまで選択、子個体生成、生存選択を繰り返す。

2. JGG(Just Generation Gap)[47]

MGGを改良し、初期収束性改善を図ったJGG(Just Generation Gap)に注目する。MGGは生存選択の際に評価値に基づいた最良個体とルーレット選択した個体を選択する。最良個体を保存することで、局所解へ陥るリスクが高くなり、ルーレット選択は解探索の収束性を悪化させる可能性がある[47]。そこで、本手法はMGGの生存選択を改良している。以下にJGGのアルゴリズムを示す。

- (a) 探索空間内への集団生成
探索空間内に複数の個体をランダムに生成する.
- (b) 集団中から親個体選択
集団内から評価値をもとに親個体を複数個選定する.
- (c) 親個体を用いて子個体生成
選択した親個体の遺伝子を用いて交叉を行い, 新たな個体を生成する.
- (d) 子個体を含めて生存選択
子個体中から評価値が良好な上位個体を複数個選択し, 親集団中の個体と入れ替える.

JGGはMGGに比べ, 収束性の向上が報告されている [47]. 本研究では世代交代モデルとしてJGGを用いる.

テスト問題

本研究で用いた最適化コードの妥当性を検証するため, テスト関数による関数最適化問題を解く. テスト関数として Rastrigin 関数を用いる [49]. 図 2.6 に 2 変数の Rastrigin 関数を示す. 本関数は強い多峰性がある. 多峰性とは空間に非常に急勾配を有する山谷を複数個持ち, 局所的最適解に陥りやすい空間の特徴をいう. 本研究で扱うモータ形状最適化問題において対象となる各特性は, 磁気的非線形性の影響を大きく受けやすい. したがって, モータトポロジー最適化の探索空間は強い多峰性を持つ場合が多いと考えられる. そのため, Rastrigin 関数で探索が可能であれば, モータ形状最適化においても本最適化コードは有用であると言える. 本テスト関数は以下の式で定義される.


$$f(x_1 \cdots x_n) = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)) \quad (2.31)$$

ただし, 探索空間は $-5.12 \leq x_i \leq 5.12$ であり, 最適解は $f(0, \dots, 0) = 0$ である.

表 2.2 に最適化条件を示す. 本検討では REX^{star} と JGG を用いた場合, および REX^{star} の鏡像個体を用いていない手法と JGG を用いた場合の二設定で最適化を行った. また, REX^{star} における探索ステップサイズの効果を検証するため, $t = 0.1, 0.5, 1.0$ の場合にて検証する.

テスト結果

Rastrigin 関数を用いたテスト結果を図 2.7 に示す. 図 2.7(a)(b) はそれぞれ, REX^{star} の鏡面個体あり, 鏡面個体なしの場合における探索結果である. それぞれ, 探索ステップサイズ t を 0.1, 0.5, 1.0 の 3 パターンで変化させた. それぞれ, $t = 0.1$ とした場合, 最も収束していることが確認できる. 一方, $t = 1.0$ の場合, 初期段階で収束が止まっている. t が大きいと 1 世代における探索ステップが大きくなり, 局所解に収束してしまうた

図 2.6: Rastrigin 関数 ($n = 2$)

めであると考えられる。以上の結果から、多峰性のある問題では $t = 0.1$ で最適化を行うことが望ましい。

また、鏡面なしの場合において、鏡面個体ありの場合に比べ収束性は悪化しているが、最終的な解はほとんど変わらないことから、鏡面個体を生成しなくても探索は可能であるといえる。本研究で扱うモータ形状の最適化内においては、モデルによって各個体の FEM による解析時間が膨大となる。そこで、最適化時間を現実的な時間とするためには、探索個体数を可能な限り削減する必要がある [14]。

以上の結果から、本研究では鏡面個体を用いず、 $t = 0.1$ の設定で最適化を行うこととした。

2.3.6 多目的最適化

概要

多目的最適化は2目的以上の目的関数に対して最適解を求める最適化問題である。図 2.8 に多目的最適化の概要を示す。物理的にすべての特性が最大および最小となることは不可能な場合が多い。このような性質をトレードオフ関係であるという。そこで、ある目的関数の評価値が定められた時、他の目的関数の評価値が最も優れている解を探索することを考える。





図 2.7: テスト関数を用いた単目的最適化結果

表 2.2: テスト関数を用いた単目的最適化設定

Number of dimensions	50
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REX ^{star}
Method of Generations	1000

定義

多目的最適化は目的関数間のトレードオフ関係が最適となるような解集合を得ることを目的としている。変数 \mathbf{x} に関する n 個の目的関数 $f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_n(\mathbf{x})$, 制約条件を $\mathbf{x} \in S$ とした時の多目的最適化の最小化問題は以下の式 2.32 で定義される。

$$f_1, f_2, \dots, f_n \rightarrow \min., \quad \text{sub.to.} \quad \mathbf{x} \in S \quad (2.32)$$

このように複数の目的関数を設定すると、実現可能な解空間が限定される。その限定された解空間の際を探索する。

パレート解

個体の評価値をもとに他の個体との優劣関係を定め、その関係に応じてランク付けを行う。最小化問題において二つの解を $\mathbf{x}^i, \mathbf{x}^j \in S$ としたとき、すべての $k = 1, 2, \dots, n$ において

$$f_k(\mathbf{x}^i) \leq f_k(\mathbf{x}^j) \quad (2.33)$$

を満たし、少なくとも一つの $k = 1, 2, \dots, n$ において

$$f_k(\mathbf{x}^i) < f_k(\mathbf{x}^j) \quad (2.34)$$

を満たすとき、 \mathbf{x}^i は \mathbf{x}^j よりもすべての目的関数において優れた解であり、 \mathbf{x}^i は \mathbf{x}^j に優越しているという。 \mathbf{x}^i に優越した解が存在しない場合、 \mathbf{x}^i をパレート解と呼ぶ。多目的最適化の場合、このように定義されたパレート解の集合を求めていく。

探索アルゴリズム

多目的最適化問題を解く多目的 GA の探索アルゴリズムとして多くの手法が開発されている。代表的な多目的 GA アルゴリズムとして、非優越ソート (NSGA: Non Dominated Sorting GA) がある [50]。図 2.9 に概要を示す。本手法はランクと呼ばれるパレート解ごとのランキングを用いて、同じランクごとに個体が集中しないよう個体を生成していく。

ランクとは個体より優越した個体の数に1を加算した値であり、パレート解はランク1である。DebらがNSGAアルゴリズムを発表したのちに、改善を行ったものがNSGA-IIである[51]。NSGA-IIとNSGAの違いとして、高速優越ソート、シェアリングの代用、エリート保存方法がある。本研究では優越ソート手法はNSGAのアルゴリズムを用い、その他はNSGA-IIのアルゴリズムを用いた。図2.10にアルゴリズムの概要を示す。具体的なアルゴリズムを以下に示す。

1. 初期集団の生成

世代 $g=1$ とし、ランダムに個体を生成し、初期集団 G_g を生成する。

2. ランク付け

集団 G_g のそれぞれの個体に非優越ソートにてランク付けを行う。非優越ソートは以下のフローで行われる。

- (a) ランクを r と定義し、初期値を $r = 1$ とする。
- (b) 評価値をもとに集団 G_g におけるパレート解を探索し、ランク r とラベル付けする。
- (c) 前ステップでランク付けした個体を無視し、残った集団を次の探索で扱う。 $r = r + 1$ とする。
- (d) すべての個体にランクのラベル付けを行うまで (b)(c) を繰り返す。

3. 混雑度の計算

それぞれのランクにおいて隣接する個体同士の距離をもとめ、距離をもとに混雑度定義する。混雑度は以下のフローで算出される。

- (a) ランク $r = 1$ とする。
- (b) $r = 1$ の個体集合をそれぞれの目的関数における評価値でソートする。
- (c) $r = 1$ の個体集合のそれぞれの個体に注目し、ソート順に隣接する個体間の距離 d をもとに混雑度 $D_i = d_{i-1} + d_{i+1}$ を求める。
- (d) $r = r + 1$ とする。
- (e) すべてのランクが終了するまで (b)(c)(d) を繰り返す。

4. エリート保存

ランクおよび混雑度によりソートし、上位のエリート集団を保存する。母集団数を超過してしまう場合はランクおよび混雑度を考慮して個体を選択する。個体 i および j において

$$r_i < r_j \tag{2.35}$$

または

$$(r_i = r_j) \cap (D_i > D_j) \tag{2.36}$$

のとき、個体 i のほうが個体 j よりも優先度が高くなる。

5. 子生成

エリート集団内で交叉を行い、子個体を生成する。再びランク付けを行い、 $g = g + 1$ とする。以降終了世代数まで繰り返す。

テスト問題

テスト関数を用いて NSGA-II の探索性能を評価する。多目的関数最適化のテスト問題は数多く提案されているが、本研究では Multi-modal MOP 問題を用いる [52]。本問題は多峰性の強い二目的に対する多目的最適化である。二目的の最小化問題は以下の式で与えられる。

$$\begin{aligned} f_1 &= x_1 \rightarrow \min. \\ f_2 &= g(\mathbf{x}) \times h(f_1, g) \rightarrow \min. \end{aligned} \quad (2.37)$$

本問題における $g(\mathbf{x}), h(f_1, g)$ は式 2.38 で表される。

$$\begin{aligned} g(\mathbf{x}) &= 1 + 10(N - 1) + \sum_{i=2}^N (x_i^2 - 10 \cos(2\pi x_i)) \\ h(f_1, g) &= 1 - \left(\frac{f_1}{g}\right)^{0.5}, \end{aligned} \quad (2.38)$$

ここで、探索空間は $i = 1$ のとき、 $0 \leq x_1 \leq 1$ であり、 $i \neq 1$ のとき $-30 \leq x_i \leq 30$ である。パレート解は式 2.39 のようになる。

$$\begin{aligned} f_1 &= x_1 \\ f_2 &= 1 - (f_1)^{0.5} \end{aligned} \quad (2.39)$$

本検討では NSGA-II および REX^{star} を用いて検証した。

表 2.3: 多目的最適化の最適化設定

Number of dimensions	10
Number of individual	200
Number of pareto	100
Optimized method	NSGA-II
Method of Crossing over	REX ^{star}
Method of Generations	5000

テスト結果

Multi-modal MOP 問題における多目的最適化のテスト結果を図 2.11 に示す。黒点は式 2.39 で示した理想パレート解であり、赤四角は得られたパレート解である。本結果は異なる集団から開始し、10 回試行した結果、最も理想パレート解に近くに得られた解である。理想パレート解は得られていないが、近いパレート解を得ることができている対象としたことが確認できる。よって、本条件でモータをトポロジー最適化における探索も可能であると判断できる。




図 2.8: 多目的最適化におけるパレート解




図 2.9: NSGA-II のフロー




図 2.10: NSGA-II におけるランク付け

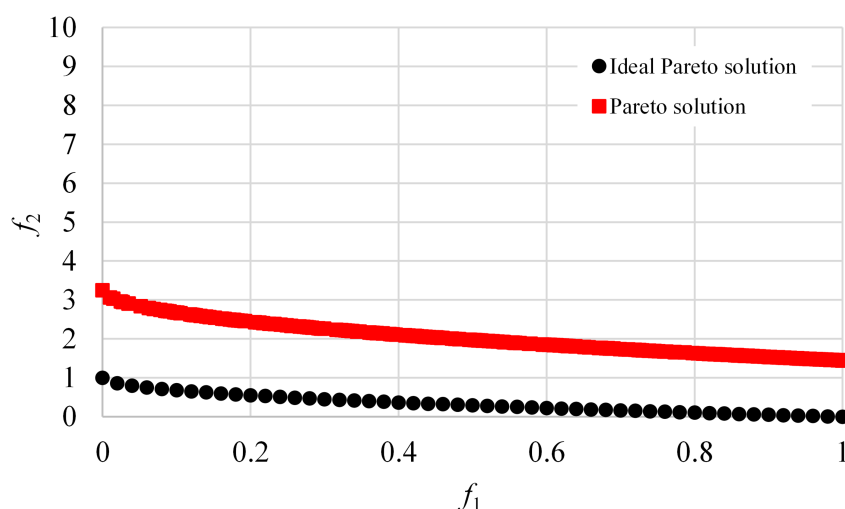


図 2.11: テスト関数を用いた多目的最適化結果

2.4 形状表現手法

2.4.1 概要

モータの形状最適化は GA とモータの特性値を評価する FEM を連成する。連成するにあたり、GA が用いる遺伝子情報からモータ形状を表現し、FEM のメッシュに反映させる必要がある。本研究では自由度の高い形状最適化が可能なトポロジー最適化に注目しており、形状表現手法に関し多くの手法が開発されている。

代表的な手法として ON/OFF 法 [18]、密度法 [53] や均質化法 [54] などが提案されているが、グレースケール問題が発生する点や、製造可能形状が現れにくいなどの問題点がある。そこで、勾配法に基づくレベルセット関数を用いるトポロジー最適化手法が提案されている [19][20]。しかし、レベルセット法は目的関数の微分を用いるため、最適化における目的関数が複雑になるにつれ、レベルセット関数の取り扱いが複雑になると考えられる。そこで、文献 [21] では正規化ガウス基底関数ネットワーク (NGnet: Normalized Gauss Network) を基底関数として用いる ON/OFF 法を提案している。本手法は GA との連成が容易であり、目的関数の微分が導出できない問題にも適用可能である。以上の観点から、本研究では基底関数を用いた手法に着目している。

2.4.2 基底関数を用いた ON/OFF 法

ON/OFF 法とは有限要素法の材料物性パターンを最適化する手法であり、各要素の材料物性を独立に定義する。一方、基底関数を用いた ON/OFF 法は基底関数の形状に依存して要素物性を決定する。

NGnet-ON/OFF 法 [21] に関して述べる。本手法は設計領域とした有限要素上にガウス基底関数を複数重ね合わせたガウス基底関数ネットワーク (NGnet) を張り、要素重心にお

ける NGnet の状態に応じて要素の材料物性を当てはめる手法である。図 2.12 に概要を示す。図 2.12(a) の (i) から (v) はガウス関数を示す。NGnet を構成するガウス関数はガウス関数中心からの半径を標準偏差とする円領域が重なるように配置する。そのうち、ガウス関数を正規化、重み付けをし、重ねあわせをすることで出力関数 $\phi(\mathbf{x})$ を求める。以下に定義式を示す。

$$\phi(\mathbf{x}) = \sum_{i=1}^N w_i b_i(\mathbf{x}) \quad (2.40)$$

$$b_i(\mathbf{x}) = \frac{G_i(\mathbf{x})}{\sum_{k=1}^N G_k(\mathbf{x})} \quad (2.41)$$

$$G_i(\mathbf{x}) = \frac{1}{2\pi\sigma} \exp\left(-\frac{1}{2\sigma^2}|\mathbf{x} - \mathbf{x}_e|^2\right) \quad (2.42)$$

ここで、 $G_i, w_i, \mathbf{x}, \mathbf{x}_e, N, \sigma$ はそれぞれガウス関数、ガウス関数の結合重み、要素の重心ベクトル、ガウス関数の中心ベクトル、ガウス関数の数、ガウス関数の標準偏差である。


図 2.12(b) は (iii) のガウス関数の重み w を 1.0、その他のガウス関数の重み w を 0.0 とした場合の出力関数 $\phi(\mathbf{x})$ を示している。さらに、図 2.12(c) は (i)~(v) のガウス関数の重みをそれぞれ 0.5, 0.8, -0.5, 0.3, -0.2 とした場合の出力関数 $\phi(\mathbf{x})$ である。このようにそれぞれの重み w に応じて関数付近の出力 $\phi(\mathbf{x})$ が変化していることが確認できる。関数中心付近はその重みの値で一定値となっている。

この出力関数 $\phi(\mathbf{x})$ を用いて設計領域内の要素物性を決定する。基底関数を設計領域内に配置する。図 2.13 に要素の ON/OFF の決定の概要を示す。図 2.12(c) の関数を用いて要素物性を決定する手法した場合を示している。それぞれの要素の重心における $\phi(\mathbf{x})$ の値によって以下のように材質 $V_e(\mathbf{x})$ を決定する。


$$V_e(\mathbf{x}) = \begin{cases} \text{iron} & (\phi(\mathbf{x}) \geq 0) \\ \text{air} & (\phi(\mathbf{x}) < 0) \end{cases} \quad (2.43)$$

最適化で NGnet-ON/OFF 法を用いる場合は式 2.40 の w_i を実数値 GA の遺伝子とすることで、出力関数の形状を変化させる。従来の ON/OFF 法では物性決定には要素ごとに正か負の値を与えるステップ関数を使用していた。一方、NGnet は複数の要素にまたがる台を持つ滑らかな関数から形状を決める。したがって、要素の形状に依存しない、滑らかな最適形状が得られることが期待される。また、遺伝子の数もガウス基底の個数分のみであるため、有限要素毎の物性値を決める ON/OFF 法よりも少ない個体数で最適化を実行することが可能である。


文献 [58] では本手法は IPM モータのみならず、シンクロナスリラクタンスモータ (SynRM) にも有効であることを示されている。文献 [59] ではオルタネータ用発電機のようなクロポール型の三次元コア形状に NGnet を適用し、発電特性の向上を図っている。また、モータ以外の電気機器への適用もなされている。文献 [60] においてはマイクロ波エネルギーハーベスター用の広帯域アレイアンテナの形状に NGnet を適用し、有用性を示されている。



(a) 5つのガウス関数を配置した場合



(b) 正規化されたガウス関数 (iii)



(c) 重み付けされた正規化ガウス関数

図 2.12: 正規化ガウス関数ネットワーク

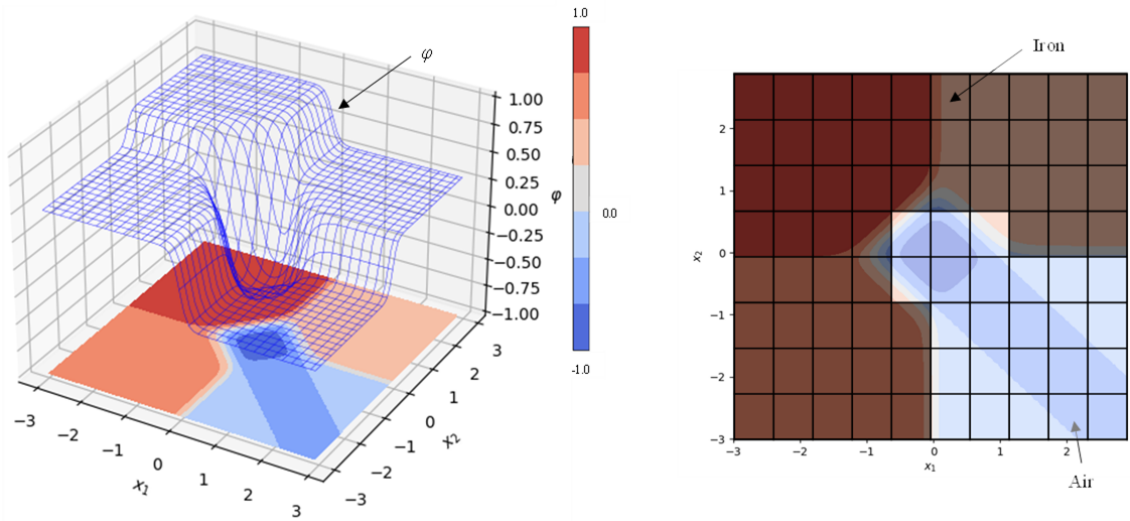


図 2.13: 基底関数を用いた ON/OFF 法

る. さらに, 文献 [61] においてはスロットアンテナに用いる小型レンズの三次元トポロジー最適化に NGnet を用いられている. また, 著者は本手法を用いて IPM モータおよび SynRM の既存モデル最適化手法を提案している [62].

さらにガウス基底の代わりにフーリエ級数展開された三角関数を用いて要素の状態を定めるフーリエ級数 ON/OFF 法を提案している [63]. フーリエ級数 ON/OFF 法は二軸に配置した三角関数を利用する. 出力関数は式 2.44 のように定義される.

$$\begin{aligned} \phi(\mathbf{x}) = & w_{00} + \sum_{m=1}^M \sum_{n=1}^N w_{mn} \sin\left(m\pi \frac{x_M}{T_M}\right) \sin\left(n\pi \frac{x_N}{T_N}\right) \\ & + \sum_{m=1}^M \sum_{n=1}^N w'_{mn} \cos\left(m\pi \frac{x_M}{T_M}\right) \cos\left(n\pi \frac{x_N}{T_N}\right) \end{aligned} \quad (2.44)$$

ここで, M, N, T_M, T_N はそれぞれフーリエ級数の次数, および周期である. w_{00} は出力関数のバイアス成分である. 式 2.44 をモータへ適用する場合は式 2.45 で定義することで極座標系で表現する.

$$\begin{aligned} \phi(\mathbf{x}) = & w_{00} + \sum_{m=1}^M \sum_{n=1}^N w_{mn} \sin\left(m\pi \frac{r - r_2}{r_1 - r_2}\right) \sin(4n\theta) \\ & + \sum_{m=1}^M \sum_{n=1}^N w'_{mn} \cos\left(m\pi \frac{r - r_2}{r_1 - r_2}\right) \cos(4n\theta) \end{aligned} \quad (2.45)$$

ここで, r_1, r_2 はそれぞれ設計領域の外半径と内半径である. 本手法は NGnet に比べ設定パラメータが少ないことから, 扱いが簡単である. 一方で工学分野では NGnet-ON/OFF 法が広く利用されていることから, 本研究では基底関数として NGnet を用いている.

2.5 モータ理論

2.5.1 概要

本研究では埋込型永久磁石 (IPM: Interior Permanent Magnet) 同期モータの断面コア形状を最適化対象とする。そこで、本節では最適化結果の考察のために必要なモータ理論を述べる。

2.5.2 永久磁石同期モータ

永久磁石同期モータは固定子を作る回転磁界に回転子が同期することにより駆動するモータである。永久磁石同期モータは永久磁石の配置により二種類に大別される。永久磁石を回転子の表面に配置した表面磁石型永久磁石 (SPM: Surface Permanent Magnet) 同期モータと永久磁石を回転子コア内に埋め込んだ IPM モータがある [3]。

図 2.14 に永久磁石同期モータの概要を示す。本研究で検討する IPM モータは固定子および回転子からなる。固定子は巻線が巻回された複数のティースを有している。巻線の巻回方法として 1 本ごとのティースに巻線を巻回する集中巻と複数のティースに跨いで巻回する分布巻がある。集中巻は 1 ティースごとに巻回するため、巻線を巻回しやすいが、固定子起磁力高調波成分が大きいためトルクリップルの要因となる。一方、分布巻は固定子起磁力高調波成分が小さいが、複数のティースを跨ぐため巻回に工夫が必要である。また、分布巻の場合、複数相のコイルが重なるため、コイルエンドが大きくなり軸長が長くなる。図 2.14 は集中巻を示している。実際はこのような特徴を用途に応じて使い分ける。




図 2.14: 永久磁石同期モータの概要

図 2.15 に永久磁石同期モータの回転子を示す。図 2.15(a)(b) はそれぞれ 8 極で構成された SPM モータおよび IPM モータを簡易的に表している。

SPM モータは空隙近くに永久磁石が配置されているため、トルクに寄与する空隙磁束密度基本波成分を高めやすい。セグメント磁石を用いた SPM モータが普及しているが、高

速回転における磁石飛散が懸念される。IPM モータは平板磁石をはじめとした永久磁石を回転子コア内に埋め込む。永久磁石を埋め込むことで永久磁石の飛散を防止できる。さらに、インダクタンスの差による磁気エネルギーを発生源とするリラクタンストルクを活用することが可能である。

IPM モータはコアの形状によって大きくトルク特性が変動するため、コア形状の設計にトポロジー最適化が有効であると考えられる。




図 2.15: 永久磁石同期モータにおける回転子

2.5.3 モータ特性

平均トルク

モータの特性の一つとして平均トルクがあげられる。トルクは回転中心周りに働く力のモーメントを示している。平均トルク T_{ave} は以下のように定義する。

$$T_{ave} = \frac{1}{N} \sum_k^N T_k \quad (2.46)$$

ここで、 N, T_k はそれぞれサンプリング点数およびサンプリング点 k におけるトルク値を示す。

トルクリップル

トルクリップル T_{rip} はトルクの脈動を示す。トルクリップルの要因として、誘起電圧高調波成分および電流リップル等があげられる。つまり、回転子起磁力により生じる空隙磁束密度分布の高調波成分を低減することが求められ、IPM モータの場合コアの形状を工夫する必要がある。

本研究では以下の式にて評価した。

$$T_{rip} = \frac{T_{max} - T_{min}}{T_{ave}} \quad (2.47)$$

ここで T_{max} , T_{min} はそれぞれトルクの最大値および最小値である．本研究で用いる最適化問題ではトルクリップルの次数成分は考慮せず，本式で評価したトルクの振幅を最適化対象としている．

トルク発生要因

トルクの発生要因として磁石磁束によるマグネットトルクおよびリラクタンストルクが挙げられる．図 2.16 に発生要因の概要を示す．マグネットトルクは回転磁界と回転子磁石磁束の吸引反発が要因となり発生する．一方，リラクタンストルクは回転子および固定子内を鎖交する磁束磁路の磁気抵抗を最小化するように働く吸引力により発生するトルクである．永久磁石の透磁率は空気の透磁率と同等と考えることができる．IPM モータの場合，回転子コアの形状によってはインダクタンス変動が大きく，リラクタンストルクを活用しやすい．




図 2.16: トルク発生要因

2.5.4 数学モデル

永久磁石同期モータの数学モデルの導出を行う．図 2.17 に永久磁石同期モータの物理モデルを示す．図に示すように U 相を基準として回転子位置 θ を定義する．対象の永久磁石同期モータは三相交流駆動である．本物理モデルの回路方程式は式 2.48 のように定義される [55]．

$$\begin{bmatrix} v_u \\ v_v \\ v_w \end{bmatrix} = \begin{bmatrix} R + pL_u & pM_{uv} & pM_{wu} \\ pM_{uv} & R + pL_v & pM_{vw} \\ pM_{wu} & pM_{vw} & R + pL_w \end{bmatrix} \begin{bmatrix} i_u \\ i_v \\ i_w \end{bmatrix} - \omega\psi_m \begin{bmatrix} \sin\theta \\ \sin(\theta - \frac{2\pi}{3}) \\ \sin(\theta - \frac{4\pi}{3}) \end{bmatrix} \quad (2.48)$$

ここで， $[v_u v_v v_w]^T, [i_u i_v i_w]^T, R, p, \psi_m, \omega, \theta$ はそれぞれ U 相 V 相 W 相の相電圧，相電流，巻線抵抗，微分演算子，磁石磁束鎖交数，回転角速度，U 相と永久磁石磁極の位相であり， L, M はそれぞれ自己インダクタンスおよび相互インダクタンスである．固定子巻線に鎖交する回転子の磁石磁束は回転子の回転に応じて変動するため，式 2.48 は θ に依存することとなる．また，本検討で扱う IPM モータは回転子位置により固定子側から見て相対的にコア形状が変化することから，自己インダクタンスおよび相互インダクタンスも θ に

依存し、式 2.48 の第 1 項も同様に θ に依存した項となる [56]. このように三相で表したモータ回路方程式は回転子位相 θ に依存しており、制御における扱いが難しい [55]. そこで、一般的にモータ制御においては回転座標系を用いることで三相交流を二軸の直流成分で表現することにより、電圧方程式を簡素化して考える.

2.5.5 三相二相変換

まず、三相交流を二相交流で表すことを考える. 図 2.18 に概要を示す [56]. 本図は三相座標と二相座標を重ねたものである. 三相座標上で UVW 相の電流および電圧が変動する. 三相電流を二軸 α, β 軸で表現することを考えると、以下のように変換することが可能である.

$$\begin{cases} i_\alpha = i_u - \frac{1}{2}i_v - \frac{1}{2}i_w \\ i_\beta = \frac{\sqrt{3}}{2}i_v - \frac{\sqrt{3}}{2}i_w \end{cases} \quad (2.49)$$

行列表記すると以下のようなになる.

$$\begin{bmatrix} i_\alpha \\ i_\beta \end{bmatrix} = \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} i_u \\ i_v \\ i_w \end{bmatrix} \quad (2.50)$$

このことから、三相二相変換行列 $[C_{\alpha\beta/uvw}]$ を以下のように定義できる.

$$[C_{\alpha\beta/uvw}] = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \quad (2.51)$$

ここで、 $\sqrt{\frac{2}{3}}$ は座標変換前後で電力不変とする換算項である.

2.5.6 二相回転座標変換

このように変換した二相に変換した場合もそれぞれの軸成分は交流のままである. インバータによる制御を行う場合、交流を直接制御するよりも直流を制御する方が容易である. そこで、二軸成分を回転子の回転位相 θ に依存しないよう θ で回転する座標系に変換することを考える.

図 2.19 に dq 変換の概要を示す. 回転座標系の磁極方向を d 軸、それと直角な軸を q 軸と定義する. 回転座標変換行列 $[C_{dq/\alpha\beta}]$ は以下のように定義できる.

$$[C_{dq/\alpha\beta}] = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \quad (2.52)$$

この回転座標系は電気角基本波成分と同期しているため、dq 軸上で直流成分として現れる. 最終的に、三相から二相回転座標系に変換する変換行列 $[C_{uvw/dq}]$ は以下のように定義される.

$$[C_{dq/uvw}] = [C_{dq/\alpha\beta}] [C_{\alpha\beta/uvw}] \quad (2.53)$$




図 2.17: 永久磁石同期モータの等価モデル [56]




図 2.18: 三相 → 二相変換 [56]

これにより、モータ制御理論を簡素化して論ずることが可能となる。よって、式2.48は式2.54のように表すことができる [56].

$$\begin{bmatrix} v_d \\ v_q \end{bmatrix} = \begin{bmatrix} R + pL_d & -\omega L_q \\ \omega L_d & R + pL_q \end{bmatrix} \begin{bmatrix} i_d \\ i_q \end{bmatrix} + \omega \psi_m \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (2.54)$$




図 2.19: dq 変換 [56]

2.5.7 理論トルク

次にトルク方程式を算出する。出力電力 P_{out} はトルク T と機械角回転角速度の積で求められるため、

$$P_{out} = T\omega_m \quad (2.55)$$

と定義できる。ここで電気角角速度 ω_r と機械角角速度 ω_m の関係は

$$\omega = P_n \omega_m \quad (2.56)$$

ここで、 P_n は極対数を示す。また、入力電力 P_{in} は電流と電圧の積で表すことができる。よって、式2.57のように表すことができる [56].

$$\begin{aligned} P_{in} &= [i_d \ i_q] \begin{bmatrix} v_d \\ v_q \end{bmatrix} \\ &= R(i_d^2 + i_q^2) + \frac{1}{2}(pL_d i_d^2 + pL_q i_q^2) + \omega \{ \psi_m i_q + (L_d - L_q) i_d i_q \} \end{aligned} \quad (2.57)$$

式2.57の第一項，第二項はそれぞれコイル抵抗による銅損，コイルのインダクタンスに蓄積されるエネルギーを示す．第三項は出力電力を示すため，式2.55と等価である．よってトルク T は式2.58と書ける [56].

$$T = P_n \{ \psi_m i_q + (L_d - L_q) i_d i_q \} \quad (2.58)$$

式2.58の第一項は磁石磁束に起因するマグネットトルクを示し，第二項はインダクタンスの差を利用したリラクタンストルクを示している．例えばSPMモータのような回転子の回転に応じて磁気抵抗が変化しない形状は $L_d = L_q$ となり，マグネットトルクのみが発生することとなる．また， $i_d = 0$ の場合もリラクタンストルクは発生しない．

2.5.8 電流位相

次に，IPMモータの平均トルクが最大となる電流位相角度 θ' 範囲を算出する． i_d, i_q を以下のように定義する [55]．また，図2.20にマグネットトルクおよびリラクタンストルクの電流位相角の依存性を示す．

$$\begin{cases} i_d = -I_a \sin \theta' \\ i_q = I_a \cos \theta' \end{cases} \quad (2.59)$$

ここで， $I_a = \sqrt{i_d^2 + i_q^2}$ である．式2.58に式2.59を代入する．

$$T = P_n \{ \psi_m I_a \cos \theta' - (L_d - L_q) I_a^2 \cos \theta' \sin \theta' \} \quad (2.60)$$

式2.60を θ' で微分すると

$$\frac{\partial T}{\partial \theta'} = P_n \{ -\psi_m I_a \sin \theta' - (L_d - L_q) I_a^2 (\cos^2 \theta' - \sin^2 \theta') \} \quad (2.61)$$

第一項が0となる場合は $\theta' = 0$ の場合であり，第二項が0となるのは $\theta' = \frac{\pi}{4}$ の場合である．つまり， $\theta' = 0 \sim \frac{\pi}{4}$ の間にIPMの最大トルク電流位相角がある．本検討では $\theta' = \frac{\pi}{6}$ で固定して最適化問題を解く．

2.5.9 本研究で扱う最適化問題における理論的解釈

本研究ではIPMモータの平均トルク最大化およびトルクリップル最小化問題を解く．電流位相 $\theta' = \frac{\pi}{6}$ であるから，マグネットトルクおよびリラクタンストルクがどちらも発生し得る．

マグネットトルクを増加させるためには式2.58より ψ_m を増大させる工夫が必要である． ψ_m は固定子に鎖交する磁石磁束を指す． ψ_m を増大させるためには，磁石残留磁束密度が高い永久磁石を用いることが考えられる．磁石グレードを変更せずにコア形状のみで磁石磁束を最大限活用するためには回転子コア内の漏れ磁束を低減する形状とする必要がある．リラクタンストルクを最大化するためにはd軸インダクタンスおよびq軸インダクタンスの差を大きくする必要がある．また，三相正弦波通電を想定しているため，トルクリップルを減少させるためには ψ_m および $L_d - L_q$ の高次成分を減少させる必要がある．




図 2.20: マグネットトルクおよびリラクタンストルクの概要

2.5.10 節点法によるトルク導出

2.5.7 節ではモータの理論トルクの導出を行った。本検討では FEM によりベクトルポテンシャルを導出後、式 2.8 によって磁束密度を求める。平均トルクおよびトルクリップルを求める際には磁束密度分布よりトルク導出が可能な節点法を用いた [38]。

節点法により、FEM により算出した磁束密度分布より各節点に働く電磁力を算出する。本研究では二次元における節点法を適用し、そこで算出されたトルクの値を単位厚さあたりのトルク値であると考え、厚みを乗じたものをモータの回転子全体のトルク値とする。図 2.21 に概要を示す。

仮想変位により得られるエネルギー変化を考えると、節点 i における節点力 f_i は以下のように書ける [38]。

$$f_i = - \iint_S (\mathbf{T} \cdot \nabla N_i) dS \quad (2.62)$$

ここで、 \mathbf{T} 、 N_i はそれぞれマクスウェルの応力テンソル、補間関数である。単位面積あたりに働く力は電流密度と磁束密度の外積であり、マクスウェルの応力テンソル \mathbf{T} の発散と等価であると考えると、マクスウェルの応力テンソル \mathbf{T} は以下のように定義できる。

$$\mathbf{T} = \frac{1}{2\mu} \begin{bmatrix} B_x^2 - B_y^2 & 2B_x B_y \\ 2B_x B_y & B_y^2 - B_x^2 \end{bmatrix} \quad (2.63)$$

ここで、 B_x, B_y はそれぞれ磁束密度の x 方向、 y 方向成分である。今、仮想変位により得られるエネルギー変化が各節点におけるエネルギーの線形和で表されるとするならば、求めたい領域に発生する力は節点力の和で求めることができる。よって、二次元空間においてトルク T は以下の式で算出される。

$$T = \sum_i l_i t_i f_i \quad (2.64)$$




図 2.21: 節点力法 [38]

ここで、 l_i, t_i, f_i はそれぞれ、節点 i の中心からの半径、単位接線ベクトル、節点力である。式 2.64 を節点座標 (x_i, y_i) を用いて表すと、

$$\begin{aligned}
 T &= \sum_i \sqrt{x_i^2 + y_i^2} \left\{ -\frac{y_i}{\sqrt{x_i^2 + y_i^2}}, \frac{x_i}{\sqrt{x_i^2 + y_i^2}} \right\} \begin{bmatrix} f_{xi} \\ f_{yi} \end{bmatrix} \\
 &= \sum_i (-y_i f_{xi} + x_i f_{yi})
 \end{aligned} \tag{2.65}$$

と書ける [38]。ここで、 f_{xi}, f_{yi} はそれぞれ節点 i の節点力 x 方向成分、 y 方向成分を示す。以上より、磁束密度からトルクを算出することができる。

2.5.11 電気学会 D モデル

さまざまな IPM モータが提案されているが、リファレンスモデルとして各研究機関にて使用されている電気学会 D モデル [57] を最適化対象とした。図 2.22 に電気学会 D モデルを示す。さらに表 2.4 に電気学会 D モデルの仕様を示す。本モータは 4 極 24 スロットの分布巻モータである。回転子の内部に径方向に着磁された永久磁石と永久磁石端部から空気領域が配置されている。この空気領域は永久磁石磁束を d 軸方向に鎖交させ、マグネットトルクを増加させる効果がある。永久磁石の残留磁束密度は 1.25T である。4 極 24 スロットのモータは理想的に 90 度ごとに同様の磁束分布を示す。したがって、FEM では 90 度モデルを用い、0 度及び 90 度に回転周期条件を課し、解析を行う。

図 2.23 に電気学会 D モデルのトルク波形を示す。また、図 2.24 にトルク波形をフーリエ級数展開し、トルク次数を抽出した結果を示す。平均トルク T_{ave}^0 およびトルクリップル T_{rip}^0 はそれぞれ $T_{ave}^0 = 2.1\text{Nm}$ および $T_{rip}^0 = 0.57$ である。トルク波形は電気角 12 次成分が支配的な波形であることが確認できる。図 2.25 にある回転角度における磁束分布を示

す。磁石磁束がd軸方向鎖交するよう永久磁石端部の空隙が配置されていることが確認できる。最適化内では電気角1/6周期を5ステップ解析し、平均トルクおよびトルクリップルを評価した。




図 2.22: 電気学会 D モデル [57]

表 2.4: 電気学会 D モデル仕様

Number of Poles	4
Number of Slots	24
Rotor Inner Diameter[mm]	16
Rotor Outer Diameter [mm]	55
Stator Inner Diameter[mm]	56
Stator Outer Diameter [mm]	112
Shaft Length[mm]	65
Electrical steel	50A470
Magnet Thickness[mm]	2.5
Magnet Amount[mm ³]	1706.25
Remanence[T]	1.25
Current[Arms]	3.0
Current phase angle[deg]	30
Number of Turns[turn]	35




図 2.23: 電気学会 D モデルトルク波形




図 2.24: 電気学会 D モデルトルク次数成分




図 2.25: 電気学会 D モデル磁束分布

2.6 計算機環境

本研究における計算環境を表 2.5 に示す。クロック数 3.5GHz, 4 コア 16 スレッドの CPU を用いる。GPU は NVIDIA Tesla V100 を用いる。本検討では最適化処理および磁界解析は CPU を使用し, CNN の演算には GPU を用いる。磁界解析の際には複数コアによる並列計算を行っている。

表 2.5: 計算機環境

CPU	Intel(R) Xeon(R) E5-2637v4	3.5GHz
OS	Ubuntu 16.04.5	
Memory	64GB	
GPU	NVIDIA Tesla V100	PCIE 16GB

2.7 総括

本章では本研究で用いる基礎理論について述べた。まず、モータの解析に用いた二次元静磁場解析における FEM の定式化について述べた。次に最適解の探索に用いた実数値遺伝的アルゴリズムによる単目的最適化や多目的最適化の理論を述べ、作成した最適化コードの妥当性をテスト関数を用いて確認した。また、トポロジー最適化で使用した NGnet-ON/OFF 法について述べた。さらに、回転機のトルクの発生原理および節点力法について述べた。最後に最適化のリファレンスモデルとして用いた電気学会 D モデルの解析結果について述べた。

第3章 CNNを用いたモータ特性推定精度向上手法の提案

3.1 はじめに

第2章で述べたように、モータ形状のトポロジー最適化においてFEMによる解析によりモータ特性を求め、探索アルゴリズムにおける評価値算出に用いる。モータ等の電気機器のトポロジー最適化の問題点の一つとして最適化時間が挙げられる。FEMによる解析時間や解析回数が増加すると、それに比例して最適化時間は増加する。近年、FEMの解析モデルが複雑化し、高精度化が図られる一方で、解析時間の増大が懸念される。さらに、モータ体格の小型化や高負荷域駆動による磁気飽和の影響や、解析モデルの大規模化による未知数の増加でニュートン・ラフソン法やICCG法の収束性悪化が懸念される。また、トポロジー最適化のような自由度の高い問題においてGAを用いる場合、十分な探索性能を保証するためには必要な探索個体数が増大する。このような背景から、実用化の観点から現実的な時間内で解を得られるような探索アルゴリズムが求められている。

FEMなどによる電磁界解析の代用として、何らかの代理モデル(Surrogate model)を用いる求解手法に関して研究されている。代表的な代理モデルとして、応答局面法[64][65]、クリギング法[66][67]、空間写像法(space mapping)[68]などがある[69]。これらの手法は様々な物理現象を簡易表現するために広く適用検討がなされている。しかし、非線形性問題や高次元問題に対して高精度に代理モデルを作成することは難しく、新たな手法が求められている。

そのような背景から、脳の神経細胞(ニューロン)から構成する神経回路を模倣したニューラルネットワーク(Neural network: NN)による代理モデルが提案されている[23]。近年はNNの多層化や構成の工夫により、さらなる特徴量抽出精度の向上がなされている。最適化においてもNNを用いて高効率探索を行う手法の提案がなされている。文献[70]においてNGnetを用いたトポロジー最適化でガウス基底関数の重みを入力としたNNの構築手法の提案されている。本手法のように設計変数やガウス基底の重みを入力変数とすると、その入力変数に対する特性を出力するネットワークを形成することができる。しかし、設計変数に依存したネットワークは変数の増減や配置変更を行うと再度ネットワーク構築を行う必要があり、汎用的なモデルとは言えない[69]。

そこで畳込みNN(CNN: Convolutional neural network)による特徴量抽出を考える。CNNは画像などを畳込み処理することにより特徴量を抽出可能であり、画像認識分野で盛んに用いられている[23][71][73][74]。本手法を用いて設計対象の特徴量を抽出することで、パラメータの考慮が不要となる。設計分野ではCADを代表とした図面作成ソフトを用いる場合が多く、CNNで用いるデータと親和性が高いと思われる。また、最適化内では材料分布と特性値のデータセットを容易に生成可能なため、大量に多様なデータを収集

3.2. 深層学習

可能と考えられる。

以上の観点から、著者はトポロジー最適化の最適化時間短縮のため、CNNをFEMの代理モデルとして用いるトポロジー最適化を提案している [25]。本手法により、最適化時間が従来手法に比べ削減されることが示されているが、CNNのモータ特性推定精度向上に関する議論は少ない。電磁界解析の代用としてCNNを用いている例は少なく議論の余地がある。

そこで、本章ではCNNの回転機特性推定精度向上手法として磁束密度分布を教師データとして用いた場合の効果を検証する。また、モータのトポロジー最適化にCNNを併用した場合のCNN推定精度とトポロジー最適化探索性能の関係性を検証する [28][29]。

本章の構成を述べる。まず、3.2節では深層学習 (DL: Deep Learning) の概要について述べる。3.3節においてCNNのモータ磁気特性推定手法について述べる。さらにCNNの推定精度向上のため、磁気非線形性を特徴量抽出する手法について提案する。3.4節にてDLをトポロジー最適化内へ組み込むアルゴリズムについて述べる。さらに、CNNの推定精度の違いにおけるトポロジー最適化探索性能について考察を行う。最後に、3.5節にて本章の総括を述べる。

3.2 深層学習

3.2.1 概要

深層学習 (DL: Deep Learning) は機械学習 (ML: Machine Learning) の一種である [23]。MLは多数のデータセットを用いてデータ内にある規則性、特徴量を抽出し、モデルを生成する手法である。従来のMLはあらかじめ人間によって定義された特徴に従って学習を行うものであった。つまり、特徴量の指定を人間によって行う必要があった。一方、DLは多層 perceptron を使用したモデルであり、入力の特徴量を自動的に抽出することが可能である。本節ではその基礎理論について述べる。

3.2.2 ニューラルネットワーク

perceptron および活性化関数

本項ではNNの基礎となる perceptron について述べる。perceptron は入力した信号の伝達を表現するアルゴリズムである。図3.1に perceptron の概要を示す。図3.1の perceptron は以下のように示される [72]。

$$u(\mathbf{x}) = a_0 + \sum_{k=1}^n a_k x_k \quad (3.1)$$

$$\phi(u) = \begin{cases} 0 & (u \leq \theta) \\ 1 & (\text{otherwise}) \end{cases} \quad (3.2)$$

ここで \mathbf{x} および \mathbf{a} はそれぞれ入力および重みである。入力と重みの線形結合を u とし、閾値 θ をもつステップ関数 ϕ を用いて、0または1の出力を決定している。

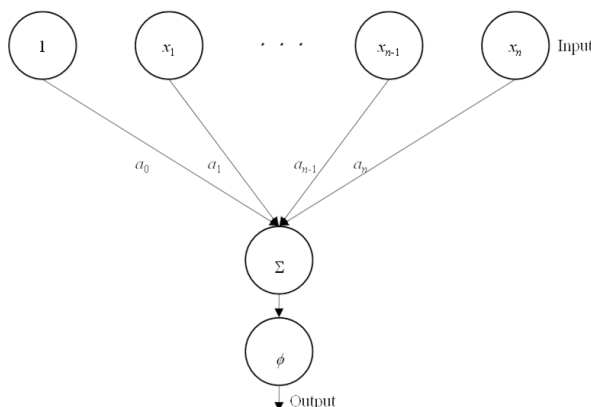


図 3.1: perceptron

perceptron はステップ関数 ϕ を用いて出力を定義した。この perceptron の出力関数を別の関数に置き換え、多重に連結させたものが NN である。perceptron の出力関数にあたる関数を活性化関数と呼ぶ。NN で用いられる活性化関数として図 3.2 のような sigmoid 関数

$$\phi(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$

が一般的に用いられてきた [23]。ステップ関数と異なり、連続的な実数値を出力する。また、sigmoid 関数は微分可能であるため、勾配法による学習が可能である。一方、近年は図 3.3 に示す ReLU 関数と呼ばれる活性化関数が用いられることが多い [75]。ReLU 関数は以下のように定義される。

$$\phi(x) = \max\{0, x\} \quad (3.4)$$

ReLU 関数は $\phi(0)$ で微分不可能である。 $x < 0$ において微分値は 0 であり、 $x > 0$ において 1 となる。 $x = 0$ の状況は学習において発生しないことを前提として用いる。本関数により、勾配が減衰することなく後段の層にも伝達することが可能である。以上の点より、ReLU 関数を用いることで勾配消失問題が緩和されることが報告されている [75]。また、単純な関数であるため、扱いが簡単である。

NN を多層化する場合、 n 層目の m 番目における出力 y_m^n は以下の式で求められる。

$$u_m^n(\mathbf{y}^{n-1}) = a_0^{n-1} + \sum_{k=1}^{m_{max}^{n-1}} a_k^{n-1} y_k^{n-1} \quad (3.5)$$

$$y_m^n = \phi(u_m^n(\mathbf{y}^{n-1})) \quad (3.6)$$

ここで、 m_{max}^{n-1} は $n - 1$ 番目の層における出力数である。また、このように全出力を結合する層を全結合層と呼ぶ。

3.2. 深層学習




図 3.2: sigmoid 関数




図 3.3: ReLU 関数

出力層

DL で用いる問題として大きく分類問題と回帰問題に分けられる。図 3.4 に二つの問題の概要を示す。分類問題はあらかじめ複数のラベルを用意し、入力したデータが特定のラベルに当てはまる確率を出力をする。回帰問題は予測対象の実数値を出力する。物体認識等は物体名を推定するため、分類問題を解く場合が多い。一方、平均トルクやトルクリップルなどの実数値を推定する場合、回帰問題を解くことで直接推定値を出力することが可能である。

それぞれの問題における出力層の構成は大きく異なる。分類問題における出力層は softmax 関数を用いる場合が多い。softmax 関数は最大値および出力の合計が 1 となる性質を持つ。これにより、出力のマルチヌーイ分布を求め、確率分布と対応させる。softmax 関数は以下の式で定義される。

$$y_m^k = \frac{e^{y_m^{k-1}}}{\sum_m e^{y_m^{k-1}}} \quad (3.7)$$

ここで k は最終層を示す。 y_m^k の最大値は 1 であり、softmax 関数の総和 $\sum_m y_m^k$ も必ず 1 となる。本研究ではそれぞれの出力に対する確率分布を出力し、最大確率のラベルを解と

する。分類問題の場合、ラベル数分の出力がある。回帰問題の場合、最終層を1つのノードとし、恒等関数を用いて出力する。

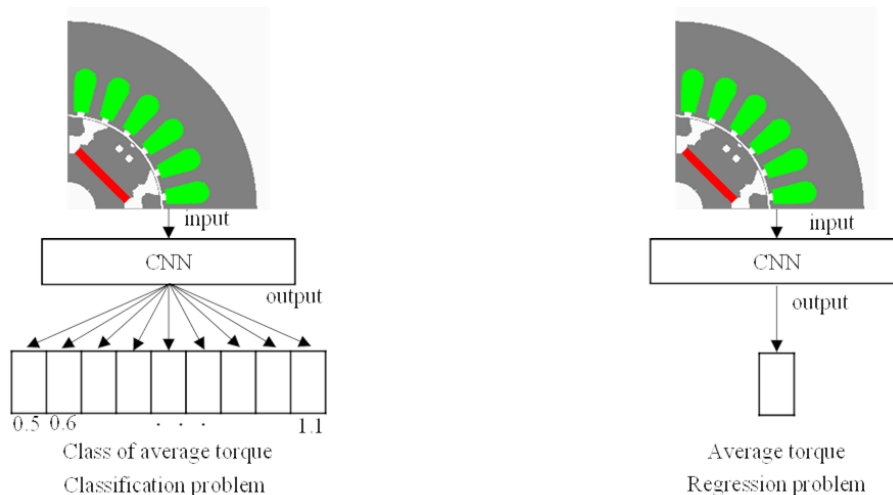


図 3.4: 分類問題と回帰問題

3.2.3 畳込みニューラルネットワーク

CNN は画像認識や音声認識分野で幅広く用いられている手法である [76]。本手法は前項までの層構成に加え、畳込み層と pooling 層で構成されている。図 3.5 に CNN の概要を示す。

畳込み層では入力されたデータに対してフィルタを用いた畳込み処理を行う。単純な DNN における全結合層では位置情報がないため、入力する画像データの隣接するピクセル間の相対関係を失うこととなる。一方、畳込み処理は隣接する要素を足し合わせることで、相対位置情報を維持したまま入出力関係を構築可能である。




図 3.5: 畳込みニューラルネットワーク

3.2. 深層学習

畳込み処理

一般的に畳込み演算は以下のように定義される。

$$c_x = \int k(u) \cdot b(x - u) du \tag{3.8}$$

ここで、 k, b はそれぞれフィルタ関数、被畳込み関数である。本処理を離散化すると以下のようにかける。

$$c_x = \sum_{u=-\infty}^{\infty} k(u) \cdot b(x - u) \tag{3.9}$$

フィルタ関数により特徴量の圧縮を行うことが可能である。本関数を二次元に拡張し、畳込み処理を行う。

畳込み層における畳込み処理の概要を図3.6に示す。図3.6は 3×3 の入力と 2×2 の畳込みフィルタおよび畳込みされた 2×2 の出力を示している。各畳込み演算におけるフィルタの移動量をスライド量と呼ぶ。本例の場合、スライド量は1である。それぞれの出力は以下のように求める。

$$c_{i,j} = \sum_{s=1}^2 \sum_{t=1}^2 k_{s,t} b_{i+s-2, j+t-2} \tag{3.10}$$

CNNの学習の際にはフィルタ関数の重みを更新する。




図 3.6: 畳込み処理

pooling 処理

畳込み処理の後、pooling層を通して層を縮小する。本層の効果として、入力に対するロバスト性が向上される点がある。代表的な処理として最大値を抜き出すmax pooling処理がある。max pooling処理の概要を図3.7に示す。max pooling処理は以下の式で定義される。

$$c_{i,j} = \max\{b_{i-1,j-1}, b_{i,j-1}, b_{i-1,j}, b_{i,j}\} \tag{3.11}$$

ここで、 $\max\{\}$ は $\{\}$ 内における最大値を示しており、あるフィルタ内における最大値を出力として次の層の値とする。




図 3.7: pooling 処理

3.2.4 学習方法

損失関数

3.2.2 節で述べたニューラルネットワークの重みはデータを用いて学習することで得られる。大量のデータから重みを学習するために損失関数 L を定義する。損失関数は NN の出力と教師データの誤差を示しており、損失関数の値が最小となるよう、反復計算を行う。

損失関数の代表的なものとして二乗和誤差および交叉エントロピー誤差が挙げられる [23]。二乗和誤差は以下の式で定義される。

$$L = \frac{1}{2} \sum_m (y_m - y'_m)^2 \quad (3.12)$$

さらに交叉エントロピー誤差は以下の式で定義される。

$$L = - \sum_m y'_m \log y_m \quad (3.13)$$

ここで、 y_m および y'_m は m 次元の出力を持つ NN の最終層の出力および教師データを示す。損失関数 L を 0 に近づけることでそれぞれの出力と教師データの差が小さくなり、NN の重みは教師データと近い値を出力するよう決定される。

勾配法

損失関数を最小化するため、連続最適化問題を解く。学習アルゴリズムとして勾配法が用いられることが多い [45]。勾配法は損失関数の勾配の降下方向に探索する最適化アルゴリズムである。従来、勾配降下法はすべてのデータを用いて勾配を算出する。しかし、多くの教師データを用いる DL の学習においては、すべてのデータを用いて勾配を計算すると計算量が莫大となる。すべてのデータを用いたとしても、冗長的な勾配情報である可能性もある。

本問題を解決する手法として確率的勾配降下法 (SGD: Stochastic Gradient Descent) が挙げられる。SGD はすべてのデータではなく、1 つのデータをランダムに抽出し、そのデータを用いて損失関数の勾配を求め、何度も繰り返す。SGD はランダム性が強く、従来

3.2. 深層学習

の勾配法に比べ勾配の分散が大きくなるため、学習率を小さくする必要がある [23]. この場合、収束性の悪化が懸念される. そこで、DL の学習において、ミニバッチ確率的勾配降下法が用いられることが多い. 本手法は全データの中から複数のデータをランダムに抽出し、損失関数の勾配を求める.

勾配法において重みの更新は以下の式で表現できる.

$$\mathbf{a}_{t+1} = \mathbf{a}_t - \eta \nabla_{\mathbf{a}_t} L \quad (3.14)$$

ここで、 \mathbf{a}_t, η はそれぞれ t ステップ目の重みベクトルおよび学習率である. また、 $\nabla_{\mathbf{a}_t}$ は t ステップ目の \mathbf{a} による微分演算子であり、 $\nabla_{\mathbf{a}_t} L$ は損失関数のそれぞれの重みによる微分によるベクトルであり $n-1$ 層目に限定すると以下のように示される.

$$\nabla_{\mathbf{a}_t} L = \left[\frac{\partial L}{\partial a_1^{n-1}} \quad \cdots \quad \frac{\partial L}{\partial a_{max}^{n-1}} \right]^T \quad (3.15)$$

確率的勾配法は損失関数の最急な方向に更新を行う. しかし、損失関数の最小値は必ずしもその点における勾配方向にあるとは限らない. そのため、空間によっては式 3.14 を用いると局所解に陥る可能性もある.

Momentam SGD

SGD 法を改良したアルゴリズムとして、Momentam SDG 法がある [77]. 本アルゴリズムは Momentam 項を導入した式 3.16 および式 3.17 を用いる.

$$\mathbf{a}_{t+1} = \mathbf{a}_t + \mathbf{v}_t \quad (3.16)$$

$$\mathbf{v}_t = \alpha \mathbf{v}_{t-1} - \eta \nabla_{\mathbf{a}_{t-1}} L \quad (3.17)$$

ここで、 \mathbf{a}_t, α は t ステップ目における Momentam 項および更新幅を示す. Momentam 項により、 $t-1$ ステップにおける勾配の影響を加味して $t+1$ ステップ目の更新を行う. つまり、物理法則における慣性力にあたる効果を示している.

RMSProp

Momentam SDG は学習係数 η を固定値で学習している. η は学習性能に大きく影響を及ぼすため、重要なパラメータである. RMSProp はこの η を可変とする手法である [78]. 学習が進むにつれ学習係数 η を減衰させる. 本手法は以下の式で更新される.

$$\mathbf{s}_t = \mathbf{s}_{t-1} + \nabla_{\mathbf{a}_t} L \otimes \nabla_{\mathbf{a}_t} L \quad (3.18)$$

$$\mathbf{a}_{t+1} = \mathbf{a}_t - \eta \frac{1}{\sqrt{\mathbf{s}_t}} \nabla_{\mathbf{a}_t} L \quad (3.19)$$

ここで、 \otimes はアダマール積を表し、それぞれの要素の積である. $\frac{1}{\sqrt{\mathbf{s}_t}}$ により、学習が進むにつれ学習率が小さくなる.

AdaGradは過去に用いた勾配情報をすべて用いる [79]. しかし, その場合, 学習の後半は学習率が0に限りなく近づくため, しだいに学習更新が停滞する. そこで, RMSPropは過去の勾配をすべて均一に加算するのではなく, 指数関数的に直近の勾配の効果を重視する.

誤差逆伝播法

学習の際にはそれぞれの層において $\nabla_{a_i} L$ を求める必要がある. それぞれの勾配を直接計算すると計算時間が膨大となる. そこで, 誤差逆伝播法を用いて高速に勾配を求めることを考える [23].

誤差逆伝播法の基礎は合成関数における連鎖律である. 合成関数 $f(h(x))$ における f の x に関する微分は次のように求められる.

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial h} \frac{\partial h}{\partial x} \quad (3.20)$$

このような性質を微分の連鎖律という. 本性質を用いて損失関数 L を a_m^k で微分することを考える. 微分連鎖律より次のように微分できる.

$$\frac{\partial L}{\partial a_m^k} = \sum_i \frac{\partial L}{\partial y_i^{k+1}} \frac{\partial y_i^{k+1}}{\partial u_i^{k+1}} \frac{\partial u_i^{k+1}}{\partial a_m^k} \quad (3.21)$$

ここで, 損失関数 L の y_i^{k+1} による微分は以下のように書ける.

$$\frac{\partial L}{\partial y_i^{k+1}} = \sum_j \frac{\partial L}{\partial y_j^{k+2}} \frac{\partial y_j^{k+2}}{\partial u_j^{k+2}} \frac{\partial u_j^{k+2}}{\partial y_i^{k+1}} \quad (3.22)$$

以上より, k 層目の重み a_m^k における微分を求める際に $k+1$ 層目以降の微分結果を用いている. さらに $k+1$ 層目の微分は $k+2$ 層目の微分を用いて求められる. このように後層の重みを用いて出力層側から結果を伝搬させることで勾配を求めることで計算コストを抑えられる.

3.3 磁気的非線形性を考慮した CNN による特性推定

3.3.1 概要

本節では CNN を用いてモータ特性の特性推定を行う。モータ特性を推定するために用いる教師データおよび学習モデルについて述べたのち、学習済み CNN のテスト結果に関して述べる。

3.3.2 学習対象モータ

図 3.8 に示す 2 種類の磁石配置を有する IPM モータの磁気特性を CNN へ学習させる。それぞれ、一枚および二枚の平板磁石を埋め込んだモータである。以降、それぞれ I 字磁石配置、V 字磁石配置と呼ぶ。

I 字磁石配置は図 2.22 の電気学会 D モデルの回転子コアを設計領域とした形状である。永久磁石は 45 度方向に着磁されており、電気学会 D モデルと同様の磁石量である。V 字磁石配置は I 字磁石配置と磁石量を変えず、二枚の永久磁石を用いた。それぞれの永久磁石の着磁方向は x 軸および y 軸方向である。図 2.22 の斜線部は設計領域を示しており、本領域のコアおよび空気の材料分布を NGnet を用いて決定する。

本検討で用いた教師データは最適化対象の断面材料分布およびある電流条件における磁束密度分布である。教師データとして材料分布により形状の特徴を学習することが可能である。しかし、本検討で扱うモータの特性値はコア内の磁気的非線形特性による影響を受けやすい。コア内の透磁率分布は電流負荷や回転角によって変化する。そこで、本検討ではある電流負荷における磁束密度分布を教師データとして用いる。磁束密度分布は推定特性との相関が強いと考えられ、CNN の推定精度の向上が期待できる。本節では CNN の学習に教師データとして材料分布を用いた場合と磁束密度を用いた場合を比較し、その効果を検証する。

3.3.3 有限要素モデル

次に FEM で用いる有限要素モデルについて述べる。図 3.9 に I 字磁石配置および V 字磁石配置の有限要素モデルを示す。また、表 3.1 に有限要素モデルの緒言を示す。本モデルは四角形要素を用いている。設計領域の要素数は I 字磁石配置および V 字磁石配置で 2931 および 1476 である。

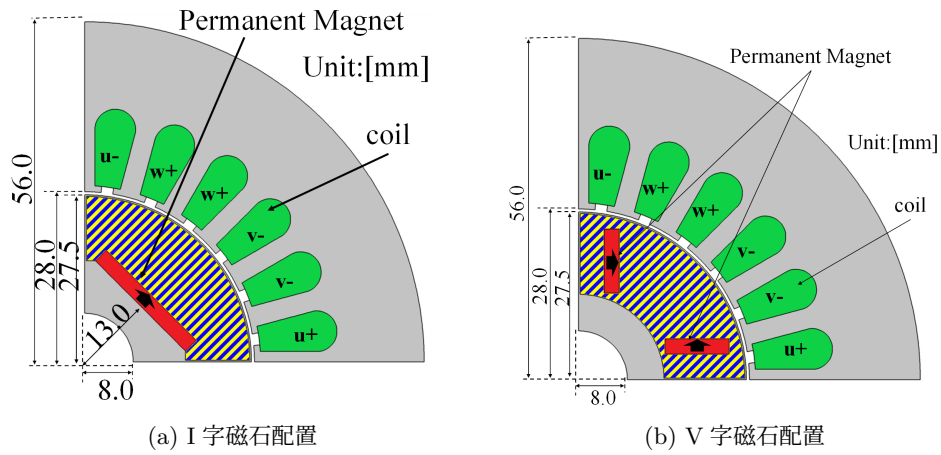


図 3.8: トポロジー最適化対象形状 [29] ©2021 IEEE

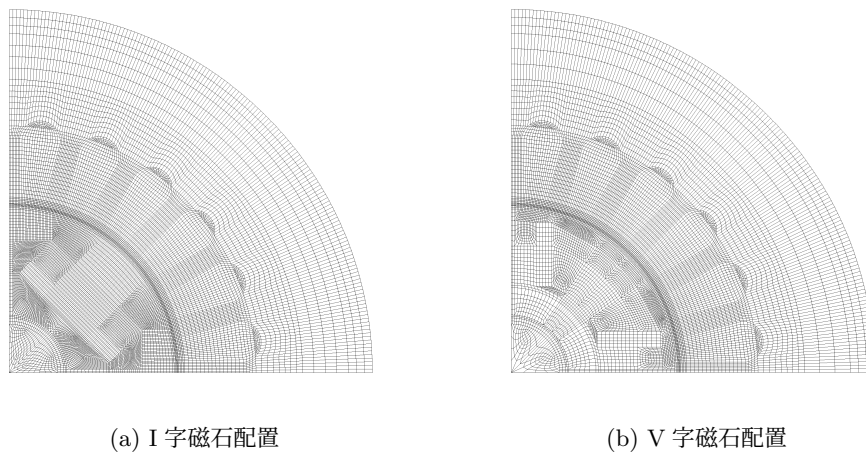


図 3.9: 有限要素モデル

表 3.1: 有限要素モデルの緒言

	I 字磁石配置モデル	V 字磁石配置モデル
要素数	14524	11240
節点数	14687	11395
設計領域要素数	2931	1476

3.3.4 NGnet の設定

図 3.10 に NGnet に用いたガウス基底の配置を示す。本検討では回転方向によらず特性が同一の磁気構造とするため、d 軸に対して線対称な形状を生成する。45 度領域にガウス基底を配置し、材料分布を決定したのちに残りの 45 度領域に材料分布をコピーする。図 3.10 はガウス基底を 54 個配置している。




図 3.10: ガウス基底の配置

3.3.5 学習ネットワーク

本検討に用いた CNN モデルについて述べる。本検討では学習ネットワークとして VGG16 を用いた [80]。図 3.11 に VGG16 のネットワーク構成を示す。VGG16 は Imagenet により学習された 16 層の畳込み層及び全結合層によって構成されている。本モデルは単純な層構成であり、さまざまな研究に用いられている。Imagenet は 1400 万枚超の画像とラベル群であり、様々な CNN 研究に活用されている [81]。オリジナルの VGG16 は最終層が 1000 のため、1000 クラスに分類可能である。問題によってクラス数を変更する場合、最終層の数を変更する。また、回帰問題の場合は VGG16 の層構成を図 3.11(b) のように変更する [82]。

さらに学習において、限られたデータセットで高精度なモデルを作成するため、層の前半 1~8 層目は ImageNet による学習重みで固定し、後半の層は ImageNet の重みを初期値として学習する。このように一部分を学習対象と異なるデータセットより学習した重みを用いて特徴量抽出機能を保ちながら学習する手法が転移学習である。

本研究ではネットワーク構築に keras ライブラリを用いる [83]。keras は python ベースの DL ライブラリである。モジュール性がよく、GPU 上での実装も簡易的であるため、本ライブラリを使用する。

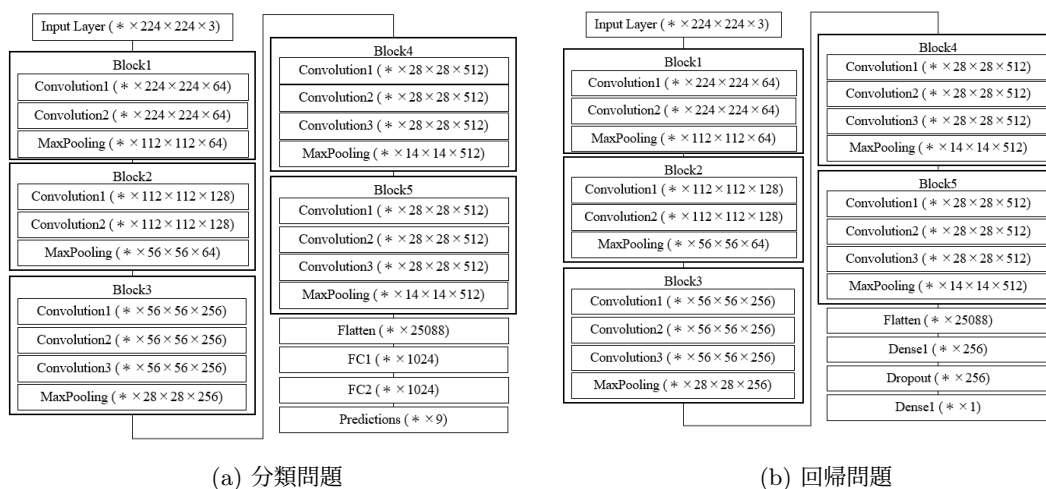


図 3.11: VGG16[28]

3.3.6 教師データ

次に学習に用いた教師データについて述べる。本検討では図 3.8 に示す 2 種類の磁石配置を有する IPM モータの磁気特性を推定する推定器を作成する。図 3.12 に入力データを示す。図 3.12 の入力データは $224 \times 224 \times 3$ のビットマップであり、図 3.12(a)(b) はそれぞれ材料分布と磁束密度分布を示している。今回、VGG16 の入力に対応するため、RGB の 3 入力を用いる。材料分布はコア、空気、永久磁石およびコイル領域を別々の色で表現している。色の表現は RGB の $256 \times 256 \times 256$ 通りの整数で表現される。それぞれのビットの色分布により、モータ断面の材料分布を入力できる。一方、磁束密度分布はグレースケールの濃淡で表現する。図 3.13 に本検討で用いたコア材 50A470 の BH カーブを示す。磁束密度分布は負荷時の磁束コンターを 50A470 の飽和磁束密度 2.3T で正規化したものを用いる。0T の場合、白、2.3T の場合、黒で表現している。




図 3.12: 入力データとして用いたビットマップ例




図 3.13: 50A470 の BH カーブ

回帰問題の場合，出力は平均トルクおよびトルクリップルを示す実数値とする．分類問題の場合，表 3.2 に示すように平均トルクおよびトルクリップルを 8 分類に分類する．表中に示す値は図 2.22 に示す電気学会 D モデルの平均トルク $T_{ave}^0 = 2.1\text{Nm}$ およびトルクリップル $T_{rip}^0 = 0.57$ で正規化した値を用いている．

分類問題に用いる教師データおよびテストデータは表 3.3 に示す最適化設定にて IPM の平均トルク最大化問題を解き，その際に FEM により得られた解析値と材料分布および磁束密度分布を用いる．式 3.23 に目的関数 F を示す．

$$F = \frac{T_{ave}}{T_{ave}^0} \rightarrow \max. \text{ sub.to } \Omega < 2 \quad (3.23)$$

ここで， Ω は断面上に現れる回転子磁性体領域の個数を示している．本制約は回転子コアがすべて連結していることと同義である．回転子は可動体であるため，独立したコアが存在すると構造として成立しない．そこで，図 3.14 に示すように設計領域に連結制約と独立したコアが存在した場合，そのコアをカウントする．その個数が 2 以上の場合，個数に応じてペナルティ制約を課す．連結制約要素としている要素は常にコアであるとする．ペナルティ制約は以下の式に応じて課す．

$$F = F - 500 \times (\Omega - 1) \quad (3.24)$$

また，初期個体および子個体生成時に $\Omega = 1$ となる個体が生成されるよう反復生成し，制約を満たすよう工夫した．各クラスが必要個体数を満たすまで最適化を繰り返す．さらに，回帰問題においては 1 度の最適化で多様な解が得られるよう，表 3.4 に示す最適化設定で多目的最適化を解いた．式 3.25 に目的関数 F_1, F_2 を示す．

$$F_1 = \frac{T_{ave}}{T_{ave}^0} \rightarrow \max. \quad F_2 = \frac{T_{rip}}{T_{rip}^0} \rightarrow \min. \text{ sub.to } \Omega < 2 \quad (3.25)$$

表 3.2: 分類問題における平均トルクおよびトルクリップルの分類

$T_{ave}^{FEM} & T_{rip}^{FEM}$	$T_{ave}^{CNN} & T_{rip}^{CNN}$
~0.45	0
0.45 ~ 0.55	0.5
0.55 ~ 0.65	0.6
0.65 ~ 0.75	0.7
0.75 ~ 0.85	0.8
0.85 ~ 0.95	0.9
0.95 ~ 1.05	1.0
1.05 ~ 1.15	1.1
1.15 ~	1.2

表 3.3: 教師データ生成時の単目的最適化の最適化設定

Number of dimensions	54
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REX ^{star}
Method of Generations	100

表 3.4: 教師データ生成時の多目的最適化の最適化設定

Number of dimensions	54
Number of individual	200
Number of pareto	100
Optimized method	NSGA-II
Method of Crossing over	REXStar
Method of Generations	200

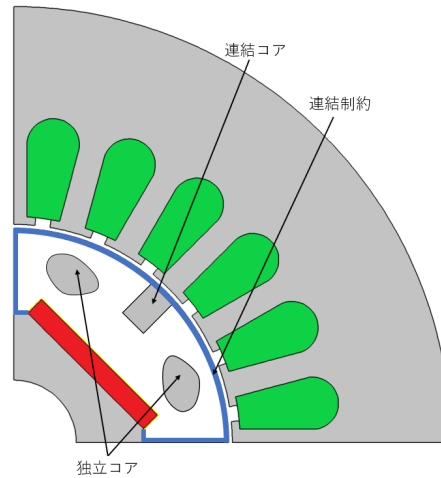


図 3.14: 回転子コア部の連結制約 ($\Omega = 3$ の場合)

3.3.7 磁束密度分布による精度への影響

モータで用いられるコアは非線形磁気特性を有している。限界設計されたモータは高トルク密度化されており、モータ内のコアは磁気飽和が発生する。磁気飽和により透磁率低くなるため、回転により透磁率分布が変動する。そのため、平均トルクおよびトルクリップルに大きく影響を及ぼす。このような背景から、モータ断面の情報からより精度よく平均トルクおよびトルクリップルを推定するためには、コア内の磁気特性状態を入力する必要があると考える。しかし、材料分布のみを入力とすると、コアは同一特性とみなされるため、コア内の透磁率分布は考慮されていない。そこで、本検討では磁気非線形性を考慮するため、磁束密度分布を用いる。磁束密度分布はある駆動状態におけるコアの透磁率分布と等価である。図 3.15 に推定値の異なる形状の材料分布及び磁束密度分布を示す。図 3.15(b) と (d) を比較した場合、固定子コアの磁束密度が大きく異なる。特に平均トルク $T_{\text{ave}}^{\text{FEM}} = 1.1$ の場合、固定子側の磁束密度は $T_{\text{ave}}^{\text{FEM}} = 0.5$ の場合に比べ高い。また、回転子コア幅の狭い領域は磁束飽和している。このように、固定子側の情報量増加及び磁気非線形性の考慮により、推定精度の向上が期待できる。

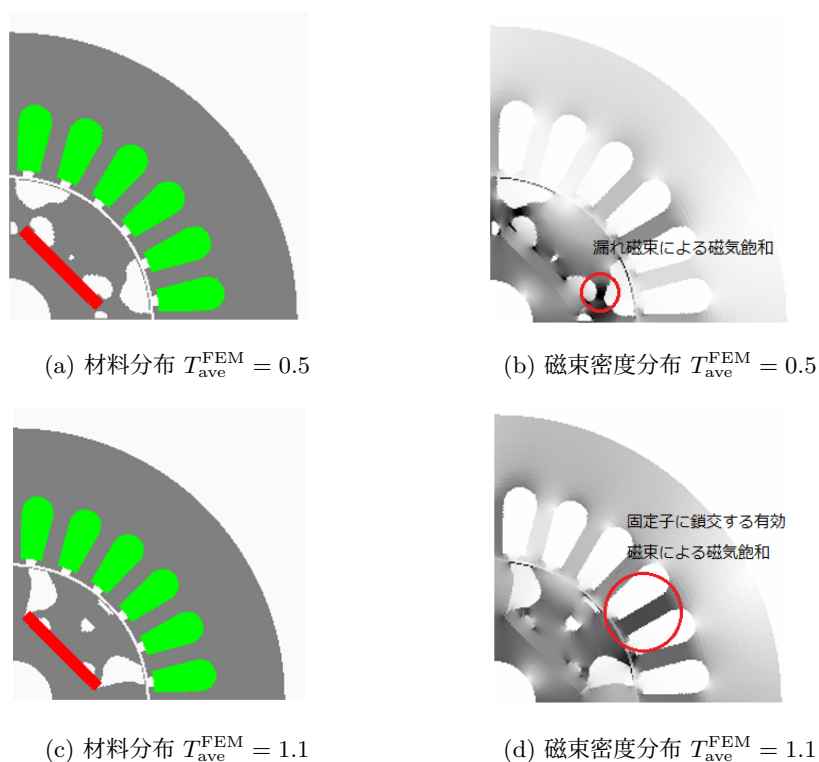


図 3.15: 異なる推定値における材料分布と磁束密度分布の比較

3.3.8 学習条件

データセットを用いて平均トルクおよびトルクリップルを推定する推定器を作成する。表 3.5 に分類問題および回帰問題の学習条件を示す。本検討ではそれぞれ 100epoch 学習を行う。学習には分類問題および回帰問題それぞれ Momentum SGD および RMSprop を用いる。また、損失関数として分類問題では式 3.13 に示す交差エントロピー誤差、回帰問題では式 3.13 に示す二乗和誤差を用いる。本検討で用いる材料分布および磁束密度分布による教師データおよびテストデータは同一の個体群を用いている。また、本検討では損失関数の感度を高くするため、学習の際に特性値を 100 倍した値を学習させている。

表 3.5: 分類問題および回帰問題における学習条件

	Classification	Regression
Epoch	100	100
Bach size	40	40
Optimizer	Momentum SGD	RMSprop
Learning rate	0.0001	0.001

3.3.9 分類問題における推定結果

表 3.6-表 3.9 に分類問題に対するテストデータによる推定結果を示す。それぞれの (a)(b) は材料分布および磁束密度分布を用いた結果である。表 3.6-表 3.9 における横軸は CNN による推定分類ラベルを示し、縦軸は FEM による解析値を用いた分類ラベルを示す。対角線上のブロックに当てはまる個体は CNN により正確に推定されていることを示す。分類問題の場合、正確に分類された個体割合 κ により推定器の精度を評価する。

平均トルクに関して I 字磁石配置の場合、材料分布および磁束密度分布を用いると $\kappa = 56.8\%$, $\kappa = 64.5\%$, V 字磁石配置の場合、 $\kappa = 56.8\%$, $\kappa = 70.5\%$ となり、それぞれ磁束密度分布を用いたほうが 7.7%, 13.7% 精度が高くなっている。一方、トルクリップルに関しては I 字磁石配置の場合、材料分布および磁束密度分布を用いると $\kappa = 43.4\%$, $\kappa = 44.1\%$, V 字磁石配置の場合、 $\kappa = 37.8\%$, $\kappa = 36.4\%$ と平均トルクに比べ精度が低く、磁束密度分布による精度は向上していない。

3.3.10 回帰問題における推定結果

図 3.16-図 3.19 に回帰問題に対するテストデータによる推定結果を示す。それぞれ異なる乱数シードによりトポロジー最適化を行い、生成したデータセットを用いている。それぞれの (a)(b) は材料分布および磁束密度分布を用いた結果である。図 3.16-図 3.19 における横軸は FEM による解析値を示し、縦軸は CNN による推定値を示している。回帰問題の場合、FEM 相関係数 ρ および FEM による評価値との誤差率 *Error* を用いて精度を評価する。相関係数 ρ は以下のように定義される。

$$\rho = \frac{\sigma_{FEM,CNN}}{\sigma_{FEM}\sigma_{CNN}} \quad (3.26)$$

ここで、 $\sigma_{FEM,CNN}, \sigma_{FEM}, \sigma_{CNN}$ はそれぞれ FEM による解と CNN による解の共分散およびそれぞれの標準偏差を示す。また、誤差率 *Error* は以下のように定義される [84]。

$$Error = \sqrt{\frac{(e_{FEM} - e_{CNN})^2}{e_{FEM}^2}} \quad (3.27)$$

ここで、 e_{FEM}, e_{CNN} はそれぞれ FEM および CNN の解である。相関係数はばらつきの影響を受けにくく、誤差率はばらつきの影響を受けやすいため、それぞれの指標を併用して評価を行う。

平均トルクに関して I 字磁石配置の場合、材料分布および磁束密度分布を用いると $\rho = 0.994, 0.997$, V 字磁石配置の場合、 $\rho = 0.991, 0.994$ となり、磁束密度分布を用いることで相関係数がそれぞれ 0.003 程度向上している。また、誤差率はそれぞれ 1.14%, 1.06% 向上している。また、トルクリップルに関しても I 字磁石配置の場合、材料分布および磁束密度分布を用いると $\rho = 0.641, 0.0.758$, V 字磁石配置の場合、 $\rho = 0.226, 0.284$ となり、磁束密度分布を用いることで相関係数がそれぞれ 0.117, 0.058 向上している。誤差率はそれぞれ 1.47%, 2.98% 向上している。しかし、トルクリップルの相関係数は平均トルクに対して大幅に悪化している。特に、V 字磁石配置のトルクリップルを推定した推定器の場合、 $\rho = 0.25$ 付近と非常に相関係数が悪化しており、正しく推定できていない。V 字磁石配置は特にトルクリップルと形状との相関を得にくい形状であることがわかる。

表 3.6: I字磁石配置 IPM の平均トルク分類問題推定結果

(a) 材料分布 $\kappa = 56.8\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	1	1	213	585	800
	1.1	0	0	0	0	1	49	162	478	110	800
	1.0	0	0	0	0	30	419	261	89	1	800
	0.9	0	0	6	7	334	426	25	2	0	800
	0.8	1	0	126	82	548	43	0	0	0	800
	0.7	3	14	569	81	133	0	0	0	0	800
	0.6	25	185	579	5	6	0	0	0	0	800
	0.5	233	390	177	0	0	0	0	0	0	800
	0.0	739	57	4	0	0	0	0	0	0	800
	TOTAL	1001	646	1461	175	1052	938	449	782	696	7200

(b) 磁束密度分布 $\kappa = 64.5\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	0	0	608	192	800
	1.1	0	0	0	0	0	0	50	736	14	800
	1.0	0	0	0	0	0	44	484	272	0	800
	0.9	0	0	0	0	15	589	193	3	0	800
	0.8	0	0	0	16	435	346	3	0	0	800
	0.7	0	0	25	396	374	5	0	0	0	800
	0.6	1	66	481	243	9	0	0	0	0	800
	0.5	65	594	137	4	0	0	0	0	0	800
	0.0	734	65	1	0	0	0	0	0	0	800
	TOTAL	800	725	644	659	833	984	730	1619	206	7200

表 3.7: I字磁石配置 IPM のトルクリップル分類問題推定結果

(a) 材料分布 $\kappa = 43.4\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	11	22	23	21	37	61	117	508	800
	1.1	0	11	20	16	29	56	132	291	245	800
	1.0	2	9	22	19	41	186	336	122	63	800
	0.9	0	20	46	39	176	326	127	29	37	800
	0.8	8	53	106	119	339	109	29	8	29	800
	0.7	13	113	210	229	163	44	9	5	14	800
	0.6	55	231	306	113	53	22	6	4	10	800
	0.5	152	296	262	50	25	9	1	0	5	800
	0.0	462	214	90	20	6	6	1	0	1	800
	TOTAL	230	744	994	608	847	789	701	576	911	7200

(b) 磁束密度分布 $\kappa = 44.1\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	1	12	15	10	22	46	27	228	439	800
	1.1	0	11	10	10	31	59	83	396	200	800
	1.0	2	14	17	13	37	183	295	176	63	800
	0.9	1	27	32	33	184	359	100	31	33	800
	0.8	5	65	60	157	320	143	12	16	22	800
	0.7	6	131	133	266	179	62	9	7	7	800
	0.6	37	258	236	152	64	36	2	8	7	800
	0.5	137	369	181	64	26	19	0	0	4	800
	0.0	459	237	69	17	6	10	1	1	0	800
	TOTAL	189	887	684	705	863	907	528	862	775	7200

表 3.8: V 字磁石配置 IPM の平均トルク分類問題推定結果

(a) 材料分布 $\kappa = 56.8\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	0	0	513	287	800
	1.1	0	0	0	0	0	1	33	701	65	800
	1.0	0	0	0	0	0	179	302	319	0	800
	0.9	0	0	0	3	17	693	76	11	0	800
	0.8	0	0	1	85	204	510	0	0	0	800
	0.7	0	2	29	548	162	59	0	0	0	800
	0.6	0	117	250	421	12	0	0	0	0	800
	0.5	8	545	177	70	0	0	0	0	0	800
	0.0	561	230	6	3	0	0	0	0	0	800
TOTAL		569	894	463	1130	395	1442	411	1544	352	7200

(b) 磁束密度分布 $\kappa = 70.5\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	0	0	276	524	800
	1.1	0	0	0	0	0	0	53	700	47	800
	1.0	0	0	0	0	0	47	500	252	1	800
	0.9	0	0	0	0	19	530	246	5	0	800
	0.8	0	0	0	34	454	305	7	0	0	800
	0.7	0	0	67	480	240	13	0	0	0	800
	0.6	0	66	583	146	5	0	0	0	0	800
	0.5	8	635	154	3	0	0	0	0	0	800
	0.0	669	131	0	0	0	0	0	0	0	800
TOTAL		677	832	804	663	718	895	806	1233	572	7200

表 3.9: V 字磁石配置 IPM のトルクリップル分類問題推定結果

(a) 材料分布 $\kappa = 37.8\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	2	7	19	57	36	17	15	296	351	800
	1.1	9	11	18	55	43	47	82	332	203	800
	1.0	5	10	28	66	76	179	179	170	87	800
	0.9	9	15	30	67	159	323	38	91	68	800
	0.8	9	32	61	147	301	126	7	59	58	800
	0.7	41	75	177	228	145	26	5	43	60	800
	0.6	52	112	379	138	45	8	2	31	33	800
	0.5	118	251	303	74	19	2	0	16	17	800
	0.0	61	63	35	12	2	1	0	3	0	177
TOTAL		245	513	1015	832	824	728	328	1038	877	6577

(b) 磁束密度分布 $\kappa = 36.4\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	15	21	11	79	7	31	48	293	295	800
	1.1	15	10	12	93	17	48	118	296	191	800
	1.0	23	16	5	81	27	127	279	170	72	800
	0.9	22	14	10	107	105	343	81	64	54	800
	0.8	57	26	21	196	246	144	17	47	46	800
	0.7	132	96	78	324	67	28	8	26	41	800
	0.6	191	168	211	169	9	15	3	11	23	800
	0.5	363	235	71	108	4	3	0	4	12	800
	0.0	130	29	5	10	1	0	0	1	1	177
TOTAL		818	586	419	1157	482	739	554	911	734	6577




図 3.16: I 字磁石配置 IPM の平均トルク回帰問題推定結果 [29]©2021 IEEE






図 3.17: I 字磁石配置 IPM のトルクリップル回帰問題推定結果 [29]©2021 IEEE




(a) 材料分布 $\rho = 0.991$, $Error = 4.50\%$




(b) 磁束密度分布 $\rho = 0.994$, $Error = 3.44\%$

図 3.18: V 字磁石配置 IPM の平均トルク回帰問題推定結果 [29]©2021 IEEE



(a) 材料分布 $\rho = 0.226$, $Error = 25.19\%$



(b) 磁束密度分布 $\rho = 0.284$, $Error = 22.22\%$

図 3.19: V 字磁石配置 IPM のトルクリップル回帰問題推定結果

図3.20に学習時における回帰問題の損失関数の値の推移を示す。図3.20(a)(b)はそれぞれ平均トルクおよびトルクリップルの推定器の epoch ごとの損失関数推移である。I字磁石配置およびV字磁石配置共に100epoch 学習した時点における損失関数値は材料分布を用いた場合よりも磁束密度分布を用いた場合のほうが小さい。回帰問題の場合ほどどちらの磁石配置においても磁束密度分布を用いたほうが精度良く学習できている。

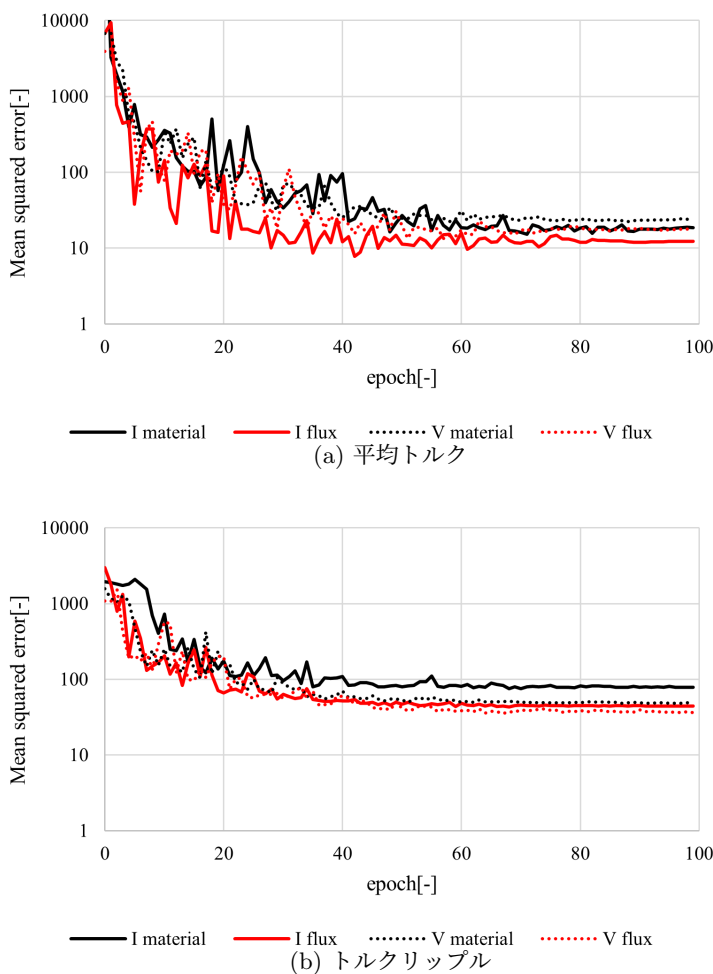


図 3.20: 回帰問題における推定器の損失関数推移

3.3.11 異なるデータセットによる回帰問題推定結果

結果の妥当性を検討するため、異なるデータセットによる学習および推定を行った。本検討では異なる4種の乱数シードで実行した多目的最適化により得られた教師データおよびテストデータにより検証する。表3.10、表3.11にI字磁石配置およびV字磁石配置の平均トルクおよびトルクリップル推定結果のFEM解析値およびCNN推定値の相関係数および誤差率を示す。SEED4の結果は図3.16-3.19と対応している。

磁束密度を用いた場合、I字磁石配置およびV字磁石配置それぞれ材料分布に比べ平均

トルク誤差率が改善されている。I字磁石配置のSEED3に関しては微小に悪化しているが、それ以外、相関係数に関してもほとんど改善されている。データセットの質に依存するが、ほとんどの場合磁束密度により推定精度が向上していることが確認できる。一方、トルクリップルの場合、相関係数および誤差率が平均トルクに比べ悪化しており、磁束密度による精度向上効果が薄れている。

3.3.12 トルクリップル発生原理

分類問題および回帰問題においてトルクリップルの推定精度が平均トルク推定精度に比べ悪化する傾向があることを示した。本要因を考察するため、トルクリップルの発生原理を述べる [85]。

回転子起因のトルクリップル発生要因として回転子起磁力高調波が挙げられる。2.5.9節で述べたように本研究では三相正弦波電流を想定している。U相を基準点としたとき、正弦波三相電流は以下の式で表される。

$$\begin{aligned} I_u &= I_{amp} \sin \omega t \\ I_v &= I_{amp} \sin \left(\omega t - \frac{2}{3}\pi \right) \\ I_w &= I_{amp} \sin \left(\omega t - \frac{4}{3}\pi \right) \end{aligned} \quad (3.28)$$

ここで I_{amp} は電流振幅を示す。また、三相電機子巻線に鎖交するそれぞれの磁束 ϕ_u, ϕ_v, ϕ_w はそれぞれ以下のように表される。

$$\begin{aligned} \phi_u &= \sum_{k=1}^{\infty} \phi_k \cos \{k(\omega t - \theta)\} \\ \phi_v &= \sum_{k=1}^{\infty} \phi_k \cos \left\{ k \left(\omega t - \frac{2}{3}\pi - \theta \right) \right\} \\ \phi_w &= \sum_{k=1}^{\infty} \phi_k \cos \left\{ k \left(\omega t - \frac{4}{3}\pi - \theta \right) \right\} \end{aligned} \quad (3.29)$$

ここで ϕ_k は k 次の磁束振幅を示す。これらを用いて発生するトルク T は以下のように表すことができる。

$$T = K(\phi_u I_u + \phi_v I_v + \phi_w I_w) \quad (3.30)$$

ここで、 K は定数である。それぞれの電流および磁束を式 3.30 に代入すると、

$$\begin{aligned} T &= K I_{amp} \sum_{k=1}^{\infty} \phi_k \cos \{k(\omega t - \theta)\} \sin \omega t \\ &+ \sum_{k=1}^{\infty} \phi_k \cos \left\{ k \left(\omega t - \frac{2}{3}\pi - \theta \right) \right\} \sin \left(\omega t - \frac{2}{3}\pi \right) \\ &+ \sum_{k=1}^{\infty} \phi_k \cos \left\{ k \left(\omega t - \frac{4}{3}\pi - \theta \right) \right\} \sin \left(\omega t - \frac{4}{3}\pi \right) \end{aligned} \quad (3.31)$$

表 3.10: I字磁石配置 IPM の平均トルクおよびトルクリップルの回帰問題推定結果の相関係数および誤差率

	Average torque			Torque ripple		
	Error			Error		
	材料	磁束密度	磁束-材料	材料	磁束密度	磁束-材料
SEED1	1.73	1.40	-0.33	19.01	17.87	-1.14
SEED2	3.16	2.83	-0.33	41.45	38.06	-3.39
SEED3	5.24	4.96	-0.28	19.55	16.12	-3.43
SEED4	4.50	3.44	-1.06	25.19	22.22	-2.98
	相関係数			相関係数		
	材料	磁束密度	磁束-材料	材料	磁束密度	磁束-材料
	SEED1	0.994	0.996	0.002	0.353	0.517
SEED2	0.981	0.987	0.006	0.590	0.216	-0.374
SEED3	0.991	0.988	-0.003	0.430	0.217	-0.213
SEED4	0.975	0.992	0.017	0.226	0.284	0.057

表 3.11: V字磁石配置 IPM の平均トルクおよびトルクリップルの回帰問題推定結果の相関係数および誤差率

	Average torque			Torque ripple		
	Error			Error		
	材料	磁束密度	磁束-材料	材料	磁束密度	磁束-材料
SEED1	2.743	1.893	-0.851	15.263	14.322	-0.941
SEED2	1.616	1.119	-0.497	27.442	30.952	3.510
SEED3	2.914	2.787	-0.127	14.674	16.053	1.379
SEED4	2.481	1.344	-1.137	9.587	8.118	-1.468
	相関係数			相関係数		
	材料	磁束密度	磁束-材料	材料	磁束密度	磁束-材料
	SEED1	0.987	0.997	0.010	0.706	0.637
SEED2	0.988	0.998	0.010	0.326	0.640	0.313
SEED3	0.991	0.996	0.005	0.735	0.689	-0.046
SEED4	0.989	0.998	0.009	0.641	0.758	0.116

式 3.31 を整理すると,

$$\begin{aligned}
 T = \frac{KI_{amp}}{2} & \left(\sum_{k=1}^{\infty} (\phi_k(\sin(k+1)\omega t - k\theta) - (\sin(k-1)\omega t - k\theta)) \right. \\
 & + \sum_{k=1}^{\infty} (\phi_k(\sin(k+1)\omega t - k\theta - \frac{2}{3}(k+1)\pi) - (\sin(k-1)\omega t - k\theta - \frac{2}{3}(k-1)\pi)) \\
 & \left. + \sum_{k=1}^{\infty} (\phi_k(\sin(k+1)\omega t - k\theta - \frac{4}{3}(k+1)\pi) - (\sin(k-1)\omega t - k\theta - \frac{4}{3}(k-1)\pi)) \right)
 \end{aligned} \tag{3.32}$$

鎖交磁束の偶数次成分は 0 となる．よって以下のようにまとめることができる [85].

$$T = \frac{3KI_{amp}}{2} \left\{ \left(\sum_{k=5,11,17,\dots}^{\infty} \phi_k \sin(k+1)\omega t - k\theta \right) - \left(\sum_{k=1,7,13,\dots}^{\infty} \phi_k \sin(k-1)\omega t - k\theta \right) \right\} \tag{3.33}$$

以上のことから、鎖交磁束の高次成分によってトルクリップルの 6 次の倍数成分が発生する．

回転子起磁力高調波起因のトルクリップルを低減するためには鎖交磁束高次成分を低減させる必要がある．例えばトルクリップル 6 次成分を低減させるためには鎖交磁束の 5 次, 7 次成分を低減させる必要がある．今回対象とする電気学会 D モデルは 2.5.11 節に述べたようにトルクリップル 12 次成分が支配的であることから、鎖交磁束 11 次成分および 13 次成分を低減させればよい．

これらの次数成分は必ずしも独立的な関係ではないことから、鎖交磁束の次数成分を低減させるコア形状は多様な解が考えられる．そのため、一意な解が存在するとは限らない．このように、トルクリップルの発生要因は平均トルクに比べ複雑であり、トルクリップルを推定する問題は平均トルク推定問題に比べ難しいと考えられる．

3.3.13 トルク振幅の推定

トルクリップルの推定精度は平均トルクに比べ悪化することを示した．本問題におけるトルクリップルは式 3.34 で定義される．

$$T_{rip} = \frac{T_{max} - T_{min}}{T_{ave}} \tag{3.34}$$

この定義によるトルクリップルは無次元の値となっている．その結果、前節に述べたようにモータ構造と推定値の相関が弱い上に、問題は複雑化すると考えられる．そこで、式 3.35 のように定義したトルク振幅 T_{pp} を学習することを考える．

$$T_{pp} = T_{max} - T_{min} \tag{3.35}$$

トルク振幅 T_{pp} は単位が Nm であり、形状とほぼ一意に決定すると考えられる．

図 3.21 および図 3.22 に振幅の推定器におけるテスト結果を示す。I 字磁石配置の場合、トルクリップルを学習した場合に比べ振幅の推定相関係数は 0.01 程度低い。一方、V 字配置を学習した場合、相関係数は 0.6 程度大幅に向上している。

図 3.23 に学習に使用した教師データの平均トルクとトルクリップルおよび平均トルクと振幅の相関関係を示す。平均トルクとトルクリップルの相関係数は 0.065 と全く相関がないことがわかる。一方、平均トルクと振幅の相関係数は 0.648 であり、ある程度相関がみられる。図 3.16 および図 3.18 より平均トルクは材料分布および磁束密度に関し、良好な相関を得ている。したがって、振幅に対しても材料分布および磁束密度に対する相関は良好であると想定できる。

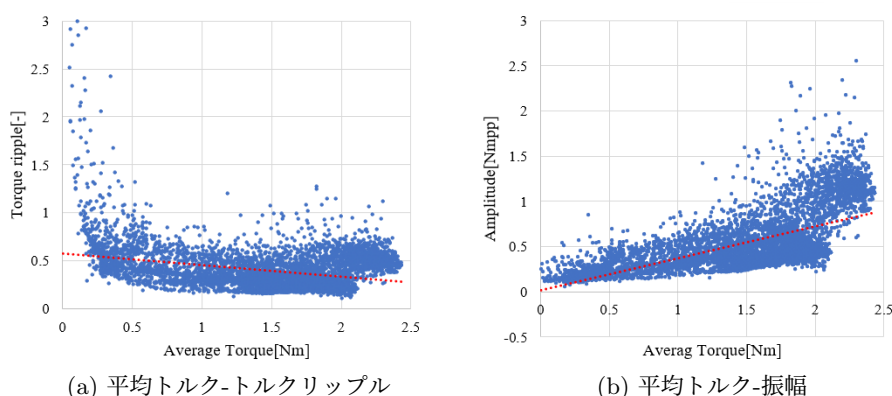



図 3.23: 平均トルクとトルクリップルおよび振幅の関係

3.3.14 磁束密度分布による推定精度の検証


3.3.8 節より分類問題のトルクリップル推定問題以外において磁束密度分布が推定精度向上に影響することを確認した。本効果の要因として、以下の理由が考えられる。

- 非線形特性の効果
- 固定子コアの情報量増加

推定精度向上の一つの要因は磁束密度分布を用いることによるコア磁気的非線形性の考慮である。一方、磁束密度分布による固定子側の情報量の増加による効果もあると考えられる。材料分布の場合、固定子コアはすべてのデータが同一形状であるため、特性値推定には回転子コアの材料分布のみが特徴量となる。しかし、磁束密度分布を用いることで固定子側も推定特性に影響を及ぼす情報を表現可能となり、推定精度が向上したと考えられる。




(a) 材料分布 $\rho = 0.983$, $Error = 8.32\%$




(b) 磁束密度分布 $\rho = 0.985$, $Error = 8.07\%$

図 3.21: I 字磁石配置 IPM の振幅回帰問題推定結果 [29]©2021 IEEE



(a) 材料分布 $\rho = 0.865$, $Error = 15.7\%$



(b) 磁束密度分布 $\rho = 0.900$, $Error = 13.8\%$

図 3.22: V 字磁石配置 IPM の振幅回帰問題推定結果

3.3.15 回転子のみを学習した場合の効果

これらの要因を検証するため、教師データとして回転子のみを抜き出し、学習を行う。本結果と固定子を含めた教師データによる結果を比較することで、単純な磁束密度分布の効果を確認することができる。図 3.24 に回転子のみの入力データを示す。固定子の形状を入力画像から切り取り、回転子のみをビットマップで表現した。

回転子を入力データに対し平均トルクの回帰問題を推定させた結果を図 3.25 に示す。FEM の解析値と CNN の推定値の相関係数 ρ が材料分布にくらべ、磁束密度分布により 0.001 向上しているが、誤差率が 0.35% 悪化している。本結果により、回転子のみでは推定精度向上効果が薄いことが確認できる。さらに、固定子を同時に学習した図 3.16 の結果と比べて相関係数が材料分布および磁束密度分布それぞれ 0.011 および 0.013 減少している。したがって、固定子側の磁束密度分布による特徴量の増加が推定精度に影響しているといえる。




図 3.24: 回転子領域のみを表した入力ビットマップ





図 3.25: I 字磁石配置 IPM の回転子領域のみを用いた平均トルク回帰問題推定結果 [29]©2021 IEEE

3.4 磁気的非線形性を考慮した CNN を用いたトポロジー最適化

3.4.1 概要

3.3.8 節にて磁束密度分布を用いることで精度よくモータ磁気特性を推定可能であることを示した。本節では文献 [25][26] にて提案したトポロジー最適化アルゴリズムに前節で構築した CNN を用いる。文献 [25][26] で提案したアルゴリズム内では材料分布を教師データとした CNN の分類問題推定器を用いている。

本検討では教師データとして材料分布ではなく磁束密度分布を用いた CNN を用いた場合のトポロジー最適化探索性能を述べる。また、材料分布および磁束密度分布で学習された推定器の違いによるトポロジー最適化結果の違いについても述べる。

3.4.2 基本アルゴリズム

図 3.26 に最適化アルゴリズムを示す [25]。基本的なアルゴリズムは従来の GA と同様である。従来の GA と異なる点は個体の評価方法である。評価する際のアルゴリズムを以下に示す。

1. 個体生成
探索に用いる個体を生成する。
2. ビットマップ生成
最適化で生成された個体の材料分布および磁束密度分布をビットマップ出力する。磁束密度分布を出力する際、1 ステップのみ FEM による解析を行い、その結果を出力する。
3. CNN による特性推定
作成したビットマップを学習済み CNN に入力し、推定値を求める。
4. FEM 解析判断
CNN の推定値に応じて解析確率 s に応じて FEM 解析判断をする。FEM による解析を行う場合は FEM の解析結果を評価値として用いる。解析を行わない場合は CNN の推定値を用いる。

CNN の推定値が良好な個体に対して FEM による解析確率を高くすることで、最適化で最良解となり得る探索集団は FEM による精度の高い特性値を得ることができ、最適化の探索精度を保つことが可能となる。

3.4.3 最適化設定

本検討ではトルクリップル最大化、トルクリップル最小化問題を解いた。式 3.36 に目的関数 F を示す。

$$F = w_1 \times \frac{T_{ave}}{T_{ave}^0} - w_2 \times \frac{T_{rip}}{T_{rip}^0} \rightarrow \max. \text{ sub.to } \Omega < 2 \quad (3.36)$$

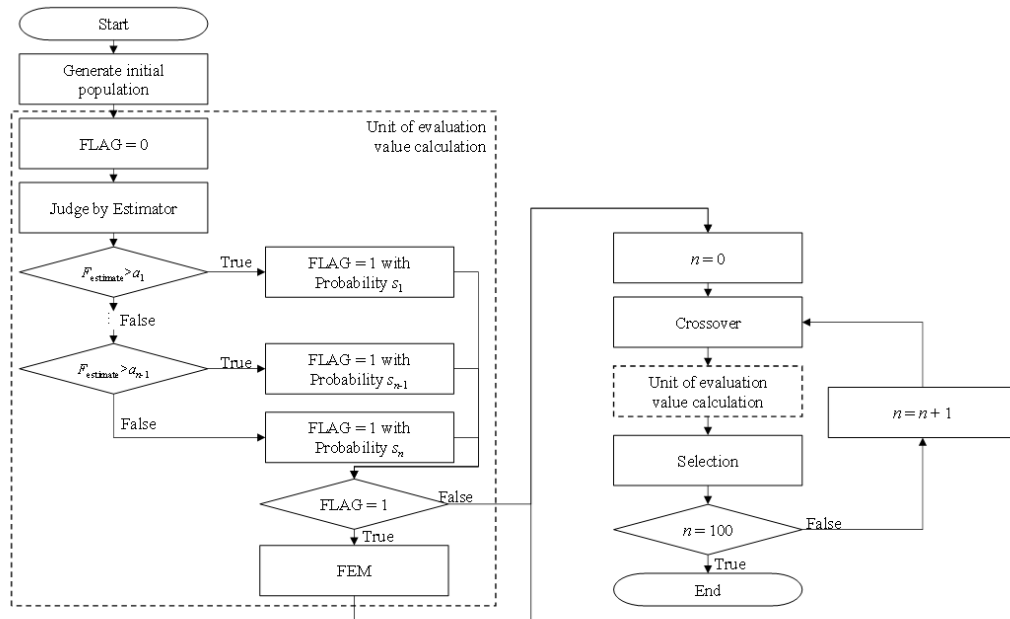


図 3.26: CNN を用いたトポロジー最適化アルゴリズム [29]©2021 IEEE

式 3.36 中の $w_1 = 1.3$ および $w_2 = 0.3$ は最適化における平均トルクおよびトルクリップルの影響度合いを調整する値である。 $F = 1.0$ の場合電気学会 D モデルと同様の評価値となる。また、表 3.13 に本検討で用いた解析確率を示す。本検討では二種類の解析確率を用いて最適化を行った。(a) の設定の場合、すべての個体を FEM により解析する。(b) の設定の場合、評価値 F によって解析確率を変更する。評価値 F が 1.0 以下の場合、FEM による解析を行わず、1.0 より高い場合、すべての個体の評価値を FEM により求める。本設定では FEM と CNN を併用することとなる。この解析確率の設定により、FEM の解析回数を減少させることができ、それに比例して最適化時間を減少させることができる。(c) の設定の場合、すべての個体の評価値を CNN による推定値で求める。最適化設定を表 3.12 に示す。本検討では、100 世代目の個体を最適解とした。

表 3.12: CNN を用いたトポロジー最適化における最適化設定

Number of dimensions	54
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REX ^{star}
Method of Generations	100

表 3.13: CNN を用いたトポロジー最適化における FEM の解析確率設定

F	(a)	(b)	(c)
0.0~1.0	100%	0%	0%
1.0~	100%	100%	0%

3.4.4 最適化結果

図 3.27 に最適化結果を示す。また、図 3.28 に評価値の推移を示す。材料分布および磁束密度分布を学習した CNN をそれぞれ用いた場合、条件 (a)、条件 (b)、条件 (c) の順で評価値が高い個体が得られている。さらに CNN を用いた最適化の場合、磁束密度分布を学習した CNN を用いた場合、評価値が高い最適解を得ている。例えば、設定 (b) および設定 (c) の場合、磁束密度分布を学習した CNN を用いることで材料分布を学習した CNN を用いた場合に比べ評価値が 0.03 および 0.01 良好な形状を得ている。

FEM の解析確率が高い (a) 条件が最も良好な解を得ることができている理由として、FEM により厳密解に近い値を評価値として用いているためと考えられる。FEM に比べ推定精度が劣る CNN は微小な形状の変動に対して鈍感である。したがって、CNN を用いた最適化においては探索点が複雑な探索空間内の局所解に陥った場合に脱出しにくいと考えられる。

図 3.29 に世代ごとの FEM による評価個体数の推移を示す。CNN を用いない設定 (a) はすべての世代で 200 個体 FEM による解析を行っているが、良好解以外に対して評価値を用いている設定 (b) においては大幅に解析回数が削減されている。設定 (a) の場合、100 世代で 20000 回 FEM による解析が必要である。一方、設定 (b) の場合、材料分布を学習した CNN および磁束密度分布を学習した CNN を用いることで 217 回および 1457 回まで削減できている。設定 (b) の場合、後半の世代になるにつれ FEM の解析回数が増加する。また、磁束密度分布を学習した CNN を用いることで FEM の解析回数が微増している。これらの理由として、探索後半の集団としての評価値平均が材料分布を学習した CNN を用いた場合に比べ良好であるためと考えられる。

3.4.5 最適解形状の考察

本最適化で得られた形状について考察する。最適解として得られた形状の特徴として、以下のような傾向がある。

- 永久磁石の端部にフラックスバリアが形成されている。
本フラックスバリアにより、d 軸インダクタンスが向上し、d 軸磁束が増加することからマグネットトルクを増加させる効果があると考えられる。
- 回転子外径側のコアは周方向に広がっており、扇形となっている。
回転子表面のコア領域が周方向に広がることで、トルクリップルを抑えるよう空隙磁束密度分布の高調波成分を抑える効果があると考えられる。

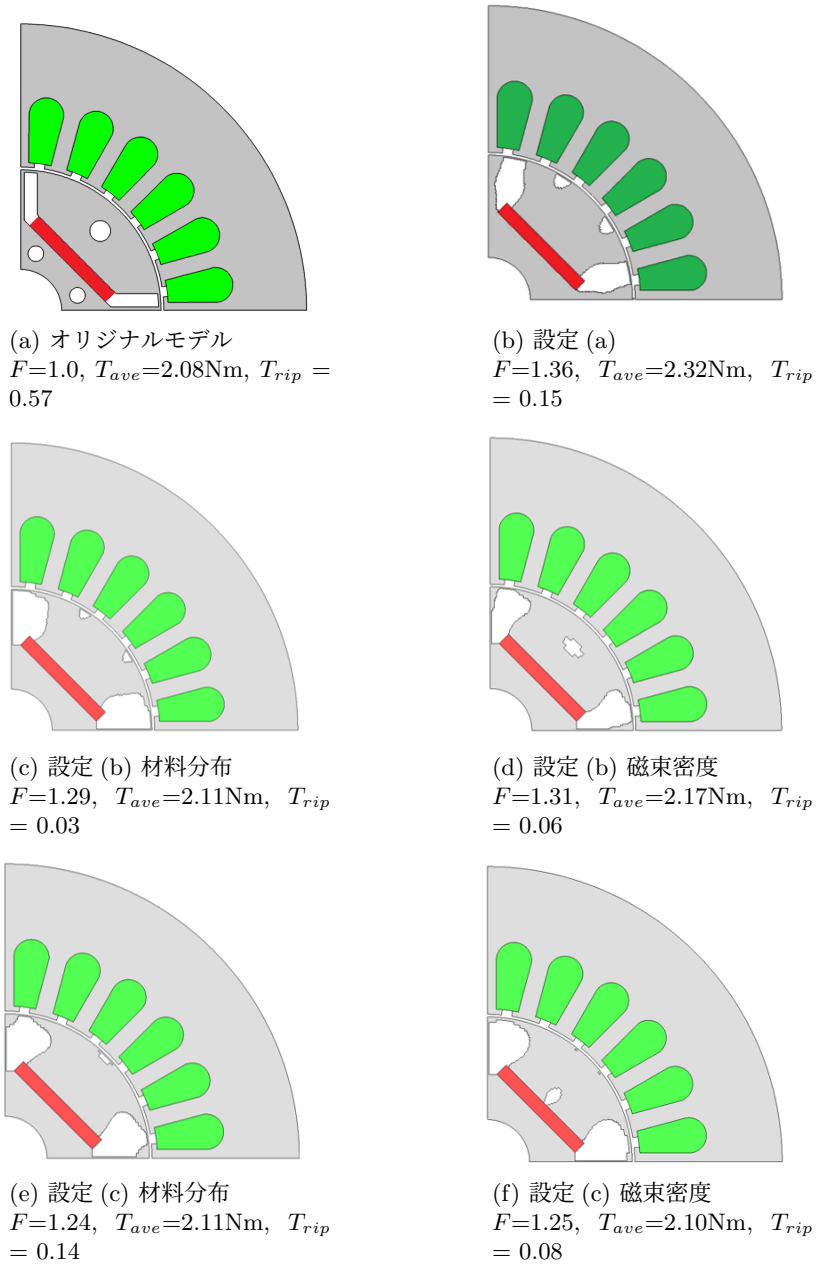


図 3.27: CNN を用いたトポロジー最適化における最適解 [29]©2021 IEEE




図 3.28: CNN を用いたトポロジー最適化における評価値の推移 [29]©2021 IEEE




図 3.29: CNN を用いたトポロジー最適化における FEM 評価個体数の推移 [29]©2021 IEEE

- 回転子外径側に小さな空気領域が形成されている。

文献 [86] でも示されているように、回転子表面に空隙を設けることで回転子起磁力の高調波成分を低減させ、トルクリップルを抑えることが可能である。

これらの最適解は上記の要素の組み合わせによって平均トルク向上およびトルクリップル抑制を達成している。

3.4.6 CNN の教師データ種類の違いによる最適解への影響

図 3.30 に材料分布および磁束密度分布を用いて学習した推定器の平均トルク推定値の例を示す。どちらも同様のモータ形状を示している。FEM の結果から算出した平均トルクは $T_{ave}^{FEM} = 1.40\text{Nm}$ である。材料密度分布を用いて学習した推定器の平均トルク推定値 $T_{ave}^{CNN} = 1.06\text{Nm}$ である。一方、材料密度分布を用いて学習した推定器の平均トルク推定値 $T_{ave}^{CNN} = 1.41\text{Nm}$ であり、精度良く推定できている。

このように磁束密度分布を学習した CNN により、推定値の精度が向上し、形状に対する推定値の感度が高く、局所解に陥った場合にも大域的最適解探索を継続できるものと思われる。以上のことから、精度の良い CNN を用いることにより、より良好な解が得られやすいと考えられる。

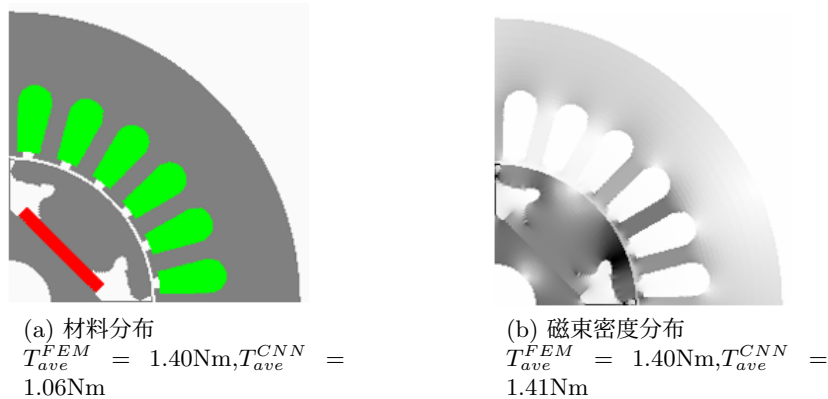


図 3.30: 材料分布および磁束密度分布を用いた CNN の平均トルクの推定例

3.4.7 最適化時間

図 3.31 に各設定における最適化時間を示す。図 3.31 の最適化時間は表 2.6 に示す計算機環境により最適化した結果である。本最適化は FEM による解析および画像生成の際に 10 コア並列処理を行っている。最適化時間算出の際は 10 個体並列時の磁束密度解析ありの場合、なしの場合における FEM のみの計算時間および CNN の推定時間、画像生成時間を求め、FEM 解析個体数をもとに解析時間を算出した。

FEM のみによる最適化は 15 時間 20 分となっている。一方、設定 (b) において材料分布および磁束密度分布を学習した CNN を用いた場合、それぞれ 4 時間 50 分 7 秒、7 時間

23分45秒と最適化時間が68.5%，51.8%低減している。また，設定(c)においてもそれぞれ4時間1分40秒，7時間16分40秒と最適化時間が73.7%，52.5%低減している。CNNの学習時間は約40分程度であり，学習時間を考慮しても最適化時間はCNNを用いたほうが短いことが確認できる。

磁束密度を用いた場合，材料分布を用いた場合に比べ最適化時間が増加している理由として，磁束密度分布を作成するための1step解析時間と探索精度向上によるFEM解析個体数の増加があげられる。よって，最適化に用いるCNNを学習する際に磁束密度を用いるか材料分布を用いるかの選択は探索精度と最適化時間の兼ね合いで決定するべきと考えられる。




図 3.31: CNN を用いたトポロジー最適化の最適化時間 [29]©2021 IEEE

3.5 総括

本章ではモータの特性を推定するCNNの推定精度に関する検討を行った。教師データとしてモータ断面材料分布および磁束密度分布を用いた場合のCNNの平均トルクおよびトルクリップル推定精度に関して検証した。また，作成したCNNを用いて回転子コア形状のトポロジー最適化を行い，探索性能の違いについて述べた。本検討で得た知見を以下に示す。

- 教師データとして磁束密度分布を用いることで，コアの磁気非線形性をCNNへ学習し，平均トルクおよびトルク振幅に関して材料分布を用いる場合に比べ推定精度が向上する。
- 推定精度の向上には固定子情報の増加も影響している。
- トポロジー最適化に適用した結果，教師データとして磁束密度分布を用いることでより良好な最適解を得ることができる。

第4章 CNNによる推定可能形状汎化手法の提案

4.1 はじめに

本章ではCNNの形状汎化手法に関する検討を行う。第3章にて回転機の推定精度を向上させる手法について述べた。さらに、トポロジー最適化内でCNNを用いる場合、その最適化精度はCNNの推定精度に依存することを述べた。本手法はあらかじめFEMのみを用いたトポロジー最適化を用いて教師データを作成する。作成した教師データを用いてCNNを学習する。そのうち、同様のモデルに対して異なる目的関数に関する最適化を行う場合、学習済CNNを用いてFEMによる評価回数を削減しつつ高速に最適解を得ることが可能である。第3章において、一磁石配置に対する回転子コア形状を入力として平均トルクおよびトルクリップルの推定を行うCNN推定器を作成した。本推定器は単一磁石配置に対する回転子コア形状最適化に大いに有効である。

一方で、近年では永久磁石同期モータは磁石飛散防止や、リラクタンストルクの活用の観点から埋込型を用いる場合が多く、コア形状や永久磁石の設計自由度が飛躍的に増大している。永久磁石同期モータは回転子起磁力を永久磁石磁束により得るため、永久磁石の配置によってもトルク特性は大きく変化する。そのため、特に永久磁石の配置とコア形状を考慮したマルチマテリアルトポロジー最適化が今後必要になると考えられる。このような複数磁石配置に対応するトポロジー最適化にCNNを用いる場合、永久磁石の形状変化に対応したCNNを学習させる必要がある。大きく磁気特性が異なるモータ形状に対して一つのCNNが対応可能か論じた文献は少ない。

そこで、本章では一つのCNNが多数の磁石配置に対応可能とする汎化手法に関し検証を行う[30]。磁石配置に対しても汎化可能となればマルチマテリアルトポロジー最適化へのCNN適用も可能となる。本検討ではI字磁石配置およびV字磁石配置を一つのCNNで学習し、平均トルクを推定させる。さらに、二つの磁石配置に対し汎化させたCNNを用いて二磁石配置の回転子を同時にトポロジー最適化する手法を提案する[30]。本手法により、磁石配置が複数に限定された場合、複数の磁石配置を考慮した探索を行うことが可能である。

本章の構成を述べる。まず、4.2節では本章で検証した汎化手法に関して述べる。4.3節では学習対象及び学習ネットワークに関して述べる。4.4節では学習結果に関して述べる。4.5節において形状汎化したCNNを用いたトポロジー最適化の結果について述べる。最後に4.6節にて総括を述べる。

4.2 汎化方法

図 4.1 に汎化手法の概要を示す。多数の磁石配置に対して CNN 推定を行う手段として、それぞれの磁石配置に対する CNN を複数個生成し、それらの CNN を組み合わせて使用することが考えられる。単一磁石配置に対する CNN を用いて磁石配置に対して汎化を行う場合、考慮する磁石配置の種類分だけ CNN を構築する必要がある。図中の単一学習はそれぞれの磁石配置ごとに CNN を構築する従来の手法である。一磁石形状のみに対応する CNN を用いたとすると、磁石形状を自由に変更させるマルチマテリアル最適化では対応する CNN の選択を行う必要があるため、扱いが難しいと考えられる。

この点を解決する手段として、一つの CNN に複数の磁石配置を学習させる手法が考えられる。学習する手法として、複数の磁石配置を学習データに混合させ、1回の学習で複数の磁石配置を学習させる手法が考えられる。本学習手法を同時学習と呼ぶ。ただ、最適化において随時新しい磁石配置やコア形状が形成されることから、学習済み教師データから逸脱した形状を同一 CNN に追加で学習できることが望ましい。この手法を追加学習と呼ぶ。追加学習および同時学習により異なる磁石配置に対する学習を一つの推定器で行うことで、推定器の選択を行う必要がなく扱いを簡単化することが可能である。

以上の観点から、追加学習および同時学習により、異なる磁石配置を持つ IPM モータの材料分布と平均トルクの関係性を CNN に学習可能であるか検証を行う。

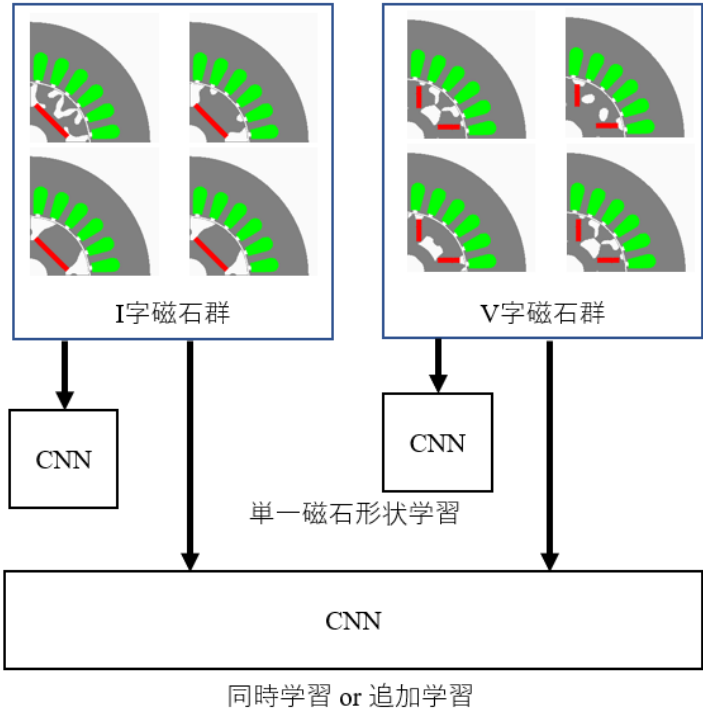


図 4.1: CNN の形状汎化手法の例

4.3 学習条件

4.3.1 概要

4.2節で述べた手法について、IPM モータに適用する。本節ではCNNの学習条件について述べる。

4.3.2 学習ネットワーク

次に本検討で用いた学習の手法について述べる [30]。本検討ではCNNの構成として図3.11に示すVGG16を用いる。図3.12(a)に示す $224 \times 224 \times 3$ の材料分布を入力する。出力として表3.2に示す平均トルクのラベルに分類する分類問題を用いて検討する。ラベルは9分類とし、最終層の大きさを9とする。学習手法として式3.16および式3.17に示すMomentum SGDを用い、式内のそれぞれの係数は $\alpha = 0.9, \eta = 10^{-4}$ とする。また、損失関数として式3.13に示す交差エントロピー関数を用いている。過学習を防ぐため2epoch連続で損失関数の値が悪化した場合、学習を打ち切る。

4.3.3 学習対象

本検討では図3.8に示したI字磁石配置およびV字磁石配置を有するモータ断面形状に適用する。表4.1に学習条件を示す。I字配置、V字配置それぞれのラベルで800個体を用いる。追加学習ではそれぞれの磁石配置に関して7200個体を用意し、それぞれの磁石配置ごとに学習する。同時学習ではそれぞれのラベルでI字配置、V字配置800個体、計14400個体を用意する。教師データ作成の際は表4.2に示す条件で平均トルク最大化問題を解いた。本節において学習精度は全個体における分類誤差 ± 1 分類以内に分類された個体割合 $\kappa_{\pm 1}$ で評価した。

表 4.1: 汎化学習条件

Epoch	100
Bach size	40
Optimizer	Momentum SGD
Learning rate	0.0001
α	0.9

表 4.2: 教師データ生成時の単目的最適化の最適化設定

Number of dimensions	54
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REX ^{star}
Method of Generations	100

4.4 学習結果

4.4.1 単一学習

まず、単一学習における学習結果を示す。表 4.3 および表 4.4 に学習データと別のテストデータで推定した結果を示す。学習データとテストデータが同一の磁石配置の場合、I 字磁石配置、V 字磁石配置の場合それぞれ $\kappa_{\pm 1} = 96.47\%$, $\kappa_{\pm 1} = 96.64\%$ とそれぞれ良好な精度で推定されている [30]。しかし、異なる磁石配置に対する推定精度は I 字磁石配置推定器の場合 $\kappa_{\pm 1} = 30.48\%$ 、V 字磁石配置の場合 $\kappa_{\pm 1} = 38.89\%$ と正しく推定できていない。異なる磁石配置の場合、その特性が著しく異なるため、教師データで補間できないものと考えられる。これらの結果から、磁石配置が変動する場合、推定データ内の磁石配置を補間するデータを用いて学習が必要であることわかる。

4.4.2 追加学習

$\alpha = 0.9$ の場合における学習結果

同一の CNN に対して一段階目に I 字磁石配置を学習し、二段階目に V 字磁石配置を学習する場合および一段階目に V 字磁石配置を学習し、二段階目に I 字磁石配置を学習する場合を考える。二段階目の学習の際には CNN の重みを予め一段階目で得られた重みにセットし、その重みを初期状態とする。それぞれの学習段階では表 4.1 に示した学習条件を用いる。

追加学習を行った CNN を用いて推定テストを行った結果を表 4.5 および表 4.6 に示す。第二段階で学習した磁石配置に対しては I 字磁石配置、V 字磁石配置それぞれ $\kappa_{\pm 1} = 97.76\%$, $\kappa_{\pm 1} = 94.12\%$ と良好な推定精度を示しているが、第一段階で学習を行った磁石配置に対する推定精度は I 字磁石配置推定器の場合 $\kappa_{\pm 1} = 48.38\%$ 、V 字磁石配置の場合 $\kappa_{\pm 1} = 49.92\%$ と単一学習の場合に比べ向上しているものの、低い推定精度である。第二段階の学習の際に第一段階で学習した重みへ上書きしているため、第一段階で学習した磁石配置に対する重みの効果が薄れていることが要因と考えられる。

表 4.3: 単一学習における I 字磁石配置学習推定器のテスト結果

(a) I 字テストデータ $\kappa_{\pm 1} = 96.47\%$ [30]

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	1	6	78	715	800
	1.1	0	0	0	0	0	46	48	358	348	800
	1.0	0	0	0	0	10	419	145	164	62	800
	0.9	0	0	0	25	280	472	11	5	7	800
	0.8	0	5	15	304	408	65	0	0	3	800
	0.7	1	60	163	508	63	4	0	0	1	800
	0.6	2	386	289	121	2	0	0	0	0	800
	0.5	47	690	57	6	0	0	0	0	0	800
	0.0	627	172	1	0	0	0	0	0	0	800
	TOTAL	677	1313	525	964	763	1007	210	605	1136	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 30.48\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	3	699	94	4	0	0	0	0	800
	1.1	0	17	651	125	7	0	0	0	0	800
	1.0	1	79	587	116	17	0	0	0	0	800
	0.9	5	145	478	138	33	1	0	0	0	800
	0.8	24	217	415	105	38	1	0	0	0	800
	0.7	42	242	341	117	58	0	0	0	0	800
	0.6	67	225	312	117	77	2	0	0	0	800
	0.5	96	203	280	116	99	6	0	0	0	800
	0.0	156	111	321	93	108	9	0	0	2	800
	TOTAL	391	1242	4084	1021	441	19	0	0	2	7200

表 4.4: 単一学習における V 字磁石配置学習推定器のテスト結果

(a) I 字テストデータ $\kappa_{\pm 1} = 38.89\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	6	45	749	0	0	0	0	800
	1.1	0	0	31	105	664	0	0	0	0	800
	1.0	0	0	74	195	529	2	0	0	0	800
	0.9	0	15	156	224	397	8	0	0	0	800
	0.8	0	78	174	219	325	4	0	0	0	800
	0.7	3	115	216	193	266	7	0	0	0	800
	0.6	8	183	162	172	261	14	0	0	0	800
	0.5	20	216	147	146	259	12	0	0	0	800
	0.0	89	181	63	196	251	20	0	0	0	800
	TOTAL	120	788	1029	1495	3701	67	0	0	0	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 96.64\%$ [30]

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	0	0	440	360	800
	1.1	0	0	0	0	0	6	44	556	194	800
	1.0	0	0	0	0	4	153	289	347	7	800
	0.9	0	0	0	1	106	485	185	23	0	800
	0.8	0	0	12	34	447	294	13	0	0	800
	0.7	0	11	163	180	425	21	0	0	0	800
	0.6	7	149	431	117	96	0	0	0	0	800
	0.5	135	405	231	25	4	0	0	0	0	800
	0.0	697	91	11	1	0	0	0	0	0	800
	TOTAL	839	656	848	358	1082	959	531	1366	561	7200

4.4. 学習結果

表 4.5: 追加学習における V 字 → I 字学習推定器 $\alpha=0.9$ のテスト結果 [30]

(a) I 字テストデータ $\kappa_{\pm 1} = 97.76\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	0	8	234	558	800
	1.1	0	0	0	0	0	26	60	535	179	800
	1.0	0	0	0	0	18	344	258	169	11	800
	0.9	0	0	0	17	365	396	21	0	1	800
	0.8	0	1	48	234	492	25	0	0	0	800
	0.7	0	21	384	322	71	2	0	0	0	800
	0.6	6	261	506	25	2	0	0	0	0	800
	0.5	140	574	86	0	0	0	0	0	0	800
	0.0	723	76	1	0	0	0	0	0	0	800
	TOTAL	869	933	1025	598	948	793	347	938	749	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 48.38\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	43	449	80	77	151	800
	1.1	0	0	0	15	215	438	48	39	45	800
	1.0	0	5	27	209	379	175	4	1	0	800
	0.9	0	85	209	294	166	46	0	0	0	800
	0.8	22	327	235	174	42	0	0	0	0	800
	0.7	154	419	157	68	2	0	0	0	0	800
	0.6	327	375	88	9	1	0	0	0	0	800
	0.5	502	272	25	1	0	0	0	0	0	800
	0.0	753	47	0	0	0	0	0	0	0	800
	TOTAL	1758	1530	741	770	848	1108	132	117	196	7200

表 4.6: 追加学習における I 字 → V 字学習推定器 $\alpha=0.9$ のテスト結果

(a) I 字テストデータ $\kappa_{\pm 1} = 49.92\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	372	86	2	6	0	0	334	800
	1.1	0	0	443	251	8	32	0	0	66	800
	1.0	0	0	276	426	35	59	0	0	4	800
	0.9	0	0	192	502	72	34	0	0	0	800
	0.8	0	0	230	483	76	11	0	0	0	800
	0.7	0	7	292	447	44	10	0	0	0	800
	0.6	0	28	390	333	47	2	0	0	0	800
	0.5	0	101	444	234	20	1	0	0	0	800
	0.0	245	132	280	132	9	2	0	0	0	800
	TOTAL	245	268	2919	2894	313	157	0	0	404	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 94.12\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	0	0	204	596	800
	1.1	0	0	0	0	0	11	5	450	334	800
	1.0	0	0	0	0	1	173	54	538	34	800
	0.9	0	0	0	14	54	517	57	148	10	800
	0.8	0	0	33	117	236	387	11	16	0	800
	0.7	0	2	209	336	198	55	0	0	0	800
	0.6	6	39	533	200	21	1	0	0	0	800
	0.5	89	220	466	25	0	0	0	0	0	800
	0.0	646	109	45	0	0	0	0	0	0	800
	TOTAL	741	370	1286	692	510	1144	127	1356	974	7200

Momentum SGD における α の効果

本結果から、工夫なしに追加学習を行うと前段で学習した磁石配置に対して推定精度が悪化することがわかる。次に第二段階学習に関して、学習パラメータを調整することを考える。CNNの学習手法として Momentum SGD を用いたが、式 3.17 の α の値によって学習速度を調整することが可能である。

テスト関数を用いて勾配法の Momentum 項による探索性能の効果を検証する [72]。式 4.1 に示すテスト関数を用いて、 $\alpha = 0.0$ 及び $\alpha = 0.9$ の場合で式 3.16, 式 3.17 を解き、 f の最小値を求める。

$$f = \frac{1}{10}w_1^2 + w_2^2 \quad (4.1)$$

$\alpha = 0.0$ の場合、速度項がなく、式 3.14 と同等の式を解いている。 $(w_1, w_2) = (-7, 7)$ を初期解とし、200 回収束を繰り返した。最適解は $(w_1, w_2) = (0, 0)$ である。 $\alpha = 0.0$ 及び $\alpha = 0.9$ の結果を図 4.2 に示す。

$\alpha = 0.0$ の場合はそれぞれのステップで再急降下方向に更新されている。しかし、200 ステップ後も最適解に到達していない。一方、 $\alpha = 0.9$ の場合、速度項の効果で勾配方向が前ステップと同様の方向の場合、ステップが進むにつれ一ステップの更新幅が増えている。また、最適解 $(w_1, w_2) = (0, 0)$ に収束している。Momentum 項を用いることで局所解に陥った際の脱却効果もあると考えられる [30]。以上の結果から、 α は収束速度の調整に影響を及ぼすことがわかる。




図 4.2: テスト関数による α の効果検証

追加学習における α の影響

本性質を用いて、追加学習における二段階目の学習収束度を調整することを考える。 α による学習収束度の調整により、第二段階目の学習で扱う磁石配置に対する推定精度にも影響があると考えられる。 α の選び方によっては前段による学習の効果を残すことも可能となると予想できる。

4.4. 学習結果

表 4.7 および表 4.8 に $\alpha = 0.0$ で第二段階学習を行い、テストデータで推定した結果を示す。それぞれ第二段階の学習で用いた磁石配置に対しては推定精度 $\kappa_{\pm 1}$ が数 % 減少しているものの、 $\alpha = 0.9$ で学習を行った場合に比べ、第一段階の学習で用いた磁石配置に対しては推定精度 $\kappa_{\pm 1}$ が大幅に向上している。

図 4.3 および表 4.9 に第二段階学習の α とテストデータによる推定精度 $\kappa_{\pm 1}$ の推移を示す。 $\alpha = 0.9$ の時、第一段階における磁石配置に対する推定精度は I 字磁石配置および V 字磁石配置それぞれ 50% 程度まで悪化している。一方、 $\alpha = 0.0$ の時、第一段階における磁石配置に対する推定精度は I 字磁石配置および V 字磁石配置それぞれ 87% および 89% 程度まで向上している [30]。さらに、第二段階学習で用いた磁石配置に対する推定精度はどちらの磁石配置も 90% 程度であり、高い推定精度となっている。

図 4.4 に第二段階学習における α ごとの損失関数の推移を示す。 α が 1.0 付近の場合、速度項の影響により 1epoch あたりの損失関数降下が早い。一方、 α が 0.0 の場合、損失関数の降下が鈍くなっている。収束する epoch 数は α によらず、ほぼ同一であるから、 α により損失関数の低減度合いを調整できている。本結果より、 α を調整することにより、二つの磁石配置に対して高い推定精度を保ちながら追加学習が可能であると考えられる。




図 4.3: 追加学習における第二段階学習における α とテストデータによる推定精度 $\kappa_{\pm 1}$ [30]

表 4.9: 追加学習における第二段階学習における α とテストデータによる推定精度

α	0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
learn V → I test I [%]	94.6	96.4	94.8	95.1	96.2	97.0	95.8	95.2	98.3	97.8
learn V → I test V [%]	89.9	90.4	92.3	92.3	89.7	84.4	90.8	88.7	83.4	48.4
learn I → V test I [%]	87.4	84.5	84.6	78.9	80.7	76.9	83.2	87.8	84.1	49.9
learn I → V test V [%]	93.5	94.1	94.4	96.3	95.6	97.0	97.4	97.2	97.6	94.1

表 4.7: 追加学習における V 字 → I 字学習推定器 $\alpha=0.0$ のテスト結果 [30]

(a) I 字テストデータ $\kappa_{\pm 1} = 94.56\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	0	9	95	696	800
	1.1	0	0	0	0	0	13	32	362	393	800
	1.0	0	0	0	0	4	164	258	296	78	800
	0.9	0	0	0	12	102	524	130	23	9	800
	0.8	0	1	43	125	347	267	10	2	5	800
	0.7	1	20	259	256	211	51	0	0	2	800
	0.6	19	134	493	105	42	6	0	0	1	800
	0.5	135	367	279	13	5	1	0	0	0	800
	0.0	641	129	27	3	0	0	0	0	0	800
	TOTAL	796	651	1101	514	711	1026	439	778	1184	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 89.89\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	0	0	130	670	800
	1.1	0	0	0	0	0	6	17	361	416	800
	1.0	0	0	1	0	5	130	189	421	54	800
	0.9	0	1	22	33	83	402	177	80	2	800
	0.8	0	19	103	150	208	282	32	5	1	800
	0.7	23	135	286	216	89	50	1	0	0	800
	0.6	114	316	264	79	20	6	0	0	1	800
	0.5	348	375	63	9	4	1	0	0	0	800
	0.0	743	55	2	0	0	0	0	0	0	800
	TOTAL	1228	901	741	487	409	877	416	997	1144	7200

表 4.8: 追加学習における I 字 → V 字学習推定器 $\alpha=0.0$ のテスト結果


(a) I 字テストデータ $\kappa_{\pm 1} = 87.41\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	117	101	172	410	800
	1.1	0	0	0	0	2	441	118	138	101	800
	1.0	0	0	0	5	19	728	27	18	3	800
	0.9	0	0	2	111	120	564	3	0	0	800
	0.8	0	1	12	444	162	181	0	0	0	800
	0.7	2	18	96	607	53	24	0	0	0	800
	0.6	0	174	226	391	7	2	0	0	0	800
	0.5	17	480	204	99	0	0	0	0	0	800
	0.0	519	238	32	11	0	0	0	0	0	800
	TOTAL	538	911	572	1668	363	2057	249	328	514	7200

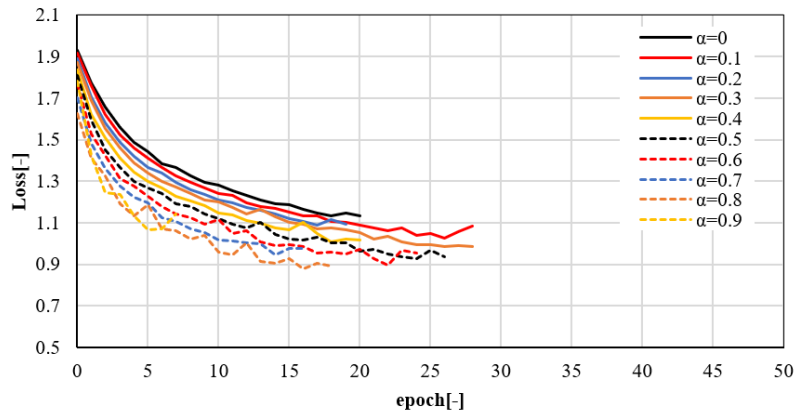
(b) V 字テストデータ $\kappa_{\pm 1} = 93.54\%$

		CNN									
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	TOTAL
FEM	1.2	0	0	0	0	0	2	2	655	141	800
	1.1	0	0	0	0	1	27	53	653	66	800
	1.0	0	0	0	0	10	195	249	344	2	800
	0.9	0	0	1	10	150	412	162	65	0	800
	0.8	0	0	40	94	353	249	48	16	0	800
	0.7	0	9	214	249	276	49	3	0	0	800
	0.6	9	133	404	164	82	8	0	0	0	800
	0.5	110	319	323	35	13	0	0	0	0	800
	0.0	631	134	30	5	0	0	0	0	0	800
	TOTAL	750	595	1012	557	885	942	517	1733	209	7200

4.4. 学習結果



(a) V字磁石配置 → I字磁石配置



(b) I字磁石配置 → V字磁石配置

図 4.4: 追加学習における第二段階学習における α ごとの損失関数の推移

4.4.3 同時学習

次に同時学習に関して検証する。同時学習の場合、教師データを用いた学習過程は1回である。本学習ではI字磁石配置およびV字磁石配置の教師データをそれぞれ800個用意し、1600個を学習に用いた。本検討では $\alpha = 0.9$ で学習した。図4.5に同時学習における損失関数の推移を示す。18epochで学習を打ち切られているが、十分に収束している。

同時学習したCNNのテストデータによる推定結果を表4.10に示す。推定精度 $k_{\pm 1}$ はI字磁石配置およびV字磁石配置に対してそれぞれ96.87%、98.61%であり、それぞれの磁石配置に対して単一学習と同様の推定精度を得ている[30]。本結果より、異なる磁石配置によりトルク性能が大きく異なる形状に対しても同時学習により一つのCNNで特徴量抽出が可能であることがわかる。




図 4.5: 同時学習における損失関数の推移

表 4.10: 同時学習のテスト結果 [30]

(a) I 字テストデータ $\kappa_{\pm 1} = 96.87\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	0	19	81	700	800
	1.1	0	0	0	0	0	30	146	299	325	800
	1.0	0	0	0	0	33	310	351	69	37	800
	0.9	0	0	0	50	369	349	30	0	2	800
	0.8	0	0	13	402	365	20	0	0	0	800
	0.7	0	17	181	575	25	1	0	0	1	800
	0.6	10	205	411	172	1	0	0	0	1	800
	0.5	114	532	144	10	0	0	0	0	0	800
	0.0	698	100	2	0	0	0	0	0	0	800
	TOTAL	822	854	751	1209	793	710	546	449	1066	7200

(b) V 字テストデータ $\kappa_{\pm 1} = 98.61\%$

		CNN									TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	1.2	
FEM	1.2	0	0	0	0	0	0	12	576	212	800
	1.1	0	0	0	0	0	13	185	519	83	800
	1.0	0	0	0	0	13	249	468	70	0	800
	0.9	0	0	0	13	317	397	73	0	0	800
	0.8	0	0	5	184	553	57	1	0	0	800
	0.7	0	2	80	595	121	2	0	0	0	800
	0.6	0	119	395	284	2	0	0	0	0	800
	0.5	41	478	253	28	0	0	0	0	0	800
	0.0	646	145	9	0	0	0	0	0	0	800
	TOTAL	687	744	742	1104	1006	718	739	1165	295	7200

4.4.4 学習手法の比較

追加学習および同時学習によって二種類の磁石配置に対する学習を一つの CNNで行うことが可能であることを示した。追加学習学習の場合、 α の値を調整することにより、あらかじめ学習している磁石配置に対しても推定精度を保つことが可能である。しかし、適

切な α を設定する必要があることから、設定が煩雑になると考えられる。同時学習の場合、そのような設定は不要であり、高精度で学習可能であるため、複数の磁石配置を取り扱う場合は同時学習を用いることが望ましいと考えられる [30].

4.5 形状汎化 CNN を用いた回転子形状のトポロジー最適化

4.5.1 概要

前節で検討した CNN を用いた二種類以上の磁石配置を同時に考慮可能なトポロジー最適化手法を提案する [30]. 第3章における最適化問題は磁石形状を固定している。しかし、磁石配置や形状は複数候補存在すると考えられ、最適化中に磁石配置の選択を行えることが望ましい。最適化を本手法により、複数の磁石配置を自動的に選択した上で最適形状を探索可能となる。ただ、探索するべき範囲が広くなるため、探索に必要な個体数が増加する。そこで、前節で検討した CNN を提案手法内で用いる。

4.5.2 提案手法

本手法は I 字磁石配置および V 字磁石配置を同時に最適化する。図 4.6 に提案するトポロジー最適化手法のフローを示す。以下に詳細を述べる [30].

1. 各磁石配置形状の個体生成
それぞれの磁石配置ごとに個体群を生成し、それぞれの個体に対して材料分布をビットマップ出力する。
2. CNN による特性値推定
同時学習を行った一つの CNN にビットマップを入力し、最適化で考慮する特性値を推定する。
3. FEM 解析判断
それぞれの推定クラスに定められた FEM による解析確率 s に応じて FEM による解析の有無を決定する。
4. 子個体生成
CNN の推定値および FEM による解析値によって評価値を定めたのちはそれぞれの磁石配置において交叉を行い、子個体を生成する。
5. 個体選択
次世代に残す個体を選択する際はすべての磁石配置における個体を評価値の高い順にソートし、ランキング方式で選択する [30]. それぞれの磁石配置個体数は上位半数に存在する個体数をもとに次世代に残す磁石配置の割合を決定する。一磁石配置における個体数が次世代で増加する場合は前世代の個体数との差をランダムな形状で補填する。次世代で個体数が減少する場合は上位の個体を用いる。

本アルゴリズムにより、最適解となり得る磁石配置を選択しつつ、最適化を行うことが可能となる。

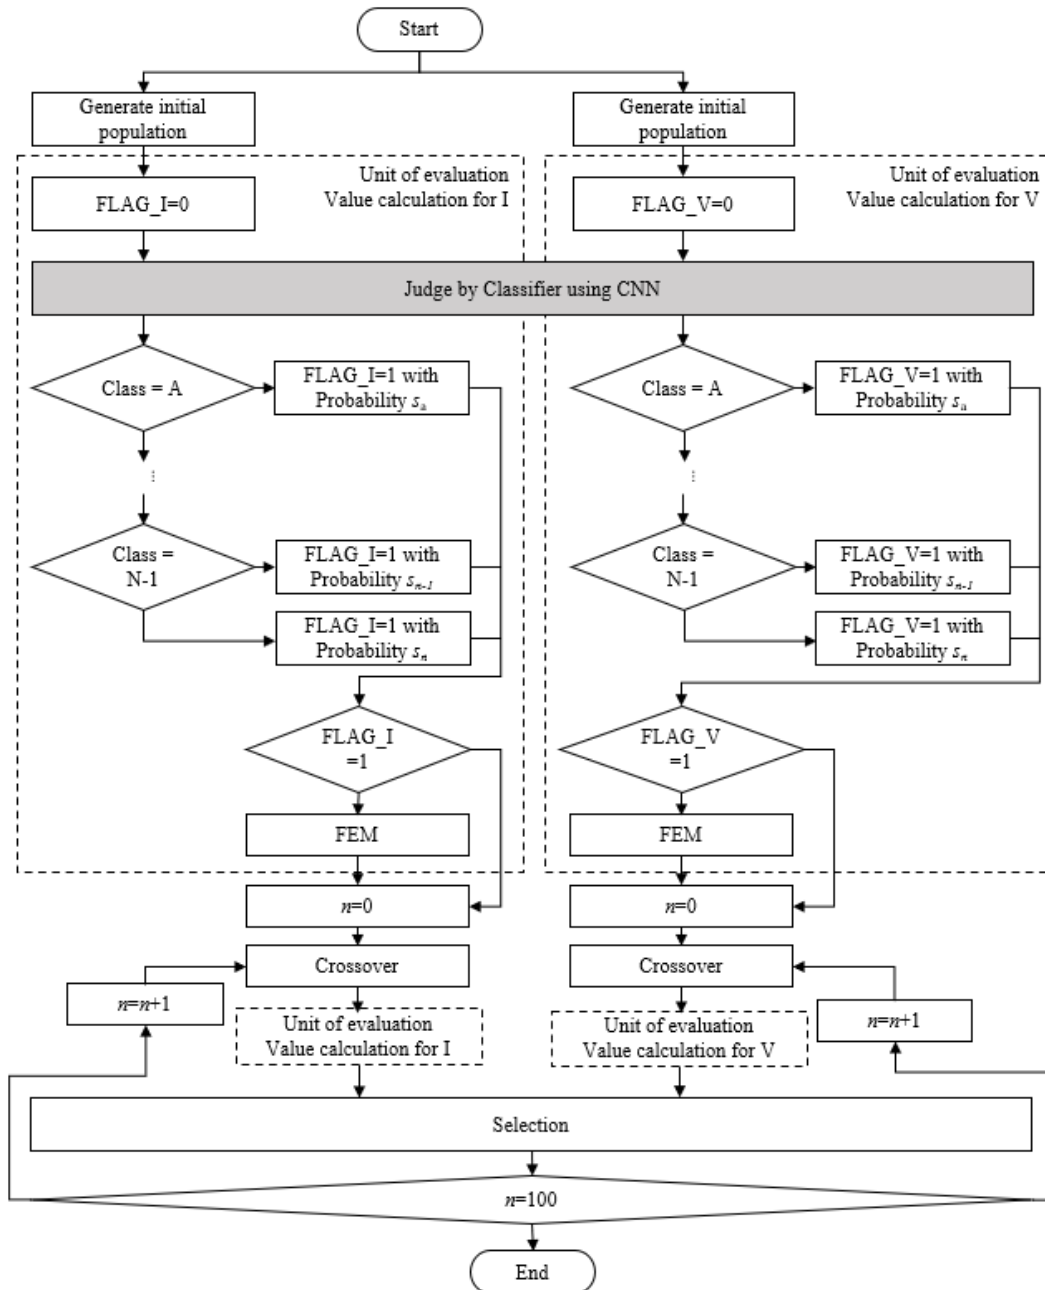


図 4.6: 形状汎化 CNN を用いたトポロジー最適化のフロー [30]

4.5.3 最適化条件

最適化対象は図 3.8 に示す I 字磁石配置および V 字磁石配置の IPM モータ回転子コア形状である。平均トルクの最大化問題を解く。表 4.11 に最適化設定を示す。本手法は集団数が世代ごとに異なるため、それに伴い子個体数を変更する必要がある。本検討では集団数の 20% を子個体数とした。また、一方の磁石配置に個体数が偏った場合、他の磁石配置における探索個体が消失されないよう、最小集団数を 48 と設定した。

また、表 4.12 に解析確率を示す。本検討では比較的高い評価値を持つ個体を FEM により高確率で解析する (a) の条件と、すべての個体を FEM により解析する (b) の条件を用意した。

表 4.11: 形状汎化 CNN を用いたトポロジー最適化における最適化設定 [30]

Number of genes	42
Number of individuals n_i	1600(I;800,V:800)
Number of children n_c	20% of n_i
Number of generations	100

表 4.12: 形状汎化 CNN を用いたトポロジー最適化における解析確率 [30]

Label of F	(a)Probabilities P_1 [%]	(b)Probabilities P_2 [%]
1.2	100	100
1.1	25	100
1.0	13	100
0.9	7	100
0.8	4	100
0.7	2	100
0.6	1	100
0.5	0	100
0.0	0	100

4.5.4 最適化結果

図 4.7 に最適化結果を示す。それぞれの設定において同様の形状を得ることができている。設定 (a)(b) どちらも V 字磁石配置を有する個体が最適解として得られている。回転子表面付近の永久磁石端部にフラックスバリアが形成され、磁石端部漏れ磁束を低減させていると考えられる。また、二枚の永久磁石に挟まれる形で大きな台形型のフラックスバリアが生成されている。本フラックスバリアにより磁石磁束の d 軸方向への鎖交量を増加させている。また、台形型のフラックスバリアは回転し表面付近には形成されていない。これはリラクタンストルク活用のため、q 軸インダクタンスを向上させるためであると考

えられる。

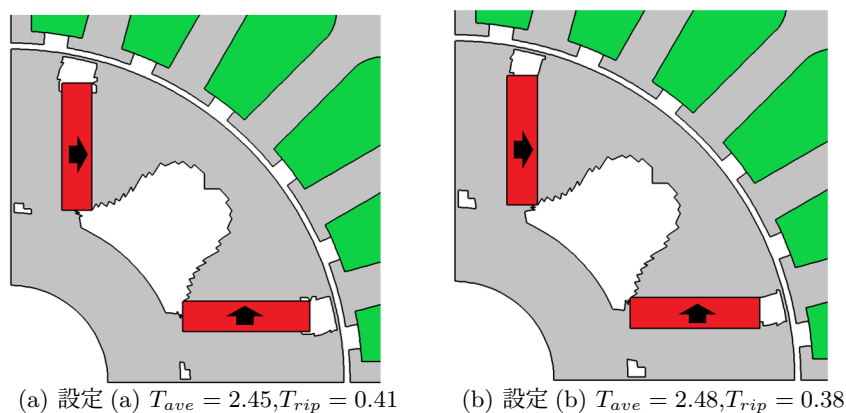


図 4.7: 形状汎化 CNN を用いたトポロジー最適化の最適解

図 4.8 に評価値の推移を示す。実線、点線はそれぞれ I 字磁石配置および V 字磁石配置の集団における評価値を示す。I 字磁石配置に比べ、V 字磁石配置のほうが評価値が高い。また、図 4.9 に I 字磁石配置および V 字磁石配置ごとの個体数の推移を示す。V 字磁石配置の方が集団数が大きく探索を行っている。本結果から、V 字磁石配置のほうが平均トルクに対して有利な個体が生成されていることがわかる。これは、I 字磁石配置と V 字磁石配置を比較したときに V 字磁石配置を用いたほうが d 軸方向へ磁石磁束を集中させやすいことから、回転子起磁力が高く、平均トルクに対し有利な形状を得やすいためであると考えられる [30]。

さらに、図 4.10 にそれぞれの世代ごとの FEM 評価回数の推移を示す。集団数が V 字磁石配置の場合それぞれの世代で平均 1400 個体程度であるため、子個体は 280 個程度である。CNN を用いることにより、評価回数がそれぞれの世代につき平均 20 個体程度に減少している。最適化において 32000 個体用いているが、CNN を用いた場合は 2078 回の解析回数に削減されており、CNN を用いた場合の約 6.4% の解析回数で最適化できている [30]。




図 4.8: 形状汎化 CNN を用いたトポロジー最適化の評価値の推移 [30]

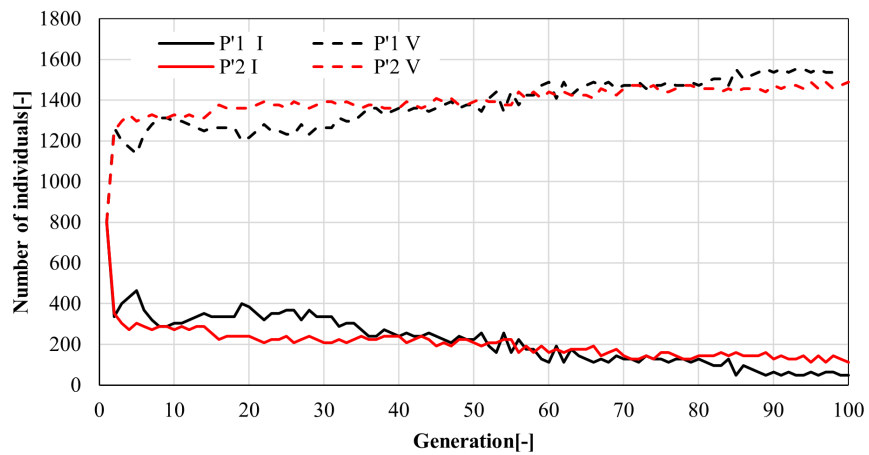


図 4.9: 形状汎化 CNN を用いたトポロジー最適化の世代ごとの個体数の推移 [30]




図 4.10: 形状汎化 CNN を用いたトポロジー最適化の世代ごとの FEM を用いた評価回数 [30]

4.5.5 トポロジー最適化における CNN の効果

トポロジー最適化内に CNN を用いた場合の探索解への影響について考察する. 図 4.8 より, CNN を用いた場合と FEM のみの場合を比較すると, V 字磁石配置は FEM のみの場合のほうが高い評価値の個体を探索できている. 第 3 章における結果と同様に, FEM を用いることで評価値の精度が向上しているため, 探索性能が向上しているものと考えられる. しかし, CNN を用いた場合もほとんど遜色ない評価値をもつ解を得られている. また, 図 4.10 より FEM の解析回数が低減されていることから, CNN を用いることにより推定精度を維持したまま最適化時間を短縮できているといえる.

4.6 総括

本章では単一の CNN を用いて多数の磁石配置の特徴量を学習する CNN の汎化手法として追加学習および同時学習を検証した. 学習対象として, I 字磁石配置および V 字磁石配置を用いた. 追加学習の場合, Momentum SGD の学習パラメータ α を調整することで前段で学習した磁石配置に対する特徴量を保ちながら追加で別の磁石配置に対する特徴量を学習することが可能であることを示した. 同時学習の場合, 異なる磁石配置を持つ形状を教師データとして混在させて学習させることで, 高精度に推定可能な CNN を構築することが可能であることを示した. また, 二種類の磁石配置を同時に考慮しつつ回転子コア形状をトポロジー最適化する新たな最適化手法を提案した. その結果, 従来探索手法の 6.4% の FEM による解析回数で探索可能であることを示した. 得られた解は従来手法, 提案手法ともに同様の特性値を持つことから, 本探索手法は有用であることが示された.

第5章 CNN推定根拠可視化技術を用いた局所探索手法の提案

5.1 はじめに

第3章でも述べたようにトポロジー最適化の探索空間は自由度の高さゆえ多峰性を持つ傾向があり、探索手法に工夫が必要である。多峰性の強い探索空間では局所最適解に陥りやすく、実行可能探索空間における大域的最適解を得ることは難しい。本問題の解決のために多段的に異なる最適化手法、目的関数を用いて最適化をする手法が提案されている。文献 [87] では一段階目に GA、二段階目に再急降下法を用いた最適化を行い、より良好な発電特性を持つオルタネータ形状を探索可能であることを示している。単目的最適化や多目的最適化において大域的な探索を行った後に、得られた最適解周辺を局所探索することで探索性能が向上する。

本手法のように多段的に最適化を行う場合、初段の最適化で得られた形状の良好な特性を次の最適化で悪化させずに最適解を探索することが求められる。このような場合、前の最適化における最適解の特性を制約条件として次の探索を行うことが考えられる。しかし、厳しい制約条件を複数設けると実行可能解が生成されにくくなるため、探索の非効率化が懸念される。

本問題を解決する手段として、設計領域を限定する手法が考えられる。制約条件として課すべき特性に対し感度の高い領域を避けつつ設計領域を設けることで、制約条件を満たす個体を得やすくなる。しかし、回転機はコア内の磁気的非線形性が強く、特性によっては感度の高い領域を限定することは容易ではない。特に IPM モータは磁石の配置やコア形状の自由度が高く、回転子起磁力の高調波成分などの影響などを考慮すると感度の高い領域の特定は難しい [88]。

一方、近年、深層学習の推定根拠を提示する説明可能な DNN が注目されている [89]-[93]。本手法は判定根拠に用いられた領域を可視化する技術であり、ブラックボックスであった深層学習の信頼性向上に寄与する技術である。著者は本手法を回転機磁気特性推定器として用いることに着目した。本手法により、特性の推定根拠となった材料分布を可視化し、設計者へ明示することが可能である。

本章では新たな局所探索手法として説明可能な DNN で得られた解を用いる二段階最適化手法を提案する [31][32]。本研究では説明可能な DNN の一つである Grad-CAM に注目をした。本章の構成を述べる。5.2 節では説明可能な DNN の概要および本研究で用いた Grad-CAM に関して述べる。5.3 節ではモータモデルへ Grad-CAM を用いた結果に関して述べる。5.4 節では Grad-CAM を用いた二段階トポロジー最適化手法に関して述べる。5.5 節では本章の総括を行う。

5.2 CNN 推定根拠可視化技術

5.2.1 概要

本節では推定根拠を明示可能な CNN について述べる。DNN の欠点として、推定根拠が明示されない点が挙げられる。総務省による「AI 開発ガイドライン案」[27]には、AI により判断された解に対し、人間が解の妥当性を判定する際に、AI の判断根拠から判断することが期待されるとの記載がある。この記載からも医療分野や車両の自動運転など安全性や信頼性を求められる分野における DNN の活用において説明性は必須であると考えられる。これらの観点から、近年説明性に関して多くの手法が提案されている。例えば、Ribeiro らは LIME[90] を提案している。本手法は分類結果に対して局所的な近似分類器を作成し、予測に影響のある特徴量を抽出する手法である。Lundberg らは SHAP[91] を提案している。本手法はゲーム理論の Shapley 値を用いた手法である。各特徴量の予測への寄与度を可視化することが可能である。また、Koh らは Influence Function[92] を提案している。本研究では CNN に特化した根拠可視化技術である Grad-CAM[93] に注目した。

5.2.2 Grad-CAM

Gradient-weighted Class Activation Mapping(Grad-CAM) は CNN の畳み込み層を用いて推定根拠を出力する手法である。図 5.1 に Grad-CAM の概要を示す [93]。まず、分類問題の出力クラス c における確率スコア p^c に注目する。分類問題は softmax 関数によって出力される確率スコア p^c が最も高いクラスを分類問題の解として判断している。確率スコア p^c を k 番目の特徴マップの (i, j) ピクセル強度 M_{ij}^k について微分し、全ピクセル分を足し合わせ、特徴マップの全ピクセル数 S で平均化したものをクラス c に対する k 番目の特徴マップの重み係数 e_k^c とすると、以下のように定義できる。

$$e_k^c = \frac{1}{S} \sum_i \sum_j \frac{\partial p^c}{\partial M_{ij}^k} \quad (5.1)$$

式 5.1 により、 p^c に対する各特徴マップの寄与度を算出した。この e_k^c を k 番目の特徴マップに乘じ、すべてのマップを線形結合し、 M_{all}^c を求める。

$$M_{all}^c = \sum_k e_k^c M^k \quad (5.2)$$

求めた M_{all}^c と活性化関数 ReLU 関数を用いて最終的な Grad-CAM の出力 G^c を得る。

$$G^c = ReLU(M_{all}^c) \quad (5.3)$$

G^c の出力が高い領域はクラス c に対する寄与度が高いと考えることができる。本出力と入力画像を透過して比較することでクラスへ分類された根拠の可視化が可能である。

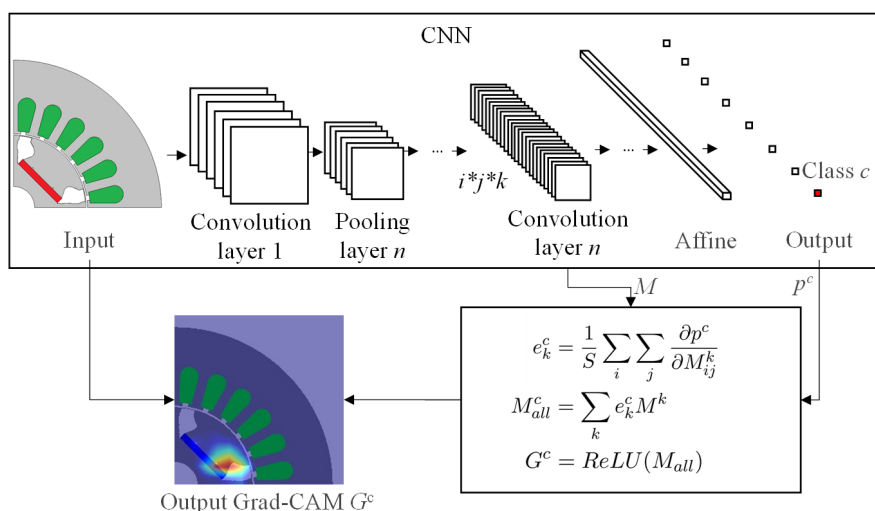


図 5.1: Grad-CAM の概要

5.3 回転機特性推定根拠の可視化

5.3.1 概要

5.2 節において述べた Grad-CAM を回転機特性の推定に用いる。平均トルクやトルクリップルなどの特性を複数のクラスに分けた場合を考える。トルク特性クラス c_t に分類された材料分布を持つ回転機に対し、トルク特性クラス c_t に対する Grad-CAM の出力 G^c を式 5.3 を用いて求める。この場合、入力した材料分布に対し、トルク特性分類の判定となる領域を可視化することが可能である。本節では回転機特性の推定根拠可視化に用いられた領域を可視化するため、回転機の材料分布を表現したビットマップに対して Grad-CAM を適用した結果を述べる。

5.3.2 適用条件

本検討では図 3.8 に示す電気学会 D モデルをベースとした IPM モータを用いる。I 字磁石配置および V 字磁石配置の二種類の磁石配置を検討する。モータモデルの仕様は表 2.4 に示す。まず、表 5.1 に示す最適化条件でトポロジー最適化平均トルク T_{ave} 最大化問題

$$F = \frac{T_{ave}}{T_{ave}^0} \rightarrow \max. \text{ sub.to } \Omega < 2 \quad (5.4)$$

を解いた。最適化内で得られた個体を表 5.3 に示すように平均トルクごとに 8 ラベル 800 個体ずつ分類する。表 5.3 中の平均トルクは電気学会 D モデルの平均トルク 2.08Nm およびトルクリップル 0.57 で正規化されている。1 回の最適化ですべてのラベルが 800 個体満たされない場合、何度か最適化を実施する。

表 5.1: 平均トルク最大化問題における最適化設定

Number of dimensions	54
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REX ^{star}
Method of Generations	100

次に図 3.11(a) で構成される VGG16 を用いて学習を実施する。本検討では 8 分類の分類問題を解くため、図 3.11(a) の最終層数を 8 としている。学習パラメータは表 5.2 に示す。学習した VGG16 の分類性能を評価するため、別のテストデータを用いて分類を行った結果を表 5.4 および表 5.5 に示す。表 5.5 は分類誤差個体数をまとめている。それぞれ、I 字磁石配置および V 字磁石配置に関する結果である。平均トルクに関し、約 97% の精度で分類誤差 ± 1 分類で推定できている。

表 5.2: 分類問題における学習条件

Epoch	100
Batch size	40
Optimizer	Momentum SGD
Learning rate	0.0001

表 5.3: Grad-CAM 適用時の平均トルクの分類

$T_{\text{ave}}^{\text{FEM}}$	$T_{\text{ave}}^{\text{CNN}}$
~ 0.45	0
0.45 \sim 0.55	0.5
0.55 \sim 0.65	0.6
0.65 \sim 0.75	0.7
0.75 \sim 0.85	0.8
0.85 \sim 0.95	0.9
0.95 \sim 1.05	1.0
1.05 \sim	1.1

表 5.4: 学習済み VGG16 の性能評価 [32]©2021 IEEE

(a) I 字磁石配置

		CNN								TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	
FEM	1.1	0	0	0	0	0	17	100	683	800
	1.0	0	0	0	0	13	84	295	408	800
	0.9	0	0	0	5	255	275	215	50	800
	0.8	0	0	16	162	553	55	10	4	800
	0.7	0	25	244	375	156	0	0	0	800
	0.6	8	179	463	143	7	0	0	0	800
	0.5	95	544	152	9	0	0	0	0	800
	0.0	705	91	4	0	0	0	0	0	800
	TOTAL	808	839	879	694	984	431	620	1145	6400

(b) V 字磁石配置

		CNN								TOTAL
		0.0	0.5	0.6	0.7	0.8	0.9	1.0	1.1	
FEM	1.1	0	0	0	0	0	0	18	782	800
	1.0	0	0	0	0	3	134	260	403	800
	0.9	0	0	0	2	190	471	119	18	800
	0.8	0	0	1	171	508	118	2	0	800
	0.7	0	2	51	625	118	4	0	0	800
	0.6	4	85	446	264	1	0	0	0	800
	0.5	49	494	239	18	0	0	0	0	800
	0.0	725	71	4	0	0	0	0	0	800
	TOTAL	778	652	741	1080	820	727	399	1203	6400

5.3.3 Grad-CAM の適用対象

5.3.2 項で作成した CNN に Grad-CAM を適用する。以下、I 字磁石配置に関して適用結果を示す。5.3.2 項の最適化で得られた個体のビットマップを図 5.2 に示す。それぞれのビットマップは平均トルクに関して別のクラスに分類のものを選択した。図 3.11(a) に示すように VGG16 は 13 層の畳込み層から構成される。Grad-CAM は 1 つの畳込み層における特徴マップを用いて可視化することから、適切な畳込み層を選択する必要がある。

5.3.4 Grad-CAM に用いる畳込み層の決定

まず、それぞれの畳込み層に Grad-CAM を適用し、適切に可視化可能な畳込み層を選択する。本検討には図 5.2(h) に示す平均トルク $T_{ave}^{CNN} = 1.1$ に分類された形状を用いた。図 5.3 に図 5.2(h) を VGG16 それぞれの畳込み層を用いて Grad-CAM に適用した結果を示す。入力層に近い畳込み層 Block2 および Block3 は回転機の淵部分に高い Grad-CAM の出力 G^c を得ている。Block4 では回転子のコア部のトルクに寄与すると考えられるコア部に高い Grad-CAM の出力 G^c を得ている。しかし、固定子の出力も残っており、十分に推定に寄与している領域を限定しきれていない。一方、Block5 は回転子のコア部により高い出力 G^c を得ており、平均トルクに寄与する領域を特定しやすい。特に Block5 Convolution3 を用いた場合、他の出力に比べ特定の領域に出力が集中している。

5.3. 回転機特性推定根拠の可視化

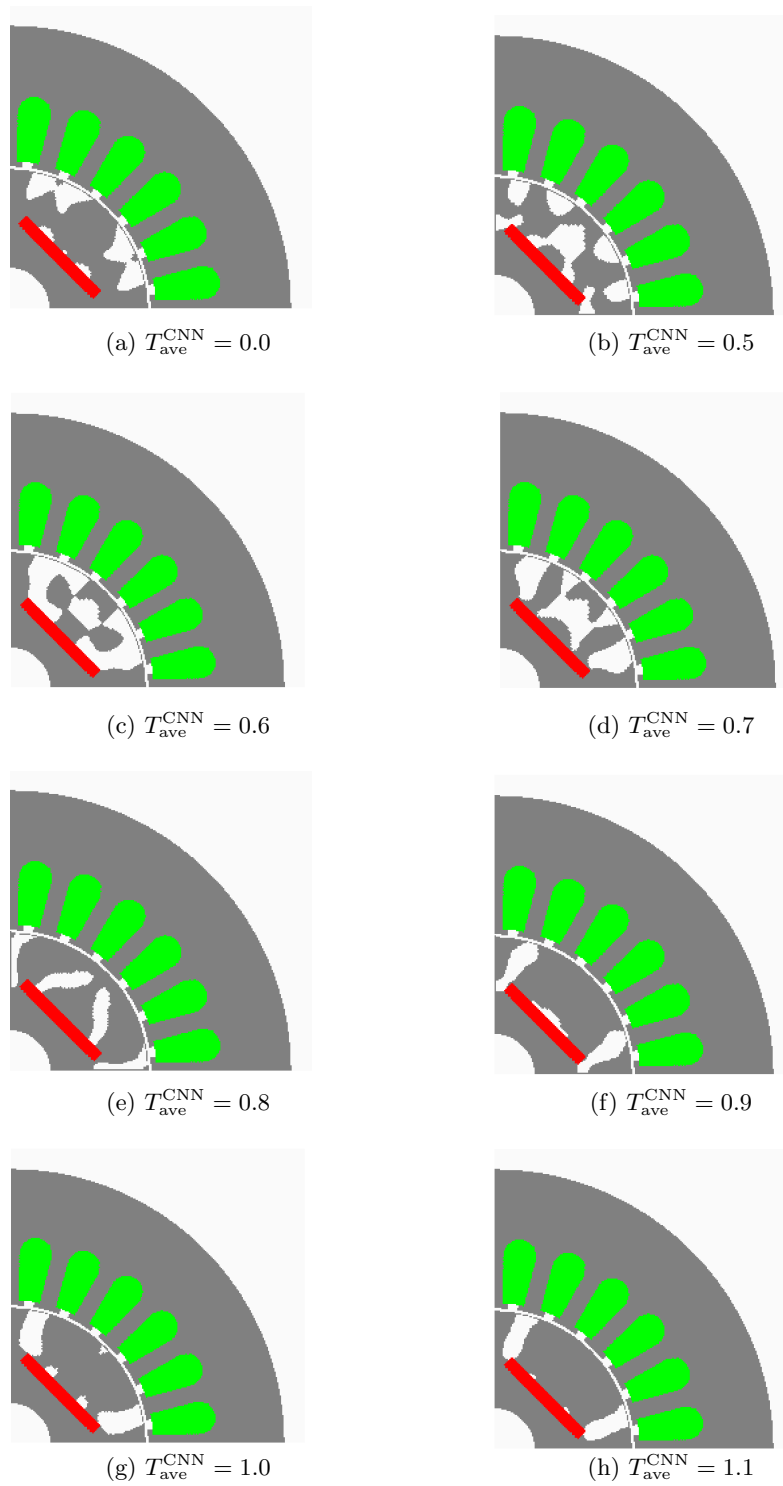


図 5.2: 各クラスに対応したビットマップ例

表 5.5: 学習済み VGG16 の分類誤差個体数

(a) I 字磁石配置		
Error	The number of individual	Ratio[%]
0.0	3893	60.83
0.1	2339	36.55
0.2	164	2.56
0.3	4	0.06
0.4	0	0.00
0.5	0	0.00
0.6	0	0.00
0.7	0	0.00
Total	6400	100.00

(b) V 字磁石配置		
Error	The number of individual	Ratio[%]
0.0	4311	67.36
0.1	2030	31.72
0.2	59	0.92
0.3	0	0.00
0.4	0	0.00
0.5	0	0.00
0.6	0	0.00
0.7	0	0.00
Total	6400	100.00

入力層に近い畳込み層は局所的な特徴量を捉えているが、出力層に近い層は複数回の畳込みおよびプーリング処理により空間情報を捉えられていることから Grad-CAM の出力もその結果を反映したものとなる [93]。本結果はその状況と一致しており、Grad-CAM により正しく寄与領域の可視化が行われていると考えられる。

以上の結果から平均トルクを出力する CNN に Grad-CAM を適用する際は最終出力層手前の層 Block5 Convolution3 を可視化することが望ましいと考えられる。

また、本形状は周方向 45 度で鏡対象な形状であるが、Block5 Convolution3 の Grad-CAM の出力は 0~45 度領域及び 45 度~90 度領域のどちらか一方に出力されている。Block5 Convolution2 においては両領域のフラックスバリアに出力を得ており、両領域のフラックスバリアが特徴量として認知できていることがわかる。d 軸磁束と比例して平均トルクが増加することから、永久磁石の両端にフラックスバリアが配置されることが平均トルクに寄与していると考えられる。そのため、本検討では G^c 出力が集中している Block5 Convolution3 を用いるが、Block5 Convolution2 のように両領域を特徴量として認知する

ことは回転機の特徴上正しいものと考えられる。

5.3.5 Grad-CAM の適用結果

次に最終出力層手前の層 Block5 Convolution3 を用いて図 5.2 のビットマップに Grad-CAM を適用した結果を図 5.4 に示す。 $T_{\text{ave}}^{\text{CNN}} = 0.0$ のビットマップの場合、磁石の端部に存在する回転子コア付近に高い出力がある。本領域は磁石端部漏れ磁束が増加するため、d 軸磁束が減少する。 $T_{\text{ave}}^{\text{CNN}} = 0.9$ 以上の平均トルクの場合も同様にフラックスバリア付近の領域に大きな出力を得ており、平均トルクへの寄与度が高い。

以上のことから、Grad-CAM を用いて回転機の平均トルクに関する特徴量を可視化可能であることがわかる。

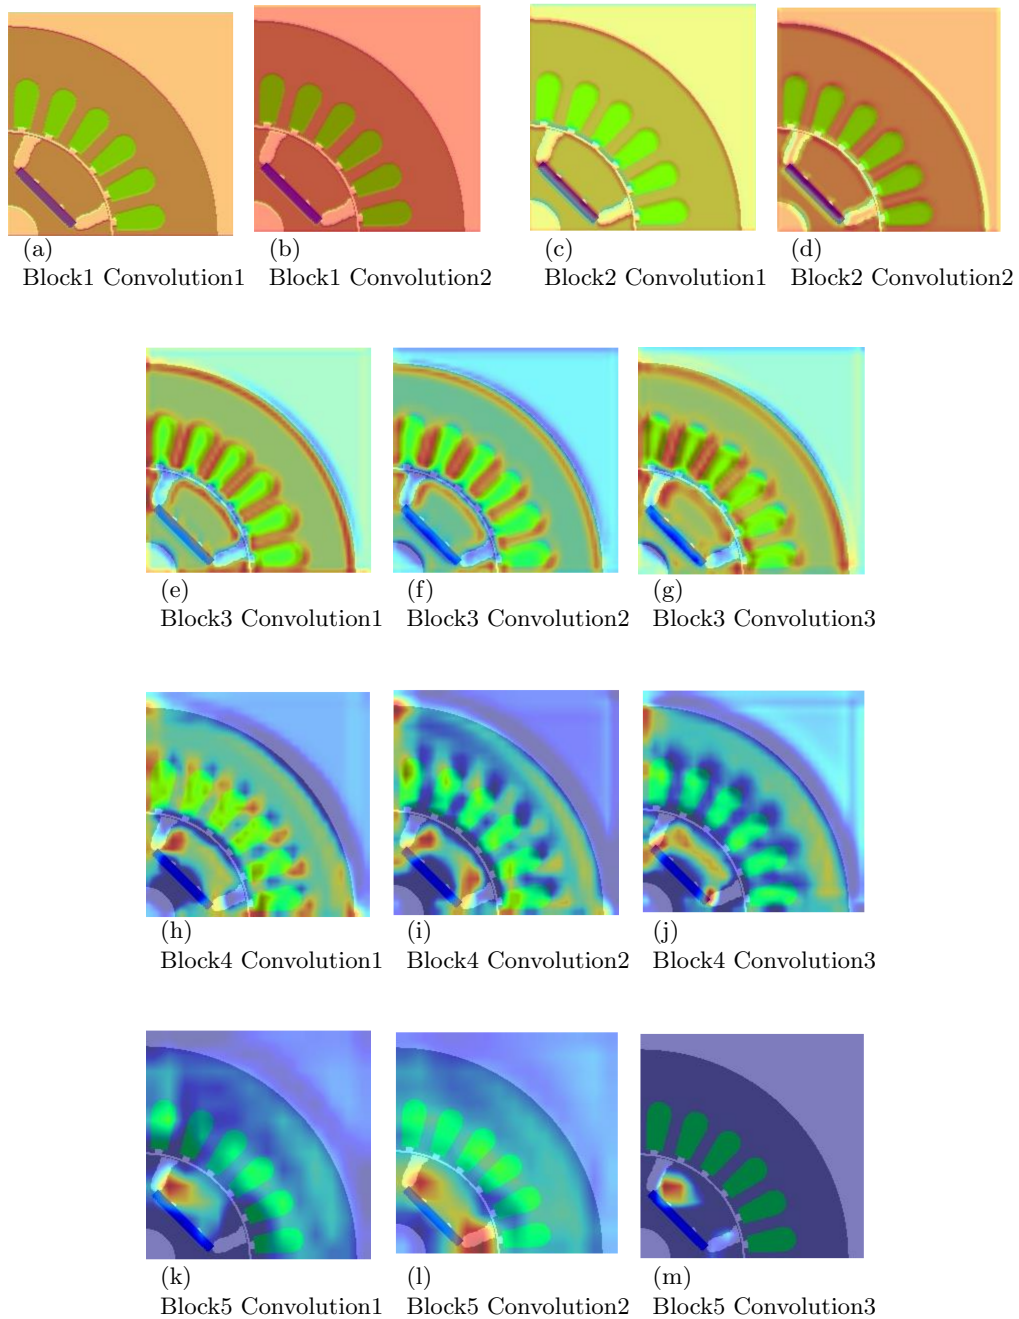


図 5.3: 各層に対する Grad-CAM 適用結果

5.3. 回転機特性推定根拠の可視化




図 5.4: 各クラスに対する Grad-CAM 適用結果

5.4 CNN 推定根拠可視化技術を用いたトポロジー最適化

5.4.1 概要

5.3 節では Grad-CAM によってトルクに寄与する領域を可視化できることを示した。次に Grad-CAM を組み込んだ新たなトポロジー最適化手法を提案する。提案手法は二つの特性に対し Grad-CAM を用いて二段階で最適化を行う。本検討では提案手法を用いて IPM モータの回転子形状を平均トルクおよびトルクリップルに対して最適化する。さらに、多目的最適化手法とも比較し、本提案手法の有用性を示す。

5.4.2 最適化アルゴリズム

図 3.8 に示す IPM モータの回転子形状の平均トルク最大化、トルクリップル最小化問題を解く。提案手法のアルゴリズムを図 5.5 に示す。本手法は大きく 5 段階で構成される。以下にそのフローを示す。

1. 第一段階最適化

第一段階目は図 3.8 の設計領域を平均トルク最大化を目的に最適化する。式 5.5 に目的関数 F_1 を示す。

$$F_1 = \frac{T_{ave}}{T_{ave}^0} \rightarrow \max. \text{ sub.to } \Omega < 2 \quad (5.5)$$

本最適化において用いた個体の材料分布と平均トルクの関係性を保存しておく。

2. CNN 学習

保存した材料分布を用いて VGG16 の学習を行う。

3. Grad-CAM 適用

第一段階の最適化で得られた最適解に対し Grad-CAM を適用し、平均トルクの良いクラスに分類された根拠となった領域を可視化する。

4. 第二段階最適化の設計領域決定

Grad-CAM の出力が強い領域は平均トルクに対して感度の高い領域であるから、その後の最適化において固定することが望ましい。そこで、第二段階最適化では該当する領域を第一段階最適化の最適解の形状に固定し、別の目的関数に対して最適化を行う。

5. 第二段階最適化

本検討では第一段階最適化の最適解の平均トルクを制約条件としてトルクリップル最小化問題を解く。式 5.7 に目的関数 F_2 を示す。

$$F_2 = \frac{T_{rip}}{T_{rip}^0} \rightarrow \min. \text{ sub.to } T_{ave} < T_{ave}^1, \Omega < 2 \quad (5.6)$$

ここで、 T_{ave}^1 は第一段階最適化の最適解の平均トルクである。平均トルク制約はペナルティ制約であり、以下の式に基づいて評価値にペナルティを課した。

$$F_2 = F_2 + 500 \times \frac{T_{ave}^1 - T_{ave}}{T_{ave}^1} \quad (5.7)$$

第二段階最適化では平均トルクに対して感度の高い領域を固定しているため、平均トルクの制約を満たす形状が生成されやすい。したがって、二目的に対して効率的に形状探索可能であると考えられる。

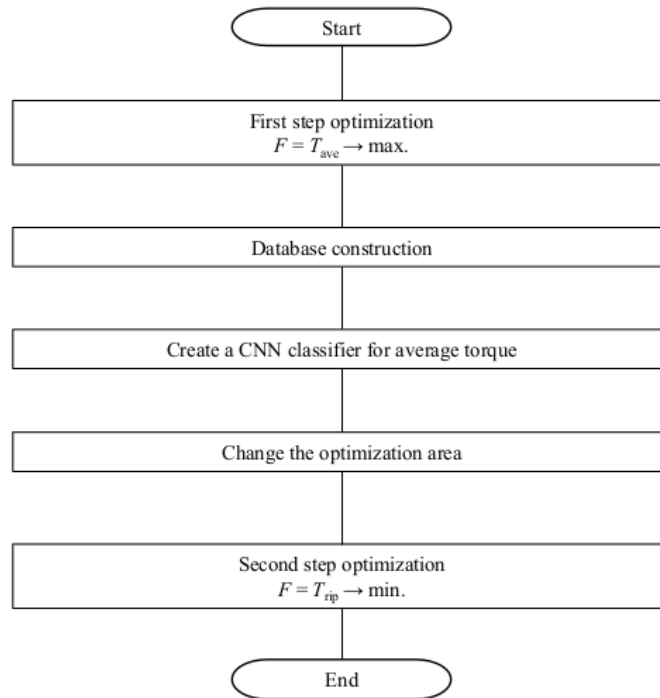


図 5.5: Grad-CAM を用いたトポロジー最適化アルゴリズム [32]©2021 IEEE

5.4.3 最適化設定

5.4.2 項で提案した手法に関し、検証を行う。本検討では I 字磁石配置および V 字磁石配置に対して最適化を適用する。表 5.6 に最適化設定を示す。第一段階最適化，第二段階最適化ともに集団数，子個体数及び交叉方法は同一とした。それぞれ 100 世代最適化を行い，計 200 世代目の個体を最終的な最適解とした。

表 5.6: Grad-CAM を用いたトポロジー最適化設定

Number of dimensions	54
Number of individual	1000
Number of parents	100
Number of children	200
Method of Crossing over	REXStar
Method of Generations	100

5.4.4 最適化結果

第一段階最適化

図5.6に第一段階最適化の最適解を示す。I字磁石配置の場合、平均トルク $T_{ave} = 2.40\text{Nm}$ 、トルクリップル $T_{ripple} = 0.34$ であり、オリジナルモデルに比べ平均トルクが15.4%増加している。磁石端部に大きなフラックスバリアが生成されており、d軸磁束が増大するコア形状となっている。さらに、磁石着磁方向のコア中央付近には空気領域が生成されている。本空気領域により、回転子空隙磁束密度の基本波成分を増大させ、マグネットトルクを増加させる働きがあると考えられる。

一方、V字磁石配置の場合、平均トルク $T_{ave} = 2.52\text{Nm}$ 、トルクリップル $T_{ripple} = 0.41$ である。二つの永久磁石端部に大きな空気領域が生成されている。また、回転子表面付近の磁石端部にも空気領域が生成されている。本空気領域は磁石端部の漏れ磁束を低減させる目的と、d軸に磁石磁束を集中させる効果があると考えられる。

Grad-CAM の適用

次に、図5.6の形状に Grad-CAM を適用した結果を図5.7に示す。I字磁石配置の場合、磁石端部と中央の空気領域間のコア部に高い Grad-CAM の出力が分布している。本領域は磁石磁束の磁路となっており、極めて重要な領域である。

一方、V字磁石配置の場合、永久磁石の着磁方向のコア部に Grad-CAM の高い出力を得た。本領域はd軸方向に磁石磁束を集中させるため、磁路として必要な領域である。

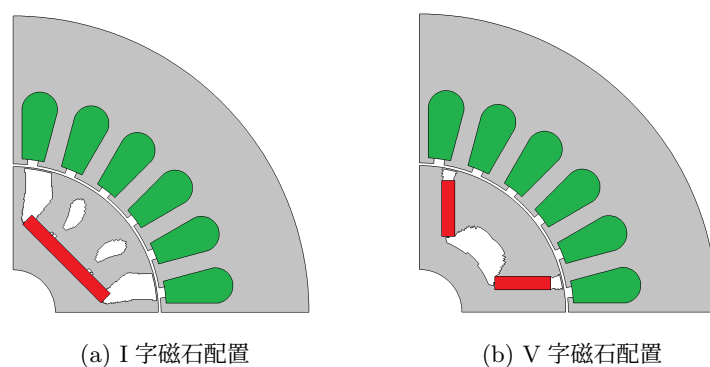


図 5.6: Grad-CAM を用いたトポロジー最適化における第一段階最適化の最適解 [32]©2021 IEEE

設計領域の決定

図5.7の Grad-CAM 出力 G_e^c をもとに第二段階最適化の設計領域を決定する。固定領域を定める際には第一段階最適化設計領域内のそれぞれの要素 e の重心における Grad-CAM 出力 G_e^c と閾値 ξ を用いて次のように決定する。

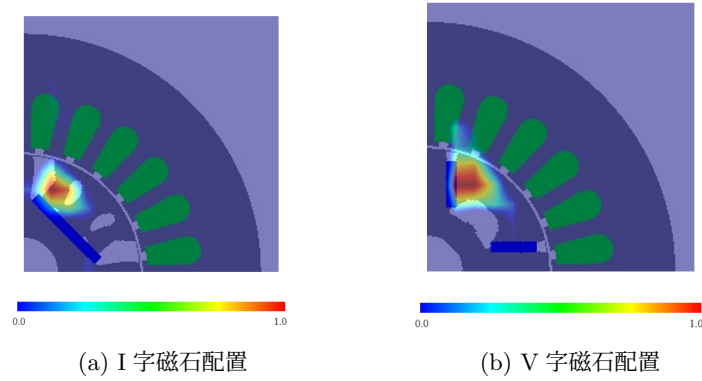


図 5.7: 第一段階最適化の最適解に Grad-CAM を適用した結果 [32]©2021 IEEE

$$e = \begin{cases} \text{Properties of the optimal solution of the first stage optimization} & (G_e^c > \xi) \\ \text{Design region} & (\textit{otherwise}) \end{cases}$$

閾値 ξ によって設計領域は変化する。本検討ではまず、Grad-CAM の出力最大値を 1.0 と正規化したとき、閾値 $\xi = 0.5, 1.0$ の場合を考える。 $\xi = 1.0$ の場合、設計領域は限定されていない状態である。図 5.8 に $\xi = 0.5$ の場合の設計領域を示す。それぞれ固定されている領域は平均トルクに大きく寄与する領域である。

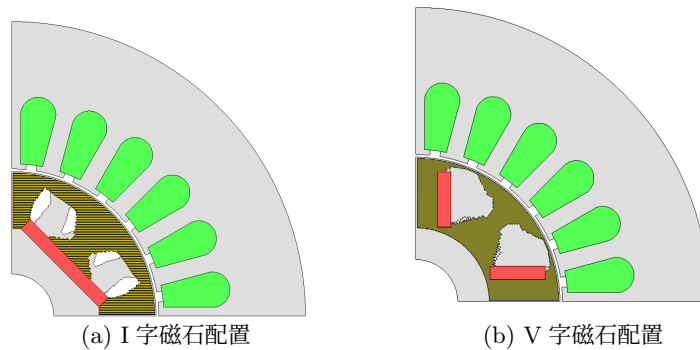


図 5.8: Grad-CAM を用いたトポロジー最適化における $\xi = 0.5$ の場合における第二段階最適化の設計領域 [32]©2021 IEEE

第二段階最適化の結果

図 5.9 に第二段階最適化結果を示す。それぞれの結果は I 字磁石配置および V 字磁石配置に対し、 $\xi = 0.5$ および $\xi = 1.0$ の場合の設計領域で最適化を行った結果である。平均ト

ルクおよびトルクリップルともに提案手法により、設計領域を限定した場合のほうがより良好な解を得ている。

$\xi = 1.0$ のとき、トルクリップル回転子表面付近に小さな空気領域が生成されている。本領域は空隙磁束密度の高調波成分を低減させる効果があると考えられる。一方、 $\xi = 0.5$ のとき、平均トルクに寄与する領域を固定しているため、 $\xi = 1.0$ の場合に比べ平均トルクが高い形状を得ることができている。永久磁石端部から生成されている空気領域が d 軸磁束の磁路に突出するような形状が生成されている。本形状により、空隙磁束密度分布の高調波成分が減少するため、トルクリップルが減少するものと思われる。

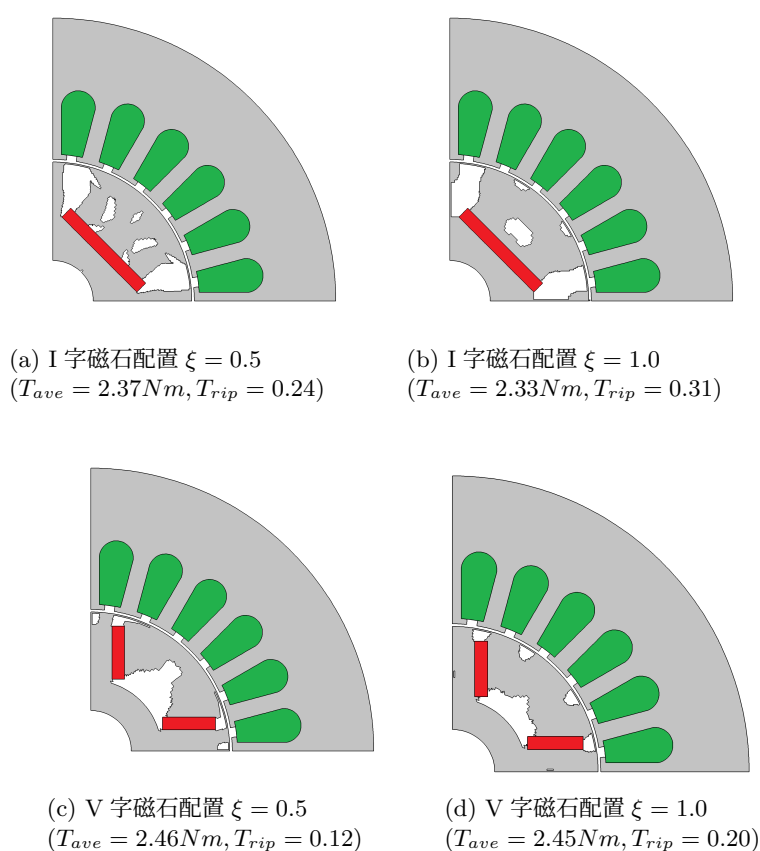


図 5.9: Grad-CAM を用いたトポロジー最適化における $\xi = 0.5$ の場合における第二段階最適化の最適解 [32]©2021 IEEE

また、図 5.10、図 5.11 および図 5.12 に世代ごとの評価値、平均トルクおよびトルクリップルの推移を示す。 $\xi = 0.5$ の場合、最適化の初期段階で平均トルクの高い個体が生成されている。




図 5.10: Grad-CAM を用いたトポロジー最適化における第二段階最適化の評価値の推移




図 5.11: Grad-CAM を用いたトポロジー最適化における第二段階最適化の平均トルクの推移

閾値 ξ の効果検証

閾値 ξ の効果を検証するため、追加で I 字磁石配置の最適化における閾値 $\xi=0.1, 0.3, 0.7, 0.9$ の場合を考える。図 5.13 に第二段階最適化の設計領域を示す。 ξ が大きいほど第二段階最適化の設計領域は限定される。

図 5.14 に第二段階最適化結果を示す。 $\xi = 0.1$ の平均トルクが第一最適化と同様の




図 5.12: Grad-CAM を用いたトポロジー最適化における第二段階最適化のトルクリップルの推移




図 5.13: Grad-CAM を用いたトポロジー最適化における閾値 ξ を変更した場合の第二段階最適化の設計領域

$T_{ave}=2.40\text{Nm}$ となり、トルクリップル $T_{rip}=0.12$ と第一段階最適化の最適解に比べトルクリップルが35.3%に減少した。一方、 $\xi = 0.1$ 以外の場合、平均トルクが第1段階最適化に比べ劣った結果となっている。図5.15に $\xi=0.1$ において得られた最適解のトルク波形を示す。比較として第一段階最適化で得られた形状とDモデルのトルク波形を掲載する。第二段階最適化により得られた形状によるトルク波形の振幅は第一段階最適化の最適解およびDモデルに比べ小さくなっている。

また、図5.16、図5.17および図5.18に世代ごとの評価値、平均トルクおよびトルクリップルの推移を示す。 $\xi=0.1$ および $\xi=0.5$ の場合、世代交代の序盤で高トルクを持つ形状を得ることができている。 $\xi=0.3$ の場合、序盤で低トルクリップルの個体を得ることができ、平均トルクの最大化が進まなかったものと考えられる。このように、 ξ を0付近の値とし、設計領域を限定することで、制約条件である第一段階最適解の平均トルクに近い個体を生成しやすくなっており、その結果、より良好な解を得ることができている。

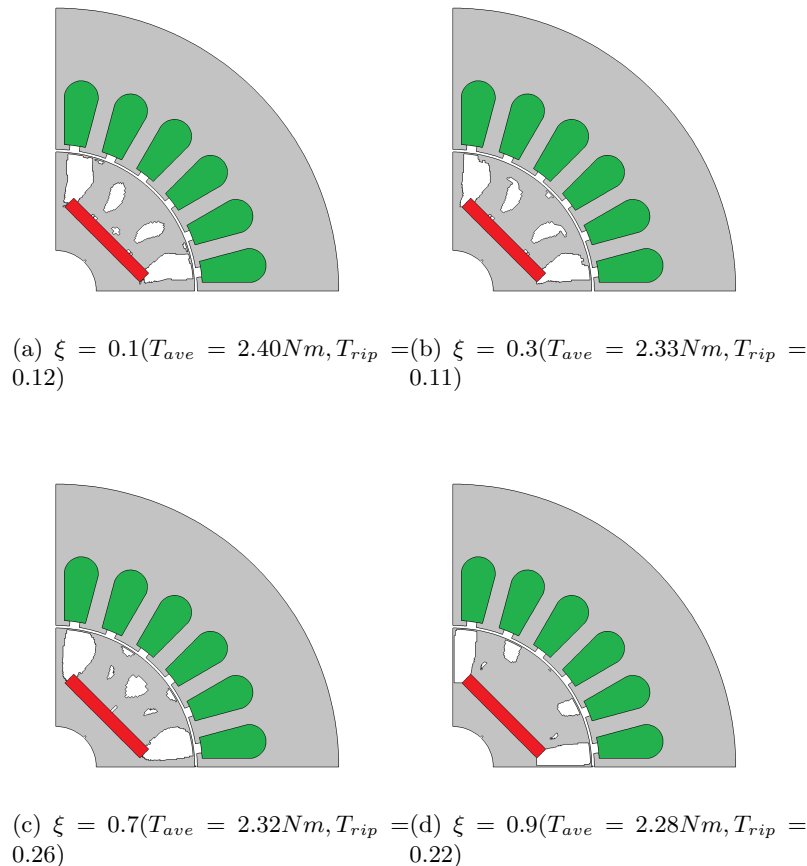


図 5.14: Grad-CAM を用いたトポロジー最適化における閾値 ξ を変更した場合の第二段階最適化の最適解

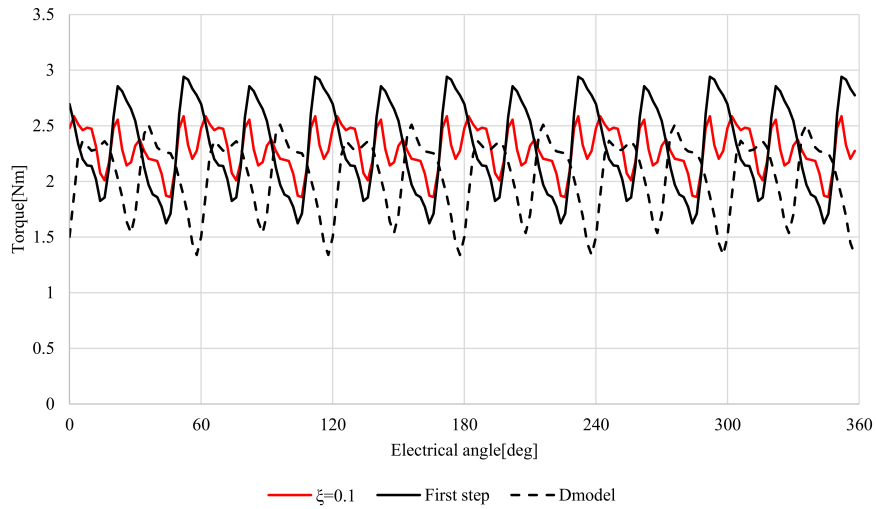


図 5.15: Grad-CAM を用いたトポロジー最適化における第二段階最適化 $\xi=0.1$ で得られた最適解のトルク波形




図 5.16: Grad-CAM を用いたトポロジー最適化における第二段階最適化の評価値の推移




図 5.17: Grad-CAM を用いたトポロジー最適化における第二段階最適化の平均トルクの推移




図 5.18: Grad-CAM を用いたトポロジー最適化における第二段階最適化のトルクリップルの推移

多目的最適化との比較

提案手法との比較のため平均トルク最大化、トルクリップル最小化の多目的最適化と比較を行った。表 5.7 に最適化設定を示す。提案手法と同様に 200 世代目のパレート解と比

較した. 式 5.8 に目的関数 F_1, F_2 を示す.

$$F_1 = \frac{T_{ave}}{T_{ave}^0} \rightarrow \max, F_2 = \frac{T_{rip}}{T_{rip}^0} \rightarrow \min, \text{sub.to } \Omega < 2 \quad (5.8)$$

表 5.7: 多目的最適化の最適化設定 [32]

Number of dimensions	54
Number of individual	200
Number of pareto	100
Optimized method	NSGA-II
Method of Crossing over	REXStar
Method of Generations	200

図 5.19 に多目的最適化の結果を示す. 横軸, 縦軸はそれぞれ平均トルク, トルクリップルを示している. 黒四角は多目的最適化のパレート解を示す. 提案手法によるすべての最適解は多目的最適化のパレート解の外側にあることがわかる. また, $\xi=0.1$ のとき, さらに良好な解を得られていることがわかる. 以上のことから, 提案手法は多目的最適化に比較してさらに探索性能の高い最適化手法であることが示される.

5.5 総括

本章では推定根拠を可視化する Grad-CAM を回転機磁気特性推定に適用し, 以下の知見を得た.

- 回転機の平均トルクに対する推定を行う CNN に対し, Grad-CAM を用いることで推定根拠を的確に可視化することが可能である.
- Grad-CAM 適用の際には出力層の手前である最終畳込み層を用いることで特徴量を限定することができる.
- Grad-CAM を二段階最適化に適用することで, オリジナルモデルに比べ平均トルク 15.4% 増, トルクリップル 78.5% 減の形状を得ることができた.
- 提案手法により多目的最適化に比べ, より良好な解を得ることが可能となる.
- ξ を小さくとることにより, 第一段階最適化の最適解における影響を加味した最適化を行うことができる.

本手法を多目的最適化によって得られた解の周辺探索に用いることも想定される. また, 他の目的に関しても CNN を構築することができれば, 適用可能である.





図 5.19: 提案手法と多目的最適化との比較

第6章 結論

本研究ではモータの特性向上を目的とした回転子断面コア形状のトポロジー最適化アルゴリズムにCNNを併用した新たな最適化手法を提案した。さらに最適化中で用いるモータの特性を推定するCNNの高精度化、形状汎化手法さらには推定根拠可視化手法に関して検証を行った。以下に各内容の詳細を示し、最後に今後の展望を述べる。

6.1 CNNを用いたモータ特性推定精度向上手法の提案 (第3章)

トポロジー最適化内でFEMの代用としてCNNを用いる場合、CNNの推定精度をさらに高精度にする必要がある。そこで、モータ形状と平均トルクおよびトルクリップルを高精度に推定する手法に関して検証した。本検討ではCNNに入力する教師データとして二次元断面材料分布および磁束密度分布を用いた。さらに、トポロジー最適化にCNNを用いた場合の教師データの種類の違いによる探索性能の違いに関して述べた。本検討において得られた知見は以下の通りである。

- CNNに学習する際、教師データとして磁束密度分布を用いることで、コアの磁気非線形性を考慮可能となり、材料分布を用いる場合に比べ平均トルクおよびトルク振幅に関する推定精度が向上することを示した。推定精度の向上には磁気非線形性特性と特性の相関が強いこと、固定子情報が増加したことが挙げられる。さらに、トルクリップルに比べ振幅のほうが容易に学習可能であることを示した。トルクリップルの推定精度向上にはさらなる工夫が必要である。
- 精度の高いCNNをトポロジー最適化に利用することにより、より探索性能が向上することが確認できた。

6.2 CNNによる推定可能形状汎化手法の提案 (第4章)

単一のCNNに複数の大きく特性の異なる磁石配置をもつ回転子を学習させる手法に関して検討を行った。また、複数の磁石配置を考慮しながら最適化を行う新たなトポロジー最適化手法を提案した。本検討において得られた知見は以下の通りである。

- 複数の磁石配置を単一のCNNに学習する手法として、一種類の磁石配置ごとに順次学習する追加学習および複数の磁石配置を同時に学習する同時学習を提案した。追加学習の場合、Momentum SGDのハイパーパラメータを調整することで前段で学習した磁石配置に関する特徴量を残しやすく、高い推定精度を保つことができることを確認した。同時学習を行うことにより、二種類の磁石配置に対して高い推定精度で学習することができた。

- 二種類の磁石配置を同時に最適化する最適化アルゴリズムを開発し、同時学習により学習した CNN を用いて平均トルク最大化問題を少ない FEM の解析回数で探索できることを示した。

6.3 CNN 推定根拠可視化技術を用いた局所探索手法の提案 (第 5 章)

CNN の欠点として推定根拠が不明瞭な点が挙げられる。本検討では CNN の推定根拠を可視化する説明可能な CNN に着目した。CNN の推定根拠を可視化する手法の一つである Grad-CAM をモータの特性推定に適用した。また、Grad-CAM の結果を用いた新たな二段階最適化手法を提案した。本検討において得られた知見は以下の通りである。

- Grad-CAM をそれぞれ二種類の磁石配置を持つ IPM モータの平均トルクを推定する CNN に適用した。その結果、モータの平均トルクに対する推定根拠の可視化が可能であることを示した。さらに Grad-CAM に用いる層として最終層が望ましいことを確認した。
- Grad-CAM を用いて可視化した平均トルクに対して感度の高い領域を平均トルク最大化問題の最適解の材料分布に固定した状態でトルクリップルに対する最小化問題を解く二段階最適化手法を提案した。本手法を用いて平均トルク最大化、トルクリップル最小化最適化問題を二種類の磁石配置の回転子コアに適用した。本手法により、二段階目の最適化において初期の世代で平均トルクの制約を満たす形状が生成されやすく、従来の最適化に比べ評価値が高い形状を得ることが可能であることを示した。さらに多目的最適化と比較してもパレート解よりも良好な解が得られることを示した。

6.4 今後の展望

本研究の今後の展望を述べる。

CNN を用いたモータ特性の推定精度向上手法として磁束密度分布を教師データとした学習手法を提案した。精度向上のため、入力データの前処理などさらに工夫する必要があると考えられる。磁束密度分布の入力方法としてスカラー値を入力するのではなく、ベクトル値を入力することでより忠実に物理現象を学習することが可能であると考えられる。さらに、材料分布と磁束密度分布を同時に学習させることも考えられる。今後、産業応用のためには平均トルクおよびトルクリップル以外にもコギングトルク、損失、回転数トルク特性など推定対象を拡大していく必要がある。

CNN による推定可能形状汎化手法として追加学習および同時学習を検証した。本検討では大きく特性が異なる磁石配置に対して同一の CNN で推定可能であることを示した。汎化手法として追加学習、同時学習以外にもアンサンブル学習なども検証する必要がある。今後、さらに異なる磁石配置を用いて二種類以上の磁石配置に対する推定を行うことが考えられる。さらに、磁石配置も考慮したマルチマテリアル最適化に CNN を適用することが可能であると考えられる。

CNN 推定根拠可視化技術を用いた局所探索手法として Grad-CAM を用いた。Grad-CAM 以外にも CNN の推定可視化手法が多数提案されており、電磁界解析と親和性の高

い可視化技術を検証していく必要がある。平均トルクだけでなく、他の特性に対して適用もしていくことも考えられる。さらに、CNNの推定根拠をトポロジー最適化へ適用していく方法として、進化計算の中でオンラインで用いる手法が考えられる。

また、CNNをさらに精度よく用いるため、教師データの収集方法やデータ処理方法に関してさらに検討を行う必要がある。

参考文献

- [1] 貝塚正明 他, “自動車の電動化における最新技術動向,” 電気学会論文誌 D, vol.139, No.6, pp.535-542, 2019.
- [2] “技術の進歩,” 三菱電機技報, vol.94, No.1, 2020.
- [3] 武田洋次 他, “埋込磁石同期モータの設計と制御,” オーム社, 2001.
- [4] 赤津 観, “史上最強カラー図解 モータ技術のすべてがわかる本,” ナツメ社, 2012.
- [5] 見城 尚志 他, “最新 小型モータのすべてがわかる,” 技術評論社, 2007.
- [6] 森本 茂雄 他, “省エネモータの原理と設計法,” 科学情報出版, 2013.
- [7] 高橋 則雄, “磁気工学の有限要素法,” 朝倉出版, 2013.
- [8] Olgierd Cecil Zienkiewicz 他, “基礎工学におけるマトリックス有限要素法,” 培風館, 1975.
- [9] 大久保 寛 他, “電気工学における大規模並列コンピューティングの利用動向と将来展望,” 電気学会誌, vol.139, No.10, 2019.
- [10] 小林 重信, “実数値 GA のフロンティア,” 人工知能学会誌, Vol.24, No.1, pp.128-143, 2009.
- [11] 山本 透 他, “実習で学ぶ モデルベース開発,” コロナ社, 2018.
- [12] 大西 拓馬, 高橋 則雄 他, “有限要素法と最適化手法を併用した IPM モータの設計法の検討,” 電気学会論文誌 D, vol.121, No.3, pp.397-402, 2001.
- [13] K. Yamazaki, et. al, “Rotor-shape optimization of interior-permanent-magnet motors to reduce harmonic iron losses.” *IEEE Transactions on Industrial Electronics*, vol.1, No.57, pp.61-69, 2010.
- [14] 佐藤 孝洋, 五十嵐 一, 高橋 慎矢, 内山 翔, 松尾 圭祐, 松橋 大器, “トポロジー最適化による埋込磁石同期モータの回転子形状最適化.” 電気学会論文誌. D, 産業応用部門誌, Vol.135, No. 3, pp.291-298, 2015.
- [15] M. P. Bendsoe, and K. Noboru, “Generating optimal topologies in structural design using a homogenization method.”, 1988.
- [16] 西脇 眞二 他, “トポロジー最適化,” 丸善出版, 2013.

- [17] T. Yamada, et. al, “A topology optimization method based on the level set method incorporating a fictitious interface energy.” *Computer Methods in Applied Mechanics and Engineering*, vol.199, No.45-58, pp.2876-2891, 2010.
- [18] K. Watanabe et al., “Optimization of Inductors Using Evolutionary Algorithms and Its Experimental Validation,” *IEEE Transactions on Magnetics*, vol.46, no.8, pp.3393-3396, 2010.
- [19] Y.Okamoto, K. Akiyama, N. Takahashi, “3-D topology optimization of single-pole-type head by using design sensitivity analysis,” *IEEE Transactions on Magnetics*, vol. 42, No. 4, pp. 1087-1090, 2006.
- [20] Y.Hidaka, T. Sato, and H. Igarashi, “Topology optimization method based on on-off method and level set approach,” *IEEE Transactions on Magnetics*, vol. 50, No. 2, pp. 617-620, 2014.
- [21] T.Sato, K.Watanabe, H.Igarashi, “Multimaterial Topology Optimization of Electric Machines Based on Normalized Gaussian Network,” *IEEE Transactions on Magnetics*, vol.51, no.5, Article #: 7202604, 2015.
- [22] Y. LeCun, B.Yoshua, H. Geoffrey, “Deep learning,” *Nature*, vol. 521, No. 7553, pp. 436-444, 2015.
- [23] I. Goodfellow, et al., “Deep Learning,” KADOKAWA, 2018.
- [24] D. Silver, et al., “Mastering the game of Go with deep neural networks and tree search,” *Nature*, vol. 529, No. 7587, pp. 484-489, 2016.
- [25] H. Sasaki, H. Igarashi, “Topology Optimization Accelerated by Deep Learning,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2901906, 2019.
- [26] H. Sasaki, H. Igarashi, “Topology Optimization of IPM Motor with Aid of Deep Learning,” *International Journal of Applied ElectroMagnetics and Mechanics*, vol. 59, no. 1, pp. 87-96, 2019.
- [27] “国際的な議論のための AI 開発ガイドライン案,” 総務省 AI ネットワーク社会推進会議, 2018.
- [28] 佐々木秀徳, 日高勇氣, 有田秀哲, 伊藤一将, 五十嵐一, “磁界分布を用いた回転機トルク性能の深層学習-基礎検討”, 電気学会静止器回転機合同研究会, SA-20-060, RM-20-084, 2020.
- [29] H. Sasaki, Y. Hidaka, H. Igarashi, “Deep Neural Network with Magnetic Nonlinearity to Estimate Rotating Machine Properties,” *IEEE Access*, in preparation.
- [30] 佐々木秀徳, 日高勇氣, 五十嵐一, “深層学習を用いたトポロジー最適化-同時および追加学習の比較,” 電気学会論文誌 B, Vol. 140, no. 12, pp.858-865, 2020.

- [31] 佐々木秀徳, 日高勇氣, 伊藤一将, 田中敏則, 五十嵐一, “説明可能 AI を援用した回転機のトポロジー最適化手法: 基礎検討,” 電気学会静止器回転機合同研究会, SA-20-020, RM-20-020, 2020.
- [32] H. Sasaki, Y. Hidaka, H. Igarashi, “Explainable Deep Neural Network for Design of Electric Motors,” *IEEE Transactions on Magnetism*, submitted.
- [33] 五十嵐一, “電磁界解析法の最近の動向,” 電気学会論文誌, vol. 127, no. 11, pp.711-714, 2007.
- [34] 邵 長城, “基礎からわかる有限要素法,” 森北出版株式会社, 2008.
- [35] D. S. Kershaw, “The incomplete Cholesky—conjugate gradient method for the iterative solution of systems of linear equations.” *Journal of computational physics*, vol. 26, No.1 ,pp.43-65, 1978.
- [36] H Igarashi, T Honma, “On convergence of ICCG applied to finite-element equation for quasi-static fields,” *IEEE Transactions on Magnetism*, vol. 38, no. 2, pp. 565-568, 2002.
- [37] 本間 利久, 五十嵐 一, 川口 秀樹, “数値電磁力学—基礎と応用—,” 森北出版株式会社, 2002.
- [38] 高橋 則雄, “三次元有限要素法,” 電気学会, 2006.
- [39] 砂川重信, “理論電磁気学,” 紀伊国屋書店, 1999.
- [40] 福島雅夫, “数理計画入門.” 朝倉書店, 2011.
- [41] D. Goldberg, “Genetic algorithms in search.”, *Optimization, and Machine Learning* .1989.
- [42] 電気学会進化技術応用調査専門委員会編, “進化技術ハンドブック,” 近代科学社, 2010.
- [43] S. Kirkpatrick, et al., “Optimization by simulated annealing.” *science*, vol. 220, No. 4598, pp. 671-680 ,1983.
- [44] J. Kennedy, et al. “Particle swarm optimization.” Proceedings of ICNN'95-International Conference on Neural Networks. Vol. 4. IEEE, 1995.
- [45] 金森 敬文他, “機械学習のための連続最適化,” 講談社, 2019.
- [46] L .J. Eshelman, et al, “Real-coded genetic algorithms and interval-schemata.” *Foundations of genetic algorithms*. Vol. 2 ,pp. 187-202, 1993.
- [47] 小林重信. “実数値 GA の新展開”, 特集進化計算の新展開. システム/制御/情報, vol. 52, no. 10, pp. 354-361, 2008.

- [48] 佐藤 他, “遺伝的アルゴリズムにおける世代交代モデルの提案と評価.” 人工知能学会誌, vol. 12, no. 5, pp. 734-744, 1997.
- [49] L. A. Rastrigin, “Systems of extremal control.” Mir, Moscow, 1974.
- [50] N. Srinivas, et al, “Multiobjective optimization using nondominated sorting in genetic algorithms.” *Evolutionary computation*, vol. 2, no. 3, pp. 221-248, 1994.
- [51] K. Deb, et al. “A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II,” *IEEE Transactions on evolutionary computation*, vol. 6, no. 2, pp. 182-197, 2002.
- [52] K. Deb, “Construction of Test Problems for Multi-Objective Optimization,” Proceedings of the Genetic and Evolutionary Computation Conference, pp. 164-171, 1999.
- [53] M. P. Bendsoe. “Optimal shape design as a material distribution problem.” *Structural optimization*, vol. 1, no. 4, pp. 193-202, 1989.
- [54] M. P. Bendsoe, N. Kikuchi, “Generating optimal topologies in structural design using a homogenization method,” 1988.
- [55] 武田洋次 他, “埋込磁石同期モータの設計と制御,” オーム社, 2001.
- [56] 電気学会・センサレスベクトル制御の整理に関する調査専門委員会, “ACドライブシステムのセンサレスベクトル制御,” オーム社, 2016.
- [57] Technical report of the institute of electrical engineering of Japan, *industry application society*, No. 776, 2000.
- [58] S. Sato, T. Sato, H. Igarashi, “Topology Optimization of Synchronous Reluctance Motor Using Normalized Gaussian Network,” *IEEE Transactions on Magnetics*, vol. 51, Issue 3, 2015, Art. 8200904.
- [59] Y. Otomo, H. Igarashi, Y. Hidaka, T. Komatsu, M. Yamada, “3-D Topology Optimization of Claw-Pole Alternator Using Gaussian-Basis Function With Global and Local Searches,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2952205, 2020.
- [60] T. Mori, H. Igarashi, “Topology optimization of wideband array antenna for microwave energy harvester,” *International Journal of Applied ElectroMagnetics and Mechanics*, vol. 52, no. 1-2, pp. 631-639, 2016.
- [61] K. Itoh, H. Nakajima, H. Matsuda, M. Tanaka, H. Igarashi, “Development of Small Dielectric Lens for Slot Antenna Using Topology Optimization with Normalized Gaussian Network,” *IEICE Transactions on Electronics*, vol. E101-C, no. 10, 2018.
- [62] H. Sasaki, H. Igarashi, Topology Optimization Using Basis Functions for Improvement of Rotating Machine Performances, *IEEE Transactions on Magnetics*, vol. 54, no. 3, Art. no. 8201504, 2018.

- [63] 佐々木秀徳, 五十嵐一, "フーリエ級数を用いた IPM モータのトポロジー最適化," 電気学会論文誌 B, vol. 137, no. 3, pp.245-253, 2017.
- [64] X. K. Gao, et al. "Robust design for torque optimization using response surface methodology," *IEEE Transactions on Magnetics*, vol. 38, No. 2, pp.1141-1144, 2002.
- [65] Y. K. Choi, H. S. Yoon, and C. S. Koh, "Pole-shape optimization of a switched-reluctance motor for torque ripple reduction," *IEEE Transactions on Magnetics*, vol. 43, No. 4, pp. 1797-1800, 2007.
- [66] S. I. Nabeta, et al. "Mitigation of the torque ripple of a switched reluctance motor through a multiobjective optimization," *IEEE Transactions on Magnetics*, vol. 44, No. 6, pp.1018-1021, 2008.
- [67] J. B. Kim, K. Y. Hwang, and B. I. Kwon, "Optimization of two-phase in-wheel IPMSM for wide speed range by using the Kriging model based on Latin hypercube sampling," *IEEE Transactions on Magnetics*, vol. 47, No. 5, pp. 1078-1081, 2011.
- [68] J. W. Bandler, et al., "Space mapping technique for electromagnetic optimization," *IEEE Transactions on Microwave Theory and Techniques*, vol.42, No. 12, pp. 2536-2544, 1994.
- [69] 佐々木秀徳, 五十嵐一, "深層学習を用いた回転機のトポロジー最適化-基礎的検討," 電気学会研究会資料, SA-17-081, RM-17-112, pp.83-88, 2017.
- [70] 佐藤孝洋, 藤田真史, "機械学習を援用した電気機器の最適化に関する検討," 電気学会研究会資料, vol.116, pp.289-294, 2016.
- [71] 小高知宏, "機械学習と深層学習," オーム社, 2016.
- [72] 斎藤康毅, "ゼロから作る Deep Learning-Python で学ぶディープラーニングの理論と実装," オーム社, 2016.
- [73] 岡谷貴之, "画像認識のための深層学習," 人工知能学会誌 vol.28.6, pp.962-974, 2013.
- [74] 麻生英樹, "多層ニューラルネットワークによる深層表現の学習," 人工知能学会誌, vol. 28, No. 4, pp. 649-659, 2013.
- [75] X. Glorot, et. al, "Deep sparse rectifier neural networks." Proceedings of the fourteenth international conference on artificial intelligence and statistics, pp. 315-323, 2011.
- [76] Y. LeCun, et al. "Gradient-based learning applied to document recognition." Proceedings of the IEEE, vol. 86, no. 11, pp. 2278-2324, 1998.
- [77] BT. Polyak, "Some methods of speeding up the convergence of iteration methods." ,*USSR Computational Mathematics and Mathematical Physics*, vol. 4, no. 5, pp. 1-17, 1964.

- [78] T. Tieleman, and H. Geoffrey. “Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude.” *COURSERA: Neural networks for machine learning*, vol. 4, no. 2, pp. 26-31, 2012.
- [79] J. Duchi, E. Hazan, Y. Singer, “Adaptive subgradient methods for online learning and stochastic optimization.” ,*Journal of machine learning research*, vol. 12, no. 7, 2011.
- [80] Simonyan, Karen, and Andrew Zisserman. , “Very deep convolutional networks for large-scale image recognition.” arXiv preprint arXiv:1409. 1556, 2014.
- [81] J. Deng, et al. “Imagenet: A large-scale hierarchical image database.” 2009 IEEE conference on computer vision and pattern recognition, pp. 248-255, 2009.
- [82] J. Asanuma, S. Doi, H. Igarashi, “Transfer Learning through Deep Learning: Application to Topology Optimization of Electric Motor,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2956849, 2020.
- [83] ”keras documentation, ” <https://keras.io/>
- [84] T. Shimotani, H. Igarashi, E. Hashimoto, H. Imanari, “Equivalent Circuit Allowing Loss Separation Synthesized From Field Computations: Application to Induction Heating,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2948570, 2020.
- [85] 樋口 剛 他, “交流モータの原理と設計法,” 科学情報出版株式会社, 2017.
- [86] 小林貴彦, 他, “集中巻 IPMSM のホール配置による振動低減,” 電気学会論文誌 D (産業応用部門誌), vol124, No.2, pp.202-207, 2014.
- [87] Y. Otomo, H. Igarashi, Y. Hidaka, T. Komatsu, M. Yamada, “3-D Topology Optimization of Claw-Pole Alternator Using Gaussian-Basis Function With Global and Local Searches,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2952205, 2020.
- [88] K. Yamazaki, et al. “Reduction of inverter carrier harmonic losses in interior permanent magnet synchronous motors by optimizing rotor and stator shapes, ” *IEEE Transactions on Industry Applications*, vol. 55, no. 1, pp. 306-315, 2018.
- [89] G. Riccardo, et al. “A survey of methods for explaining black box models.” *ACM computing surveys (CSUR)*, vol. 51, no. 5, pp. 1-42, 2018.
- [90] M. Ribeiro, Marco Tulio, S. Sameer, and G. Carlos. “Why should I trust you?” Explaining the predictions of any classifier,” Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, pp. 1135-1144, 2016.

- [91] S. Lundberg and S. Lee. “A unified approach to interpreting model predictions,” *Advances in neural information processing systems*, p. 4765-4774, 2017.
- [92] P. Koh and L. Percy, “Understanding black-box predictions via influence functions,” *arXiv preprint arXiv:1703.04730*. 2017.
- [93] R. Selvaraju, M. et al. “Grad-cam: Visual explanations from deep networks via gradient-based localization.” In *Proceedings of the IEEE international conference on computer vision*, pp. 618-626, 2017.

研究業績

学位関連論文 (査読付学会誌)

1. 佐々木秀徳, 五十嵐一, “フーリエ級数を用いたIPMモータのトポロジー最適化,” 電気学会論文誌B, vol. 137, no. 3, pp.245-253, 2017.
2. H.Sasaki, H.Igarashi, “Topology Optimization Using Basis Functions for Improvement of Rotating Machine Performances,” *IEEE Transactions on Magnetics*, vol. 54, no. 3, Art. no. 8201504, 2017.
3. H.Sasaki, H.Igarashi, “Topology Optimization of IPM Motor with Aid of Deep Learning,” *International Journal of Applied Electromagnetics and Mechanics*, Vol. 59, No. 1, pp. 87-96, 2019.
4. H.Sasaki, H.Igarashi, “Topology Optimization Accelerated by Deep Learning,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2901906, 2019.
5. 佐々木秀徳, 日高勇氣, 五十嵐一, “深層学習を用いたトポロジー最適化-同時および追加学習の比較”, 電気学会論文誌B, vol. 140, no. 12, 2020.

学位関連論文 (査読付国際会議プロシーディング)

1. H. Sasaki, S. Furui, H. Igarashi, H. Sakamoto, T. Abe, K. Ogura, “Regularized Topology Optimization of IPM Motors and Post-Processing for Interpretation of Optimal Solutions”, CEFC2016, MP062-4, Miami in USA, Nov., 2016.
2. Hidenori Sasaki, Hajime Igarashi, “Shape Fitting and Optimization of Rotating Machines Using Basis Function Methods,” IGTE2016, PI-7, Graz in Austria, Sep., 2016.
3. H. Sasaki, H. Igarashi, “Topological Optimization Using Basis Functions for Improvement of Rotating Machine Performances,” Compumag2017, PA-A4-12, Daejeon, Korea, June, 2017.
4. H. Sasaki, H. Igarashi, “Topology Optimization of Rotating Machines Using Multi-Step NGnet-based Method,” ISEM2017, O-SOC-2:5, Chamonix-Mont-Blanc, France, September, 2017.

5. H. Igarashi, H. Sasaki, “Topology Optimization Accelerated by Deep Learning,” CEFC2018, TAO3-4, Hangzhou, China, October, 2018.
6. H. Sasaki, Y. Hidaka, T. Tanaka, K. Ito, H. Igarashi, “Explainable Deep Neural Network for Design of Electric Motors,” CEFC 2020, 353, Pisa, Italy, November, 2020.

その他論文 (査読付学会誌)

1. S. Doi, H. Sasaki, H. Igarashi, “Multi-Objective Topology Optimization of Rotating Machines Using Deep Learning,” *IEEE Transactions on Magnetics*, DOI:10.1109/TMAG.2019.2899934, 2019.

学位関連講演 (国内会議)

1. 佐々木秀徳, 五十嵐一, ガウス基底を用いた回転機フラックスの形状最適化, 平成28年度電気学会産業応用部門大会, Y-102, 群馬, 8月, 2016年.
2. 佐々木秀徳, 五十嵐一, 基底関数を用いた回転機のトポロジー最適化, 電気学会静止器回転機合同研究会, SA-16-111, RM-16-157, 沖縄, 9月, 2016.
3. 佐々木秀徳, 五十嵐一, IPMモータのトポロジー最適化における形状変化, 平成28年度電気・情報関係学会北海道支部連合大会, OS-11, 札幌, 11月, 2016.
4. 佐々木秀徳, 五十嵐一, 非線形磁気特性を考慮した回転機のトポロジー最適化, 非線形問題の解法に関する研究会, 9, 岐阜, 1月, 2017.
5. 佐々木秀徳, 五十嵐一, ガウス基底関数を用いたシンクロナスリラクタンスモータの既存形状トポロジー最適化, 計算力学講演会, OS24-1-145, 大阪, 9月, 2017.
6. 佐々木秀徳, 五十嵐一, 深層学習を用いた回転機のトポロジー最適化 - 基礎的検討, 電気学会静止器回転機合同研究会, SA-17-081, RM-17-112, 佐賀, 9月, 2017.
7. 佐々木秀徳, 五十嵐一, 深層学習によるトポロジー最適化の高速化 - 基礎的検討, 電気・情報関係学会北海道支部連合大会, 4, 函館, 10月, 2017.
8. 佐々木秀徳, 五十嵐一, 深層学習を用いた回転機のトポロジー最適化 - 第二報, 電気学会静止器回転機合同研究会, SA-18-021, RM-18-021, 東京, 1月, 2018.
9. 五十嵐一, 佐々木秀徳, AI技術と高精度電磁界解析を用いた最適設計, 平成30年電気学会全国大会シンポジウム講演「電気機器設計に役立つ数値解析技術の最前線」, 福岡, 3月, 2018.
10. 佐々木秀徳, 日高勇気, 田中敏則, 伊藤一将, 大友佳嗣, 五十嵐一, 深層学習における追学習手法に関する検討, 電気学会静止器回転機合同研究会, SA-19-078, RM-19-098, 三重, 9月, 2019.

研究業績

11. 佐々木秀徳, 日高勇氣, 田中敏則, 伊藤一将, 五十嵐一, 説明可能 AI を援用した回転機のトポロジー最適化手法:基礎検討, 電気学会静止器回転機合同研究会, SA-20-020, RM-20-020, 宮城, 1月, 2020.
12. 佐々木秀徳, 日高勇氣, 有田秀哲, 伊藤一将, 五十嵐一, 磁界分布を用いた回転機トルク性能の深層学習-基礎検討, 電気学会静止器回転機合同研究会, SA-20-060, RM-20-084, web 開催, 9月, 2020.

特許

1. 形状最適化結果表示方法及びその装置, 特願 2017-223830, 出願日:平成 29 年 11 月 21 日
2. 形状最適化結果表示方法及びその装置, 特願 2017-223831, 出願日:平成 29 年 11 月 21 日
3. 形状最適化結果表示方法及びその装置, 特願 2018-014417, 出願日:平成 30 年 1 月 31 日

受賞

1. 「電気学会優秀論文賞 B 賞」受賞 2018 年 2 月 6 日
2. 「精密工学会北海道支部学生奨励賞」受賞 2018 年 3 月 25 日

謝辞

本研究を遂行するにあたり、多くの方々にお世話になりました。ここに深く感謝の意を表します。

まず、7年間の研究生活におきまして終始暖かい激励とご指導をいただきました。北海道大学大学院情報科学院 五十嵐一教授に心より感謝を申し上げます。五十嵐教授には学部在籍時より私に様々な機会を与えていただき、研究をはじめとして様々なご助言をいただきました。研究の進め方が未熟な私に様々な場面で指針を示していただきました。これまでの経験は現在の職務を遂行するきっかけを作っています。また、博士課程在籍中は遠方にもかかわらず、何度も打ち合わせをさせていただき、密に議論をさせていただきました。心より感謝申し上げます。

また、北海道大学大学院情報科学院 野口聡准教授には学部在籍時より多くの研究に関するご助言をいただきました。学会参加時にも様々なご助言をいただき、生活の指針となりました。心より感謝申し上げます。

北海道大学大学院情報科学院 小笠原 悟司教授、北 裕幸教授には論文に関し非常に有益なご助言をいただきました。心より感謝申し上げます。

北海道大学大学院工学研究院工学系技術センター 技術部 第三技術室 情報技術支援班 技術専門職員の 今井適氏には計算機環境整備にご尽力いただきました。計算機不具合の際には、早急に対応してくださいました。ここに厚く御礼を申し上げます。また、遠隔のやり取りにも関わらず円滑に事務処理をしていただきました事務補佐員の斎藤尚代女氏に厚く御礼申し上げます。

本研究の実施にあたりまして、三菱電機株式会社先端技術総合研究所の日高勇氣氏には日々多くのご助言をいただきました。本研究は日高氏のご助言なく成し遂げることができませんでした。また、三菱電機株式会社先端技術総合研究所の北尾純士氏には博士課程における数々のご助言をいただきました。日高氏、北尾氏のご助言は博士課程進学における道しるべとなりました。ここに厚く御礼を申し上げます。

さらに、三菱電機株式会社先端技術総合研究所電機システム技術部の皆様には博士課程進学にあたり多大な理解をいただきました。特に元電機技術部門統轄部長 大穀晃裕氏、現電機システム技術部長 佐藤 伸治氏、元電機システム技術部次長 山田 正樹氏、元機構制御モータ技術グループ課長 山本 和男氏、田中 敏則氏、現機構制御モータ技術グループ課長 有田 秀哲氏には学会発表に際して様々なお手数をおかけし、数々のご助言をいただきました。ここに厚く御礼を申し上げます。

また、修士課程修了後も学会、プライベート等の機会に数々のご助言をいただき、私を支えてくださいました北海道大学大学院情報科学院電磁工学研究室の先輩、後輩の皆様にも厚くお礼申し上げます。特に先輩であります東芝エネルギーシステムズ株式会社 佐藤 孝洋氏、日本テキサス・インスツルメンツ合同会社 佐藤 佑樹氏、東芝三菱電機産業システム

株式会社 下谷 俊人氏には博士課程における様々なご助言をいただきました。プライベートにおいても様々なご助言をいただき、心より感謝申し上げます。また、後輩であり博士課程学生である大友 佳嗣氏，比留間 真悟氏，株式会社富士通研究所 丸尾 明人氏には修士課程時代から今まで，プライベートでも充実した時間を過ごさせていただきました。さらに，現修士課程学生である浅沼 丈氏，佐藤 駿輔氏には研究におけるご助言をいただきました。ここに厚く御礼申し上げます。

最後に，大学院博士課程進学に関し，躊躇なく受け入れてくださり，遠方ながらありとあらゆる場面で私を暖かく見守り続けてくださいました両親，陰ながら応援してくださいました弟，妹，両祖母，そして亡き祖父に深く感謝いたします。

2021年2月
佐々木 秀徳