

深層学習を用いた永久磁石磁化推定手法に関する基礎検討

高須, 大地 / TAKASU, Daichi

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

63

(開始ページ / Start Page)

1

(終了ページ / End Page)

7

(発行年 / Year)

2022-03-24

(URL)

<https://doi.org/10.15002/00025341>

深層学習を用いた永久磁石磁化推定手法に関する基礎検討

A FUNDAMENTAL STUDY ON ESTIMATION METHOD FOR MAGNETIZATION DISTRIBUTION IN PERMANENT MAGNET USING DEEP LEARNING

高須大地

Daichi TAKASU

指導教員 岡本吉史

法政大学大学院理工学研究科電気電子工学専攻修士課程

Since the performance of a permanent magnet synchronous motor depends on the magnetization distribution in the permanent magnet, it is essential to estimate the magnetization distribution at the previous stage of the practical design. When the magnetization is nondestructively identified by the electron back-scattered diffraction patterns or X-ray diffraction, the estimation time becomes so long. In contrast, an effective method, which is based on the minimization of the measured and calculated fluxes, has been proposed. The method based on mathematical programming has been proposed as a nondestructive estimation method. Although the method can estimate the magnetization distribution fast, this method has the possibility to derive unphysical magnetization distribution when some parameters are not adequately adjusted. Subsequently, to suppress the non-physical magnetization, an estimation method for magnetization distribution using deep learning is proposed to suppress the nonphysical magnetization. **Key Words** : *Biot-Savart law, Deep Learning, Magnetization Estimation, Nd-Fe-B Magnet*

1. はじめに

永久磁石同期モータ (PMSM: Permanent Magnet Synchronous Motor) はカーボンニュートラルの観点から様々な用途で使用され、高トルク・低振動な特性が要求されている。PMSM のトルク特性は、装荷される永久磁石の磁化配向に大きく依存する。しかし磁化配向に擾乱のある永久磁石をモータに装荷した場合、モータの振動・騒音を誘発することが懸念される^{[1], [2]}。そのため、モータの実設計における前段階で、永久磁石内部の磁化分布を事前に把握することが重要である。

永久磁石内部の磁化分布の評価方法として、結晶観察により計測する手法と、永久磁石の外部磁束密度を計測し、計測データから磁化分布を逆推定する手法が挙げられる。結晶観察に基づく手法^{[3], [4]}は、磁石を切断するなど破壊的なアプローチが含まれ、更に、計測に数日間が必要となる。他方、数値解析により磁化分布を逆推定する手法は、永久磁石を破壊することなく、数分で磁化推定が可能である。しかし、計測点上の指定された磁束密度分布を再構成するために用いる磁化分布の解が、無数に存在するという不定性が欠点として挙げられる。

磁化分布の不定性の解消に有効な手法は多岐にわたる。Tikhonov 正則化^[5]法を用いた逆問題では、正則化パラメータの設定により非物理的な分布を抑制できるが、

完全に除去することはできない。特異値分解を用いた推定手法^{[6], [7]}では、ノイズの増幅を抑えるために、非物理的な磁化分布を含む高次モードを打ち切ることで、現実的な磁化分布が推定可能である。しかし、打ち切りの見極めはエンドユーザに委ねられるため、実際の製造プロセスへの適用が困難である。また、非線形計画法を用いて最適化問題を解く推定手法^{[8], [9]}も提案されている。この手法では、磁化分布を高速に推定することが可能である。しかし、外部磁束密度の観測点が少ない状態で推定を行うと、端部における磁化推定精度が低くなるため、外部磁束密度の計測点を多くとる必要がある。そこで本稿では、深層学習^[10]を用いた、新たな磁化推定手法を提案する。あらかじめ Biot-Savart 則で生成したデータを用いて、外部磁束密度分布を入力とし、内部磁化分布を出力する深層学習モデルを構築する。深層学習へ学習させるデータを現実的な磁化分布に限定することで、ある外部磁束密度に対して、現実的な磁化分布のみが予測される DNN を構築することが可能であると考えられる。本モデルの高精度化には学習データの生成方法が重要であることから、この点について子細な検討を行った。さらに、永久磁石起因の外部磁束密度を実測し、磁化推定を行った。その際、Biot-Savart 則で生成した学習データで、学習を行った DNN が、測定誤差を含んでいる実測

された外部磁束密度データを入力しても、精度よく磁化推定をすることが可能であるか、実用的な側面から検証を行った。

2. 磁化分布推定手法

(1) Biot-Savart 則

Biot-Savart 則^[11]により生成した、永久磁石内の磁化ベクトル \mathbf{M} により、測定点における磁束密度 \mathbf{B} は次式の Biot-Savart 則より計算される。

$$\mathbf{B} = \mathbf{A}\mathbf{M} \quad (1)$$

ここで、 \mathbf{A} は、解析積分公式^[12]を用いて計算される長方形行列を示す。

(2) 永久磁石モデル

本研究では、平行配向、多極配向に着磁された二種類の Nd-Fe-B 磁石の磁化推定を目標とする。磁化推定に用いる永久磁石の寸法及びメッシュを図 1 (a) に示す。x, y, z 方向の長さは、IPM モータのベンチマークモデル (IEEJ-D モデル^[13]) に搭載された永久磁石を基準としている。分割数は x 方向に 17 分割、y 方向に 48 分割、z 方向に 2 分割し、セル数 N_c は 1632 個とした。本研究で使用する永久磁石 (品名: N50M-F) は磁化強度 1.416 T で着磁された、信越化学工業製の永久磁石である。自作の磁界測定システムを用いて、測定を行う測定点配置を図 1 (b) に示す。計測点は、永久磁石から 2 mm 離れた平面上に 1 mm 間隔に配置した。計測点数は合計 1350 点である。

図 2 に磁化が平行配向 (+z 方向) に着磁されている永久磁石内外の物理量を示す。図 2 (a) は平行配向の磁化ベクトルを示している。また、図 2 (b) は Biot-Savart 則を用いて図 2 (a) の磁化から得られる外部磁束密度を示す。次に、多極配向に着磁されている永久磁石の概要を図 3 に示す。図 3 (a) に理想的な磁化分布を示す。また、図 3 (b) は Biot-Savart 則を用いて、図 3 (a) から得られる外部磁束密度を示す。本検討ではテストデータとして本計測により得られた外部磁束密度分布を用いた。

(3) ディープニューラルネットワーク

教師あり機械学習の一つであるディープニューラルネットワーク (DNN: Deep Neural Network) を用いた磁化推定手法を提案する。DNN の概要を図 4 に示す。本検討では、Biot-Savart 則を用いて、磁化分布から得られる永久磁石外側の磁束密度 (B_x, B_y, B_z) を入力値として、磁化分布を出力する DNN を構築する。なお、第 β 層の α 番目のニューロンの持つ値 ϕ_α^β を以下の式で定義する^[14]。

$$\phi_\alpha^\beta = \sum_{\gamma}^{N_{\beta-1}} w_{\gamma}^{\beta-1} f(\phi_\alpha^{\beta-1}) \quad (2)$$

ここで、 $N_{\beta-1}$ と $w_{\gamma}^{\beta-1}$ はそれぞれ第 $\beta-1$ 層のサイズと第 $\beta-1$ 層の γ 番目のニューロン $\phi_\alpha^{\beta-1}$ と間の重みである。活性化関数はハイパボリックタンジェントを採用した。

(4) 中間層のパラメータ

DNN のハイパーパラメータを決定するため、中間層の層数やニューロン数に対してグリッドサーチを行った。グリッドサーチについて、中間層数は 5 層から 10 層、ニューロン数は、1024 から 16384 の範囲で様々な DNN を構成し、探索を行った。表 1 に示す組み合わせにおける DNN で学習を行い、損失関数が最も低くなったパラメータを採用した。本検討で採用した DNN の構造を表 2 に示す。本モデルは中間層が 10 層で構成されている。入力層のサイズは、Nd-Fe-B 磁石の外部磁束密度分布サンプリング点数に依存する。計測点 i において計測された外部磁束密度ベクトル $\mathbf{B}^i = (B_x^i, B_y^i, B_z^i)$ は 3 成分であるため、入力層 N_m のサイズは計測点数の 3 倍となる。また、出力層において要素 j の各磁化ベクトルに対して、 $\mathbf{M}^j = (M_x^j, M_y^j, M_z^j)$ が出力される。磁化ベクトルの出力数は使用するメッシュに依存する。本検討では、1632 点の磁化ベクトルで考えるため、出力層サイズを 4896 点とする。

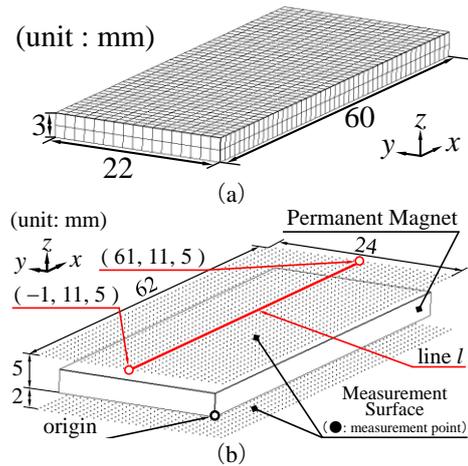


Fig. 1. Analysis model of permanent magnet. (a) Size and calculation cells. (b) Measurement points.

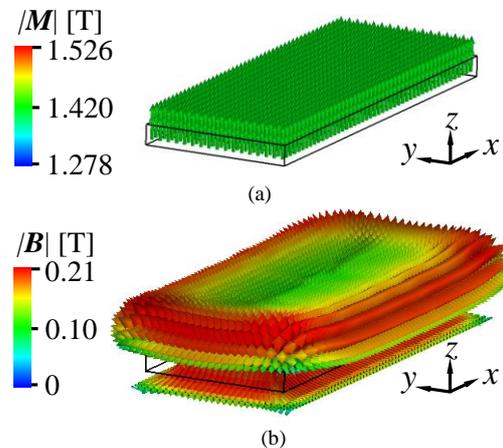


Fig. 2. Distribution of \mathbf{M} and \mathbf{B} in parallel orientation. (a) Ideal magnetization distribution. (b) Ideal magnetic flux density.

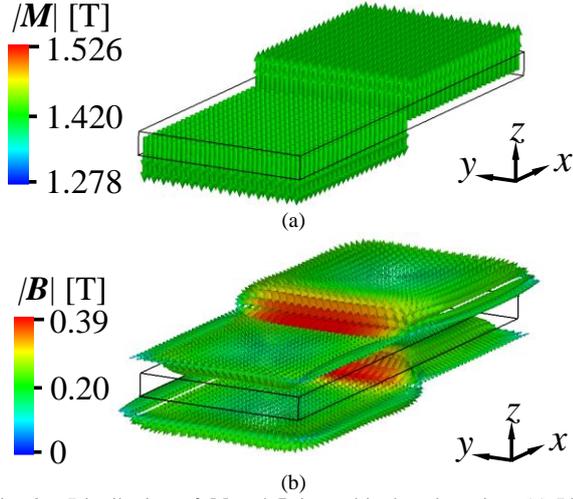


Fig. 3. Distribution of \mathbf{M} and \mathbf{B} in multipole orientation. (a) Ideal magnetization distribution. (b) Ideal magnetic flux density.

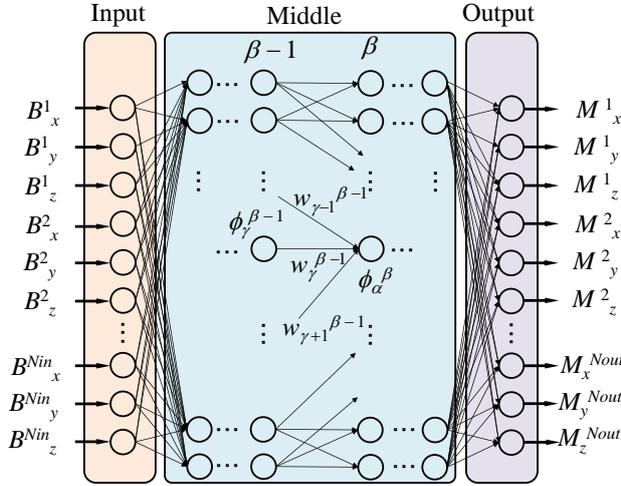


Fig. 4. Deep Neural Network

Table 1. GRID SEARCH FOR DNN

		Layer Number									
		1	2	3	4	5	6	7	8	9	10
Size		2^{10}	2^{11}	2^{12}	2^{13}	2^{14}					
		2^{14}	2^{13}	2^{12}	2^{11}	2^{10}					
		2^{10}	2^{11}	2^{12}	2^{13}	2^{13}	2^{14}	2^{14}			
		2^{10}	2^{10}	2^{11}	2^{11}	2^{12}	2^{13}	2^{14}			
		2^{10}	2^{10}	2^{11}	2^{11}	2^{12}	2^{12}	2^{13}	2^{13}	2^{14}	2^{14}

Table 2. SIZE OF DNN

Layer Number	Input	1	2	3	4	5
Size	9450	1024	1024	2048	2048	2048
Layer Number	6	7	8	9	10	Output
Size	4096	4096	8192	8192	16384	4896

(5) 学習データ生成手法

本研究では、DNNの学習データを以下に示す2つの方法で生成し、磁化推定に対する親和性を検討する。なお、以降学習データの磁化強度 \mathbf{M} は 1.416 T で統一する。一つ目の方法では、図 5 に示すような磁化角 θ に設定し

た学習データ（入力値： \mathbf{B} 、出力値： \mathbf{M} の組み合わせ）を生成する。まず、図 5 (a) に示すように、全セルで θ を統一し、 $0 \sim 360^\circ$ の範囲で 0.05° ずつ θ を変化させる。これにより、平行配向の磁化を持つ学習データが 7200 個生成される。同様に、永久磁石モデルの左右半分ずつの磁化角差が 180° になるよう $0 \sim 360^\circ$ の範囲で 0.05° ずつ θ を変化させた。その時の磁化角 θ の設定を図 5 (b) に示す。これにより、多極配向の磁化特性を補完することができる学習データが 7200 個生成される。以上の方法から、平行配向と多極配向の磁化特性を補完する合計 14400 個の学習データセットが生成される。これらの学習データを“Simple data”とする。さらに多様な磁化配向データを生成するため、フーリエ級数展開を用いて磁化角 θ を決定した学習データを作成する。一次元フーリエ級数展開により磁化角 $\theta(x)$ を以下のように定義する。

$$\theta(x) = \sum_{m=1}^{N_F} \{a_m \cos \psi_m(x) + b_m \sin \psi_m(x)\} \quad (3)$$

$$\psi_m(x) = m \frac{\pi}{h_x} (x - x_0)$$

ここで、 N_F はフーリエ級数展開の次数、 a_m と b_m は展開係数、 h_x は三角関数の一周周期長さであり、平行配向と多極配向の磁化分布を再現するという観点から 30 mm とした。また、 x 座標の原点を x_0 として、永久磁石の中心に配置した。(2) 式に基づいて学習データを生成するにあたり、標準偏差を 91.32 とした正規乱数を用いて、展開係数 a_m と b_m を $-180 \sim 180^\circ$ の範囲でランダムに変化させた。また、 N_F を $0 \sim 14$ の範囲で 1 ずつ増加させ、各 N_F 毎に 500 個のデータセットを生成した。これにより、合計 7500 個の学習データが生成された。これらの学習データを“Fourier data”とする。

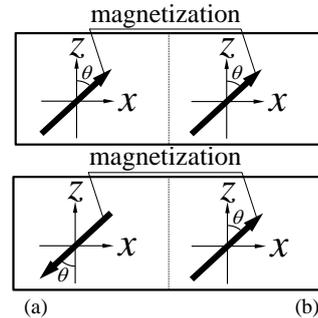


Fig. 5. Definition of magnetization angle. (a) Parallel orientation. (b) Multipole orientation.

(6) DNN の学習

学習パラメータを表 2 に示す。また、DNN を学習するための損失関数 L は以下のように定義される。

$$L = \frac{1}{N_{train}} \sum_n^{N_{train}} \|\mathbf{M}_n - \hat{\mathbf{M}}_n\|^2 \quad (4)$$

ここで、 M_n , \hat{M}_n および N_{train} はそれぞれ、データ n の全点において、対応する実際の磁化分布、推定された磁化分布および学習データ数である。DNN は L について誤差逆伝搬法^[15]を適用することで学習する。学習アルゴリズムには Adagrad^[16]を用いた。このとき、結合の重み w を更新するアルゴリズムは以下のように定義される。

$$s^t = \frac{\partial L}{\partial w^t} \quad (5)$$

$$\Delta w^t = -\frac{\eta}{\sqrt{\sum_u (s^u \odot s^u)}} \odot s^t \quad (6)$$

$$\Delta w^{t+1} = w^t + \Delta w^t \quad (7)$$

ここで、 t および $h = 1.0 \times 10^{-3}$ はそれぞれ、学習ステップおよび学習率の初期値である。ただし、 \odot はアダマール積とする。本研究では、まず、“Simple data”から200個体をランダムに抽出し、テストデータとし、残りのデータを学習データとしている。次に、“Fourier data”では、学習データとは別に、1500個体を生成しテストデータとして用いる。したがって、 N_{train} は“Simple data”と“Fourier data”でそれぞれ14200と7500に設定する。学習の際には各層で Dropout^[17]を実行した。このとき、Dropout率を0.2に設定した。また、DNNは機械学習ライブラリである Keras^[18]を用いて構築・学習を行った。

Table 3. HYPERPARAMETER FOR TRAINING

Number of data (Simple / Fourier)	14400 / 5700
Batch	32
Epoch	300

3. 計測システム

(1) 自動計測システム

前章の設定で構築した DNN は、Biot-Savat 則により生成したデータを用いて学習した。実際に本モデルを使用する際は、実測の外部磁束密度分布を入力として用いることが想定される。そこで、本モデルが実測の磁束密度分布による永久磁石内部磁化推定の可能性を検討した。図 6 に本検討で用いた自動磁界測定システムを示す。本測定システムのフレームと3つのステッピングモータは、図 6 (a) に示すように、市販の3Dプリンタ (HIC TOP 社製 型番: 3DP-26) のキットを援用したものである。本測定システムでは、永久磁石を移動板に保持し、マイクロコンピュータ (Sanguino) で3つのステッピングモータを制御することで、高精度にホールセンサを任意の計測点座標に移動させている。また、図 6 (b) は Infineon Technologies AG 社製の、TLE493-W2B6 のホールセンサである。本構成により、任意の座標で、部磁束密度を測定可能である。また、図 6 (c) はホールセンサの初期測定位置を決めるための L 型ストッパーである。可動板の

材質はアルミニウム合金 (A2017) あり、永久磁石搭載面の普通公差は ± 0.05 mm 以下で加工されている。本システムのステッピングモータの位置制御とホールセンサの同期プログラムは Python により実装した。また、本計測システムを用いて、図 2 および図 3 の永久磁石の外部磁束密度を計測した。図 7 (a), 図 7 (b) にそれぞれ、平行配向磁石と多極配向磁石の計測結果を示す。

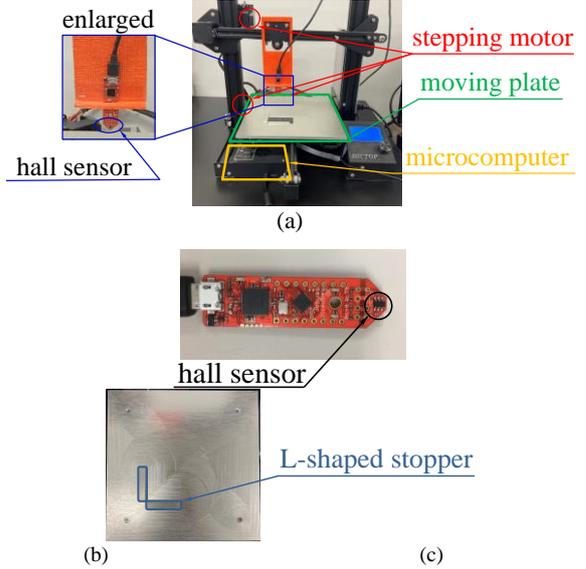


Fig. 6. Automatic measurement system. (a) Schematic diagram of system. (b) Hall sensor. (c) Moving plate.

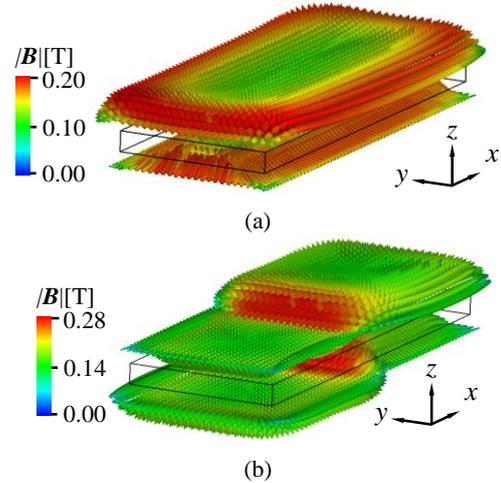


Fig. 7. Measured magnetic flux density by in-house system. (a) Parallel orientation (b) Multipole orientation.

4. 磁化推定結果

以下に示す結果は Google Colaboratory によって割り当てられた、GPU Tesla V100 SXM2 (CUDA コア数 5120, 12 GB) で実行されたものである。

(1) “Simple data”による推定結果

はじめに、“Simple data”により学習した DNN へテストデータを入力した。このとき、推定値と真値の平均二乗誤差は 4.2×10^{-4} であり、十分に精度よく推定ができている。さらに、図 2 (b) および図 3 (b) に示す平行配向と多極配向の理想的な外部磁束密度データを入力し

た際の、推定値と真値の平均二乗誤差は 3.9×10^{-4} と 6.0×10^{-4} であった。これらの結果から、“Simple data” で DNN を学習した場合、高精度に磁化分布を推定できることが確認できる。また、図 7 (a) と図 7 (b) の磁束密度分布を入力した際に出された磁化分布を図 8 に示す。図 8 (a), (b) はそれぞれ平行配向磁石、多極配向磁石の推定結果である。磁化ベクトルの大きさおよび方向は真値とほぼ一致していることが確認できる。このことから、学習データに、推定対象となる磁束密度及び磁化分布が含まれていなくても、磁化推定が可能であることが分かる。図 9 に自作の磁界測定システムから得られた磁束密度 (図 7 (a) および図 7 (b)) を DNN に入力した際の磁化分布推定結果を示す。推定された磁化ベクトルの方向は真値とほぼ一致しているが、大きさが疎らな分布となっていることが確認できる。実測には測定誤差に起因するノイズが含まれており、推定結果に影響したものと考えられる。

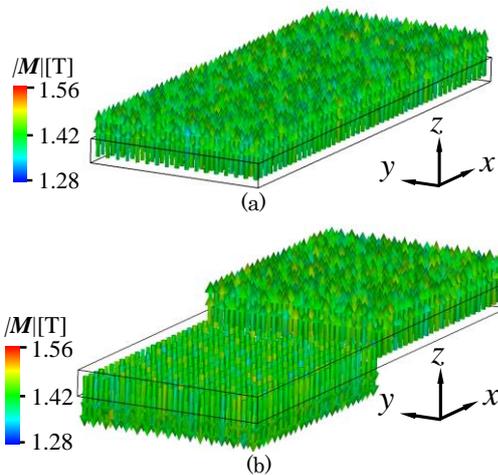


Fig. 8. Estimation results of Magnetization distribution using the DNN trained by “Simple” (input: theoretical magnetic flux density). (a) Parallel oriented magnet. (b) Multipole oriented magnet.

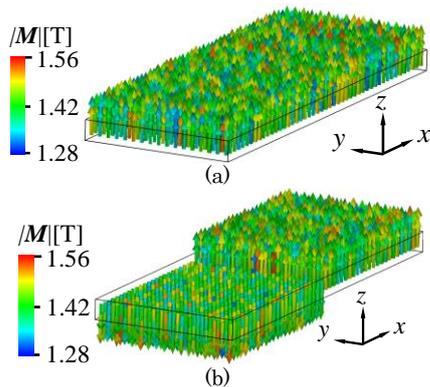


Fig. 9. Estimation results of Magnetization distribution using the DNN trained by “Simple” (input: measured magnetic flux density). (a) Parallel oriented magnet. (b) Multipole oriented magnet.

(2) “Fourier data” による推定結果

次に“Fourier data”により学習した DNN へテストデータを入力した。その結果、平均二乗誤差は 0.038 となり、“Simple data”を用いて学習をした DNN に比べて推定精度が悪化した。図 2 (b) および図 3 (b) の理想的な磁

束密度分布を入力した際に出された磁化分布を図 10 に示す。本推定値と真値の平均二乗誤差はそれぞれ 0.003, 0.114 となった。平行配向磁石の内部磁化ベクトルは、真値に近い分布になっているが、多極配向に関しては分布が大きく異なっている。特に、多極配向特有である磁化角の急激な変化が再現できておらず、端部や磁化方向が切り替わる部分の推定精度を向上させる必要がある。“Fourier data”により学習した DNN の推定精度が悪化した要因として、“Fourier data”に含まれる磁化分布が“Simple data”に比べ多様であることや、テストデータがランダムに生成したデータセットに、内包されていない可能性が挙げられる。図 11 に自作の磁界測定システムから得られた磁束密度 (図 7 (a) および図 7 (b)) を、DNN に入力した際の磁化分布推定結果を示す。図 11 (a) と図 11 (b) の推定結果と真値の平均二乗誤差はそれぞれ 0.028 と 1.612 となった。図 11 (a), (b) と図 10 (a), (b) を比較すると、図 11 (a), (b) の推定精度が低くなっていることが分かる。この精度差の原因は、測定器の測定誤差による磁束密度データの擾乱が起因していると考えられる。

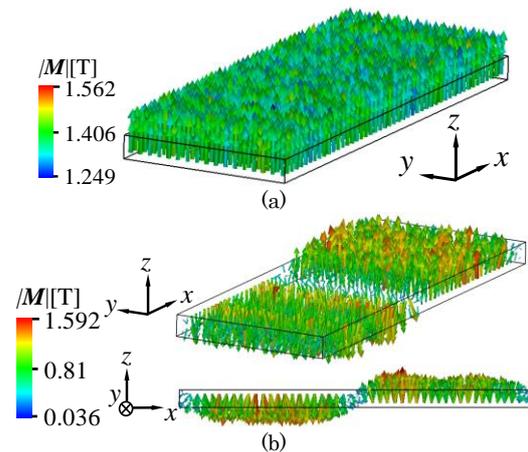


Fig. 10. Estimation results of magnetization distribution by the DNN trained by “Fourier” (input: theoretical magnetic flux density). (a) Parallel oriented magnet. (b) Multipole oriented magnet.

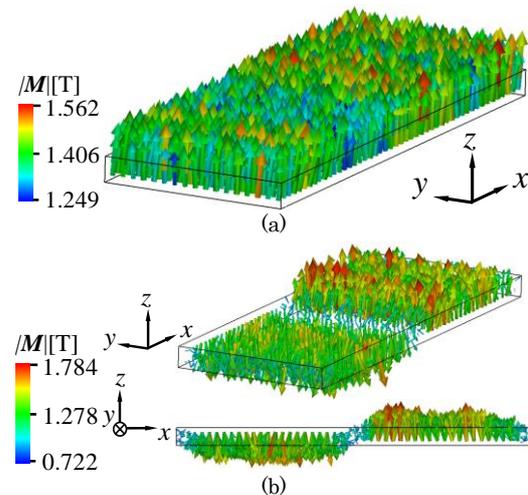


Fig. 11. Estimation results of magnetization distribution by the DNN trained by “Fourier” (input: measured magnetic flux density). (a) Parallel oriented magnet. (b) Multipole oriented magnet.

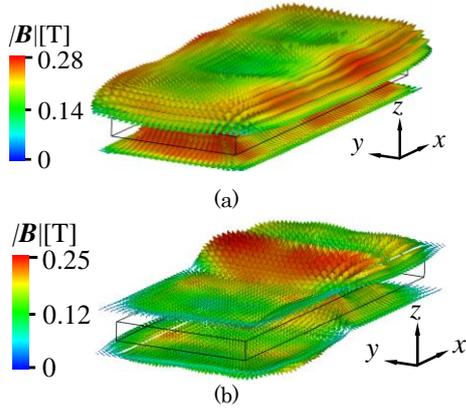


Fig. 12. Reconstructed magnetic flux density using magnetization shown in Fig. 10. (a) Parallel oriented magnet. (b) Multipole oriented magnet.

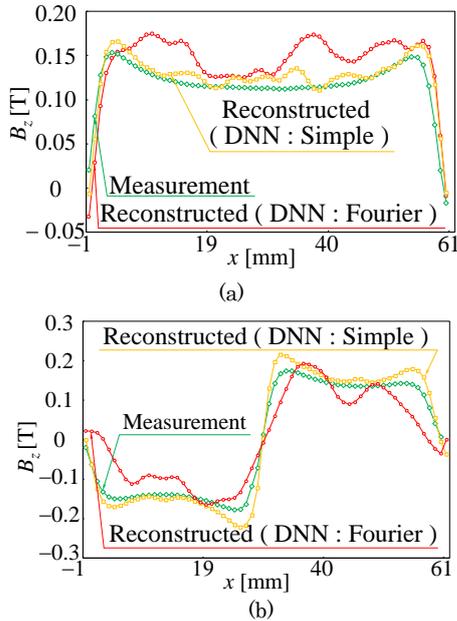


Fig. 13. Reconstructed magnetic flux density on the line l . (a) Parallel oriented magnet. (b) Multipole oriented magnet.

(3) DNNによる磁化推定結果の性能比較

図 9 および図 11 から再構成された外部磁束密度と、実測した外部磁束密度分布を、図 1 (b) の線 l 上で比較した。図 13 に、結果を示す。“Simple data”により学習した DNN を用いることで、実測に近い磁束密度分布を得られることが確認できる。一方、“Fourier data”により学習した DNN を用いることで得られる推定結果は、実測と大きく異なっており、データ生成手法や DNN モデルの改善が必要である。

5. まとめ

本論文では、入力データを磁束密度、出力データを磁化分布としたディープニューラルネットワーク (DNN) に基づく磁化推定法を提案した。提案手法により実測の測定誤差を考慮しても、非物理的な磁化分布の発生を抑制でき、さらに、目標に近い磁化分布を推定できることが明らかとなった。また、“Simple data”による推定結果が“Fourier data”による推定結果に比べて、精度が高く

推定できることが分かった。しかし、今後、様々な磁化配向に対応させていくことを考慮すると、“Fourier data”による推定精度を上げる検討や、他の関数を採用する必要である。

参考文献

- [1] M. Yousuf, F. Khan, J. Ikram, R. Badar, S. S. H. Bukhari, and J.-S. Ro, “Reduction of torque ripples in multi-stack slotless axial flux machine by using right angled trapezoidal permanent magnet,” *IEEE Access*, vol. 9, pp. 22760-22773, Feb. 2021.
- [2] G. Kucukyildiz, E. Yolacan, H. Ocak, and M. Aydin, “Detection of structural magnet defects for permanent magnet synchronous motors,” *IEEE Trans. Ener. Conv.*, 2021. (Early access article)
- [3] Y. Zhang, Y. Zhang, J. Song, X. Qi, J. Du, W. Xia, J. Zhang, A. Yan, and J. Liu, “Magnetic domain structure of $\text{Sm}(\text{Co}, \text{Cu}, \text{Fe}, \text{Zr})_x$ thick permanent magnetic films,” *IEEE Trans. Magn.*, vol. 49, no. 7, pp. 3360-3363, July 2013.
- [4] N. Kitai, Y. Matsuura, R. Ishii, M. Natsumeda, and J. Hoshijima, “Relation between $\text{Nd}_2\text{Fe}_{14}\text{B}$ grain alignment and coercive force decrease ratio in Nd-Fe-B sintered magnets,” *Hitachi Metals Technical Reviews*, vol. 30, pp. 20-27, 2014. (in Japanese)
- [5] H. Igarashi, T. Honma, and A. Kost, “Inverse inference of magnetization distribution in cylindrical permanent magnets,” *IEEE Trans. Magn.*, vol. 36, no. 4, pp. 1168-1171, July 2000.
- [6] L. Arbenza, O. Chadebec, C. Espanet, Y. Rtimi, and G. Cauffer, “Characterization of permanent magnet magnetization,” *IEEE Trans. Magn.* vol. 53, no 11, art. no. 8109504, 2017.
- [7] 菅原賢悟, 黒川卓杜, 日比野良彦, 近藤康, 矢野博幸: 「フェライト磁石の個体差分析のための磁化分布推定」, 電気学会静止器・回転機合同研究会資料, SA-18-6, RM-18-6, pp.31-35, (2018).
- [8] N. Nakamura, Y. Okamoto, K. Osanai, S. Doi, T. Aoki, and K. Okazaki, “Nondestructive estimation of magnetization distribution in permanent magnet using quasi-Newton method based on 2-D Fourier series expansion,” *IEEE Trans. Magn.*, vol. 56, no. 1, Jan. 2020, Art. no. 6700305.
- [9] N. Nakamura, Y. Okamoto, K. Osanai, S. Doi, T. Aoki, and K. Okazaki, “Magnetization estimation method for permanent magnet based on mathematical programming combined with sigmoid function,” *Proceedings of the 23rd Conference on the Computation of Electromagnetic Fields COMPUMAG 2021*, Jan. 2022 (to be published).
- [10] Y. LeCun, Y. Bengio and G. Hinton, “Deep learning”, *Nature*, vol. 521, pp. 436-444, May 2015.
- [11] N. Nakai, Y. Takahashi, K. Fujiwara, and H. Ohashi, “Estimation of magnetization distribution in a permanent magnet using genetic algorithm,” *Proc. of XVII International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF 2015)*, JP171, 2015.

- [12] 高速大規模電磁界数値解析技術調査専門委員会：「電磁界解析における高速大規模数値計算技術」，電気学会技術報告，No 1043（2016）
- [13] 回転機のバーチャルエンジニアリングのための電磁界解析技術調査専門委員会：「回転機のバーチャルエンジニアリングのための電磁界解析」，電気学会技術報告，No. 776（2000）。
- [14] L. Thomas, Manoj Kumar M V and Annappa B, "Discovery of optimal neurons and hidden layers in feed-forward Neural Network," *IEEE International Conference on Emerging Technologies and Innovative Business Practices for the Transformation of Societies (EmergiTech)*, pp. 286-291, 2016.
- [15] J. Hertz, A. Krogh, B. Lautrup and T. Lehmann, "Nonlinear backpropagation: doing backpropagation without derivatives of the activation function," *IEEE Transactions on Neural Networks*, vol. 8, no. 6, pp. 1321-1327, Nov. (1997).
- [16] J. Duchi, H. Elad and S. Yoram, "Adaptive subgradient methods for online learning and stochastic optimization." *Journal of machine learning research*, vo. 12, no. 7, (2011).
- [17] M. Rahmani and G. K. Atia, "Data Dropout in Arbitrary Basis for Deep Network Regularization," 2018 52nd Asilomar Conference on Signals, Systems, and Computers, pp. 66-70, 2018.
- [18] <https://keras.io/ja/>

研究業績

A. 国際会議論文（査読なし，○印：発表者）

- [1] ○D. Takasu, H. Sasaki, N. Nakamura, Y. Okamoto, "Nondestructive Estimation Method for Magnetization Distribution in Permanent Magnets Using Deep Learning", *The 15th Joint MMM-INTERMAG Conference*, New Orleans, America, Jan. 2022.

B. 口頭発表論文（査読無し，○印：発表者）

- [1] ○高須大地，島嘉宏，中村勢到，岡本吉史：「3Dプリンタを援用した静磁界自動計測器の開発と永久磁石の非破壊磁化推定への応用」，電気学会全国大会講演論文集，2-103（2021）。
- [2] ○高須大地，佐々木秀徳，中村勢到，岡本吉史：「深層学習を用いた永久磁石磁化推定手法に関する検討」，電気学会静止器・回転機合同研究会資料，SA-22-026/RM-22-026，pp. ???，（2022）。（発表予定）