

AIを用いたモータ設計技術の研究

Research on Motor Design Technology Using AI

山田 奈央※
Nao Yamada
平手 宏昌※
Hiromasa Hirate
片平 洋一※
Yoichi Katahira

1. はじめに

現在、ブラシレスDCモータのモータコア設計には、有限要素法による磁場解析が広く用いられている。最適形状を探索する際、有限要素解析(以下、FEA)を繰り返し実施する必要がある、計算時間の長期化が課題となっている。この課題の解決方法として、近年、機械学習や深層学習を活用した「代理モデル」による高速設計探索が注目されている^{(1),(2)}。そこで、当社でも、代理モデルを活用した自動設計技術の研究を実施した。



図1 代理モデルとは

表1 対象モータの仕様⁽³⁾

項目	値
極数	4
スロット数	24
ターン数/相	140
ステータ外径	112
ロータ外径	55
積厚	60




図2 対象モータの外形図

2. 自動設計システム

2.1 対象モータの仕様

本研究では、電気学会のベンチマークモデルとされている4極24スロット分布巻きの埋込型永久磁石同期モータを対象とした。また、ステータ形状、体格、使用材料は固定し、ロータ形状の最適化を行った。

表1に対象モータの仕様、図2に外形図を示す。

2.2 システムの概要

代理モデルとは、複雑なCAEシミュレーション(本研究ではFEA)の代替として、機械学習や深層学習を活用し、現象を予測できる数理モデルである。代理モデルを活用することで、最適形状探索に伴う計算コストを大幅に削減し、効率的な設計空間探索が可能となる。

本研究において最適形状を得るまでの一連のプロセスを図3に示す。このプロセスは「学習データの作成」、「代理モデルの構築」および「最適化」の3ステップで構成されている。

まず第1ステップでは、変数とする寸法および運転条件を決め、それぞれの上下限値を設定する。これらの条件を満たす形状を学習に必要な数だけ生成し、FEAを実施する。全ケースの形状パラメータ、運転条件、解析結果を統合し、データセットを作成する。次のステップでは、データセットを訓練、検証、テストデータに分割し、説明変数を標準化する。訓練データで各特性の回帰モデルを学習させつつ、検証データで汎化性能を確認して代理モデルを構築し、テストデータで未知データに対する精度を確認する。最後に、この代理モデルを用いて、任意の運転条件下での性能予測および最適化を行う。各ステップの詳細は次章で述べる。




図3 代理モデルを活用した最適化のフローチャート

※モータカンパニー 研究・開発センター

3. 実施内容

3.1 学習データの作成

本研究では、ロータ形状および電流、位相、回転数を変数として、48,000 ケースの形状を生成し、平均トルクおよび鉄損の値を用いて形状最適化を行った。形状の生成、解析データの取得には、JMAG-Designer 24.1 を用いた。図4に形状変数の位置、表2に運転条件を含めた各変数の上下限値を示す。

設定範囲内の寸法の組合せであっても、形状が成立しない場合がある。これを回避するため、JMAGのレンジファインダー機能を利用した。レンジファインダーは、形状が成立する変数の範囲を探索し、成立形状のみを取得する機能である。これにより、指定した48,000 ケースの成立形状が得られた。

取得した全ケースに対してFEAを実施し、トルク、ヒステリシス損失、渦電流損失を出力した。トルクの時系列データから平均トルク (T_ave) を算出し、ヒステリシス損失と渦電流損失の合計を鉄損 (P_fe) の値とした。なお、




図4 各形状変数の位置

表2 各形状変数および運転条件の上下限値

変 数 名		下限	上限	備考
寸法	d1 [mm]	0.1	10	辺 - 点
	d2 [mm]	2	3	Mg 幅
	d3 [mm]	5	14	辺 - 外径
	d4 [mm]	0.25	5	辺 - 点
	d5 [mm]	0.25	5	辺 - 点
	d6 [mm]	1	18	中心 - 点
	d7 [mm]	1	18	中心 - 点
	d8 [mm]	0.5	1.5	円弧 - 外径
運転条件	電流 [A]	0.5	2	—
	位相 [°]	0	90	—
	回転数 [min ⁻¹]	1000	4000	—

表3 得られた特性値の処理方法

項 目	表 記	処 理
平均トルク	T_ave	トルクの重み付き平均
鉄損	P_fe	ヒステリシス損失と渦電流損失の和

T_aveは端点データの偏りの影響を低減するため、式(1)で表される重み付き平均を用いて計算した。

n: データ数、 x_i : i 番目のデータ

$$T_{ave} = \frac{x_1 + x_n + 2 \sum_{i=2}^{n-1} x_i}{2(n-1)} \quad \dots (1)$$

最後に、形状変数および運転条件を説明変数、T_aveおよびP_feを目的変数としてデータセットを作成した。

3.2 代理モデルの作成

本研究では、ニューラルネットワーク⁽⁴⁾による回帰を用いて代理モデルを構築した。

まず、作成した全データセットを、6:2:2の比率でランダムに訓練、検証、テストデータに分割した。スケール差による学習の不安定性を低減するため、説明変数に対し、平均を0、分散を1とする標準化を行った。

続いて、訓練データを用いて、scikit-learnのMLPRegressorにより代理モデルを作成した。機械学習モデルの性能は、学習プロセスを制御する変数に大きく依存する。この変数はハイパーパラメータと呼ばれ、学習によって最適化されるものではないため、事前に適切に設定する必要がある。本研究では、ハイパーパラメータ最適化フレームワークであるOptuna⁽⁵⁾を使用し、最適化を行った。隠れ層の構成や学習率など、表4に示したハイパーパラメータを対象とし、探索と評価を繰り返して最適な組合せを決定した。

学習時の評価指標として、二乗平均平方根誤差(Root Mean Squared Error、以下、RMSE)を使用した。RMSEを式(2)に示す。過度な学習により、訓練データへの適合度は向上する一方で、未知データに対する損失が増加することがある。この現象を過学習という。過学習を防ぎ、モデルの汎化性能を確保するため、検証データのRMSEが一定期間改善しない場合に学習を終了した。

n: データ数、 y_i : 正解値、 $\hat{y}_i$: 予測値

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \dots (2)$$

表4 ハイパーパラメータの探索範囲

ハイパーパラメータ名	[範囲] または {選択肢}
Number of hidden layers	[1, 4]
Sizes of hidden layers	[4, 64]
activation	{relu, tanh, logistic}
alpha	[1e-4, 1e-1]
batch_size	{32, 64, 128}
learning_rate	{constant, invscaling, adaptive}
learning_rate_init	[1e-5, 1e-2]
beta_1, beta_2	[0.8, 0.999]
epsilon	[1E-10, 1E-7]

最後に、完成した代理モデルについて、訓練データおよびテストデータの解析値と予測値のプロットにより、モデルの精度を確認した。

3.3 最適化の問題設定

本研究では、目的関数を平均トルク最大化、および鉄損最小化として、多目的最適化を行った。運転条件は、電流を1 A、回転数を1500 min⁻¹に固定した。

最適化アルゴリズムは、多目的遺伝的アルゴリズムの一種であるNSGA-II⁽⁶⁾(Non-dominated Sorting Genetic Algorithms II)を用いた。集団サイズを40、子孫の数を40、終了世代を50に設定し、初期個体をラテン超方格サンプリング(Latin Hypercube Sampling、以下、LHS)により生成して最適化を実行した。なお、最適化の過程では、レンジファインダーを通さないため、形状不成立の個体が出力される可能性がある。その場合には、制約条件の追加や最適化パラメータの変更を行った。それでも形状不成立の個体が多く出力された場合は、形状成立を判定する機械学習モデルを別途構築し、これを制約条件に組み込んだ。これらのモデルの詳細について以下に記す。

最後に、目的関数のバランスが異なる最適解の集合であるパレートフロントから、最適形状を選択した。

(1) 異常検知モデル：モデルの適用範囲⁽²⁾

モデルの適用範囲(Applicability Domain、以下AD)とは、学習データに基づいて信頼できる予測が可能な領域のことである。本研究では、One-Class Support Vector Machine⁽⁴⁾(OCSVM)を用いてADを定義する。OCSVMは、正常データのみから学習を行う教師なし学習であり、学習データの分布を囲うように境界を構築する手法である。異常値の検出や、データ密度の推定などに広く用いられている。

新しい入力が構築した境界内に含まれる、すなわちAD内に属する場合、この予測結果は信頼できると判断される。一方、境界外の場合は、学習データから外挿した領域に属するため、予測の信頼性は低いと判断される。OCSVM

のハイパーパラメータ ν を適切に設定することで、学習データに対して、外れ値として扱うサンプルの上限割合を調整できる。 ν を大きくするとADが狭くなり、異常と判定される学習データが増加する。

(2) 2クラス分類モデル：領域の成立判定

JMAGのモデルでは、領域自体や領域間で輪郭が交差した場合、その領域は不正とされ、面積が0または重複した値として出力される。これを利用して分類モデルを構築し、形状の成立判定を行った。

寸法データをLHSによりランダムに5,000ケース作成し、各ケースのロータコアおよびフラックスバリアの面積を出力した。その結果、ロータコアでは1,594ケース、フラックスバリアでは1,651ケースにおいて、形状が不成立であった。ロータコア面積は自身の形状崩壊時に、フラックスバリア面積はロータコアの形状崩壊およびマグネットとコアの干渉時に不正となる。不正領域が確認されたケース、すなわちNGケースには1、正常なケースには0をラベリングし、寸法データと合わせてデータセットとした。このデータセットを8:2の比率でランダムに訓練データとテストデータに分割し、scikit-learnのMLPClassifierにより、ロータコア形状成立判定モデル(以下、SV_Rt)およびフラックスバリア形状成立判定モデル(以下、SV_FB)の2種類の分類モデルを構築した。OK/NGの判定閾値をTHとし、モデルが出力する分類確率がTH以下となる場合にOKと判定されるよう、制約条件を設定した。

3.4 解析および最適化結果

(1) 学習データの作成

説明変数の分布をヒストグラムにより確認した(図5)。運転条件の3項目は偏りなく分布していた。一方、寸法については、特にd3、d5、d6、d7において大きな偏りが見られた。これは、形状不成立の個体がレンジファインダーによって除外されたためである。また、データセットの作成に要した時間は約36時間であった。




図5 各説明変数のヒストグラム(Amp：電流、Beta：位相、RPM：回転数)

(2) 代理モデルの作成

作成した代理モデルの学習過程を図6に示す。学習の進行に伴い、訓練データおよび検証データに対するRMSEは同様の挙動を示しながら減少し、0に近づいた。したがって、目的変数をT_ave、P_feとする各モデルで、過学習は認められなかった。また、各モデルはそれぞれ102、295エポックで学習が早期終了した。

代理モデルの解析値と予測値のプロットを図7に示す。また、RMSEに加え、式(3)および式(4)で表される、決定係数 R^2 および平均絶対誤差(Mean Absolute Error、以下MAE)の算出結果を表5に示す。

n : データ数、 y_i : 正解値、 $\hat{y}_i$: 予測値、 $\bar{y}$: 正解データ平均

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \dots (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \dots (4)$$

訓練データおよびテストデータのいずれにおいても、解析値と予測値はおおよそ傾き1の直線状に分布した。ただし、P_feのモデルにおいて、高値領域で予測精度の低下が確認された。これは、学習データの分布(図8)が、小さ




図6 各代理モデルの学習曲線 (RMSE)




図7 解析値と代理モデルによる予測値の関係

表5 各代理モデルの精度 (R^2 、RMSE、MAE)

評価指標	T_ave		P_fe	
	train	test	train	test
R^2	0.999	0.999	0.999	0.998
RMSE	0.011	0.012	0.465	0.574
MAE	0.008	0.008	0.321	0.366

い値に偏っており、高値領域に対応する学習データが著しく不足していることに起因すると考えられる。この領域の値を用いて最適化を行う際には、学習データの追加などの対応が必要である。

以上より、本研究においては十分な精度を有する代理モデルが構築できたと判断される。また、代理モデルの構築に要した時間は、約1.5時間であった。

(3) 最適化

はじめに、形状成立判定を制約条件に含めず、T_aveの最大化およびP_feの最小化を目的関数とした最適化を実施した。実際は成立しない形状の特性を代理モデルが予測し、良化方向に進んだと判断され、最適化が過剰に進行した(図9)。その結果、最終世代である第50世代で得られた全ての形状が、ロータコアの形状崩壊により不成立であった。

そこで、ADおよび領域成立判定の分類モデルを作成した。ADのパラメータは $\nu = 0.3$ とし、学習データとして3.2節で構築した代理モデルの学習データからランダムに抽出した5,000ケースを用いた。ADおよびSV_FB、SV_Rtの混同行列および正解率を表6に示す。なお、SV_FBおよびSV_RtのOK/NGの判定閾値THは0.5とした。その結果、ADでは70 %、SV_FBおよびSV_Rtではそれぞれ約95 %の精度で、形状成立を判定可能なモデルが構築された。これらのモデルの作成に要した時間は、各40秒程度であった。

次に、これらの形状成立判定モデルの効果を確認するため、各モデルの判定結果を制約条件に含めた最適化を実施した。最適化に要した時間は、1回あたり1秒未満であった。最適化の進行評価指標には、ハイパーボリューム(以下、HV)を用いた。HVとは、基準点およびパレートフロントで囲まれた空間の体積(2次元の場合は面積)を指す。最適化後の成立数およびT_ave = 0、P_fe = 30を基準点としたHVを表7に、各最適化で得られたパレートフロントを図9




図8 各目的変数のヒストグラム

表6 各形状成立判定モデルの精度

モデル	AD ($\nu = 0.3$)	SV_FB (TH = 0.5)	SV_Rt (TH = 0.5)
	Pred NG / OK	Pred NG / OK	Pred NG / OK
Actual NG	242 / 89	267 / 32	284 / 29
Actual OK	205 / 464	14 / 687	16 / 671
Accuracy	0.706	0.954	0.955

表7 各形状成立判定モデルを用いた最適化結果

モデル	AD	SV_FB	SV_Rt
パラメータ	$\nu = 0.3$	TH = 0.5	TH = 0.5
成立数	4	24	3
HV	13.93	22.74	12.51




図9 形状成立判定モデルを適用した最適化結果

に示す。実施した3パターンの最適化いずれにおいても、過剰な進行は抑制された。特にSV_FBを制約条件として設定した最適化では、鉄損が負になるケースは3ケースのみであり、成立数も高いことから、SV_FBの設定の有効性が高いことが確認された。以上より、THや ν の値を調整しつつ、SV_FBを主軸としてSV_RtおよびADを組み合わせた制約条件で、最適化を実施する方針とした。

この方針に従い、条件を変えながら複数の試行を実施し、成立数およびHVが大きかった3条件をそれぞれopt1、opt2、opt3として表8に示す。また、各最適化によって得られたパレートフロントを図10に示す。各形状成立判定モデルは、適切なパラメータを設定し、組み合わせて制約条件に組み込むことで、形状崩壊を効果的に抑制することが確認された。opt1では、SV_FBとSV_Rtを用いており、他2条件と比較して成立数は36 (成立率90 %)と最も少ないものの、HVは23.19と最も大きく、最も最適化が進行した。一方、opt2ではADとSV_FBを用いており、すべての形状が成立した(成立率100 %)が、HVは22.98に減少した。図10より、opt2のパレートフロントは、他2条件と比較して最大点が小さく、さらに最小点付近では鉄損の予測値が負となっていることが確認できる。前者の要因としては、ADの ν の値が0.1と比較的大きいため、高値領域の形状が除外されたことが考えられる。また、後者に起因して、 $T_{ave} < 0.2$ の範囲ではHVが実際より大きく算出されたと推察される。opt3では、3種類すべての形状成立判定モデルを用いており、成立数は37 (92.5 %)、HVは22.88であった。他2条件よりそれぞれの判定基準を緩めても、組み合わせることで同等の効果が得られたと考えられる。

続いて、最適化により得られた第50世代の形状に対し

表8 形状成立判定モデルを組み合わせた最適化結果

項目	opt1	opt2	opt3
制約条件	AD	$\nu = 0.1$	$\nu = 0.03$
	SV_FB	TH = 0.3	TH = 0.4
	SV_Rt	TH = 0.5	TH = 0.6
成立数	36	40	37
HV	23.19	22.98	22.88




図10 opt1～3で得られたパレートフロント

表9 opt1～3で得られた特性値の予測精度

評価指標	opt1		opt2		opt3	
	T_{ave}	P_{fe}	T_{ave}	P_{fe}	T_{ave}	P_{fe}
R^2	0.982	0.991	0.991	0.988	0.989	0.988
RMSE	0.039	0.743	0.024	0.716	0.031	0.807
MAE	0.034	0.675	0.022	0.514	0.026	0.615

てFEAを実施し、予測値との乖離を確認した。図11に各条件の最適化結果およびFEAによって得られた値のプロットを、表9に R^2 、RMSE、MAEの値を示す。図11より、opt1は全体的にずれがあり、opt2では $T_{ave} < 0.35$ 、opt3では $T_{ave} > 0.95$ の範囲でずれが大きいことが確認できる。表9の数値で比較すると、opt2の誤差が最も小さかった。opt1とopt3の比較では、RMSEの値だけでは優劣を判断し難いが、MAEの値からopt3の方が誤差が小さいことがわかる。これらの差は、ADの使用および ν の値に起因すると考えられる。すなわち、ADを使用、または ν を大きく設定することで、最適化によって得られる形状が、学習データの密度が高い範囲に制限されるため、予測の信頼性が向上する。その結果、ADを使用し、 ν を0.1としたopt2で、最も誤差が小さくなったと考えられる。以上より、ADを使用し、予測値とFEAの値の乖離が小さいopt2を採用することとした。

最後に、得られたパレートフロントの中から、要求仕様を満足する形状を選択する。ここでは、得られた形状のうち、図11中に示したA、B、Cの3形状およびFEAの結果を図12に示す。A、B、Cはそれぞれ、トルク重視、バランス型、鉄損重視の代表点として選定した。FEA結果より、初期形状と比較して、Aは平均トルク、鉄損ともに減少、




図11 opt1～3の最適化結果とFEAの値




図12 初期形状および最適化で得られた形状の3例

Cはともに増加した。Bは両者の中間に位置し、初期形状より平均トルクが大きく、鉄損が小さいというバランスの取れた特性を有することが確認された。

以上より、本研究で構築した代理モデルおよび形状成立判定を考慮した最適化手法により、要求仕様に応じた多様な設計解を効率的に得られることが示された。

4. まとめ

本研究では、ロータコアの最適形状の設計において、代理モデルおよび形状成立判定用いた最適化手法の有効性を確認した。構築した代理モデルにより、従来のFEAに比べて大幅に計算コストを削減しつつ、精度の高い予測が可

能であることを示した。また、本手法により、要求仕様に応じた多様な形状案を得られることを確認した。

従来のFEAを用いたモータコア設計は、解析に数日から数週間を要し、属人的な判断に依存することが多かった。一方、本手法では、一度代理モデルを作成してしまえば、高速かつ安定した最適設計を実現できる。

今後は、対象形状を拡大し、ステータ形状や当社生產品の設計にも適用した、包括的なモータ自動設計システムの開発を目指す。

最後に、本研究を行うにあたり、多大なご指導、ご協力をいただいた(株)MotorAI代表取締役社長 清水悠生氏に、心より感謝申し上げます。

参考文献

- (1) Y. Shimizu, S. Morimoto, M. Sanada, and Y. Inoue : 「Using Machine Learning to Reduce Design Time for Permanent Magnet Volume Minimization in IPMSMs for Automotive Applications」IEEE Journal of Industry Applications, Vol.10, No.15, pp. 554-563 (2021)
- (2) 清水 悠生 : 「深層生成モデルを活用したIPMSMの形状最適化におけるロバスト性向上の検討」2022年電気学会産業応用部門大会、3-68 (2022)
- (3) 電磁界解析による回転機の実用的性能評価技術調査専門委員会 : 「電磁界解析による回転機の実用的性能評価技術」電気学会技術報告、No.1244 (2012)
- (4) A. Géron (下田 (監訳)、長尾 (訳)) : 『scikit-learn、Keras、TensorFlowによる実践 機械学習 第2版』オライリー ジャパン (2022)
- (5) 柳瀬 利彦 : 「Optunaで始めるハイパパラメータ最適化」電子情報通信学会誌、Vol.104、No.7、pp.728-733 (2021)
- (6) K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan : 「A fast and elitist multiobjective genetic algorithm : NSGA-II」IEEE Transactions on Evolutionary Computation, Vol.6, No.2, pp.182-197 (2002)