



北海道大学
HOKKAIDO UNIVERSITY

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

2017/9/22 静止器/回転機合同研究会
SA-17-081, RM-17-112

北海道大学 大学院情報科学研究科

◎佐々木 秀徳, 五十嵐 一

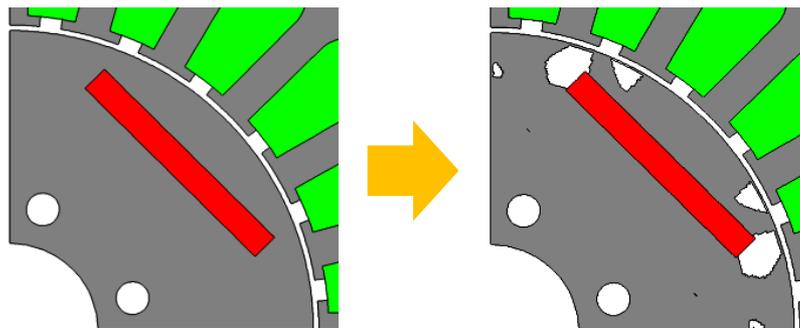
目次

- 研究概要・目的
- 提案手法
- 最適化設定
- 最適化結果
- 結論

研究概要

◆トポロジー最適化

- ✓ 境界の形状だけでなく、トポロジーも変化させて最適化を行う。



回転子の最適化例

- ✓ この手法は斬新な形状を生み出す可能性がある。
- ✓ しかし、最適化には数日から数週間の時間を要する。

理由として...

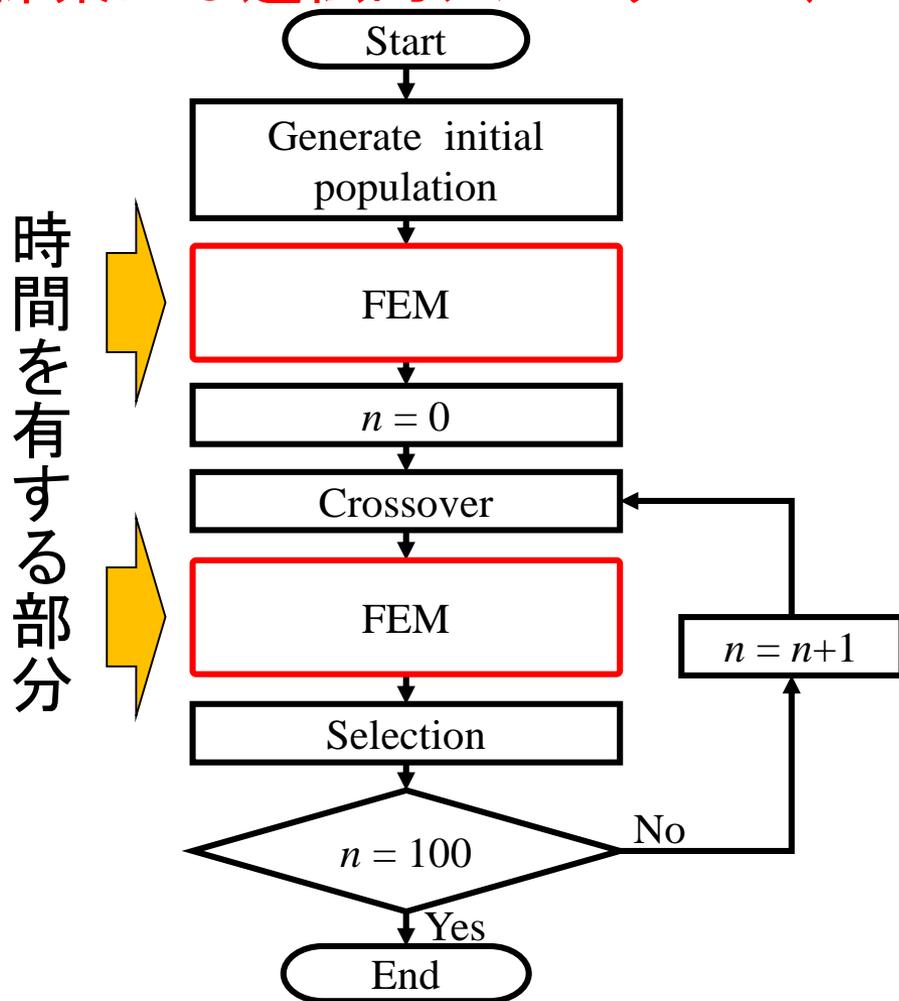
- ✓ 最適化空間の自由度の高さ。
- ✓ 遺伝的アルゴリズム(GA)中で何度もFEMを行う必要がある。

などが挙げられる。

研究概要

◆トポロジー最適化

✓ 探索には遺伝的アルゴリズム(GA)を用いる.



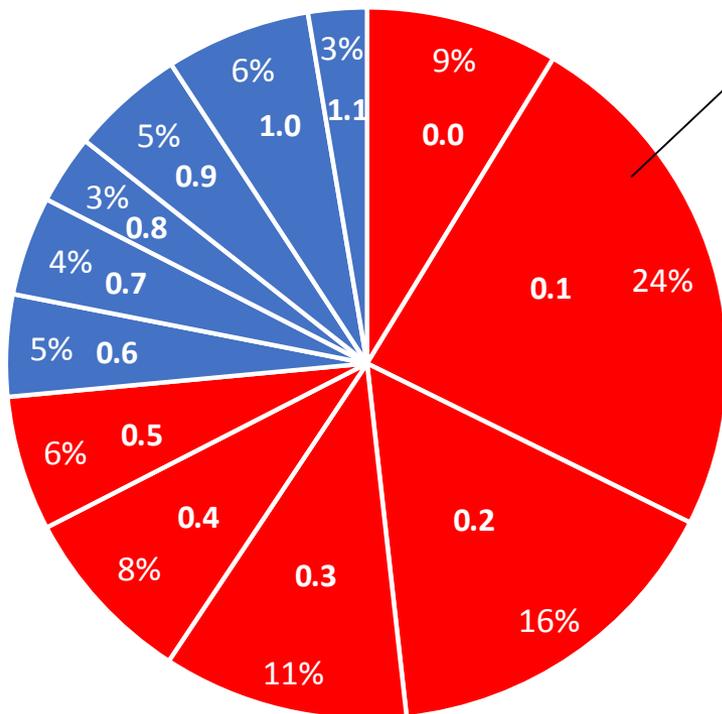
GAは生物の進化を模倣したアルゴリズムである.

GA内では個体を生成するたびに個体の適応度をFEM解析する必要がある.

研究概要

◆トポロジー最適化

✓ 集団内の多くの個体が低い評価値である。



Distribution of fitness in the initial population

73.5%の個体が最適化前の形状の半分以下の評価値である。



これらの形状は次世代に最良個体として残る可能性が低いと考えられる。

これらの形状をFEMで解析する必要があるだろうか？

◆ 深層学習を用いた最適化

- ✓ 深層学習は幅広い分類問題において従来の機械学習手法よりも優れていることが報告されている^[1].
- ✓ 文献[2]にてニューラルネットワークを用いてGAの遺伝子を入力とした分類器を作成し、最適化に組み込む方法を提案。
➡ 最適化手法・対象に依存してしまう。

◆ 汎化が可能かつ最適化手法に依存しない方法を提案

材料分布を入力とした深層学習分類器

[1] Y. LeCun, B. Yoshua, H. Geoffrey, “Deep learning,” *Nature*, vol. 521, No. 7553, pp. 436-444, 2015.

[2] 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,” IEICE technical report, vol.116, pp.289-294, 2016.

研究目的

◆ 研究目的

最適化時間の短縮, 新しい設計手法の確立



◆ 提案手法

畳込みニューラルネットワーク(CNN)とGAを用いた最適化手法

- ✓ GA中の有限要素解析回数の削減のためにCNNを用いる.
- ✓ 入力を材料分布にすることで, 最適化手法に依存しない分類器を作成した.
- ✓ 提案手法は最適化時間の減少が見込まれる.
- ✓ 本研究では提案手法をIPMモータに適用した.

目次

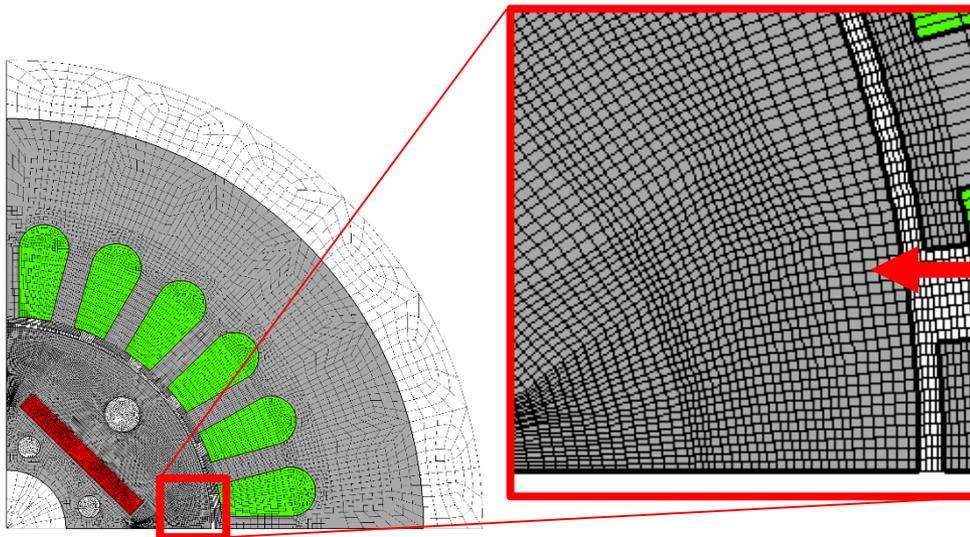
- 研究概要・目的
- 提案手法
- 最適化設定
- 最適化結果
- 結論

提案手法

◆ NGnet-on/off法

[3]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.

- ✓ 複数個のガウス基底を設置し, 正規化ガウス関数ネットワーク (NGnet)を作成する.
- ✓ 設計領域内の要素の物性は出力 ϕ によって決定する.
- ✓ 最適化中では重み係数 w_i を実数値遺伝的アルゴリズム(RGA)の遺伝子とする.
- ✓ 本手法を用いることで境界がなめらかな形状を得ることができる[3].



$$\phi = \sum_{i=0}^{N_g} w_i b_i$$

$$V_e \leftarrow \begin{cases} \text{iron} & \phi(\mathbf{x}_e) \geq 0, \\ \text{air} & \phi(\mathbf{x}_e) < 0. \end{cases}$$

w_i : The weighting coefficient

b_i : Normalized Gaussian bases

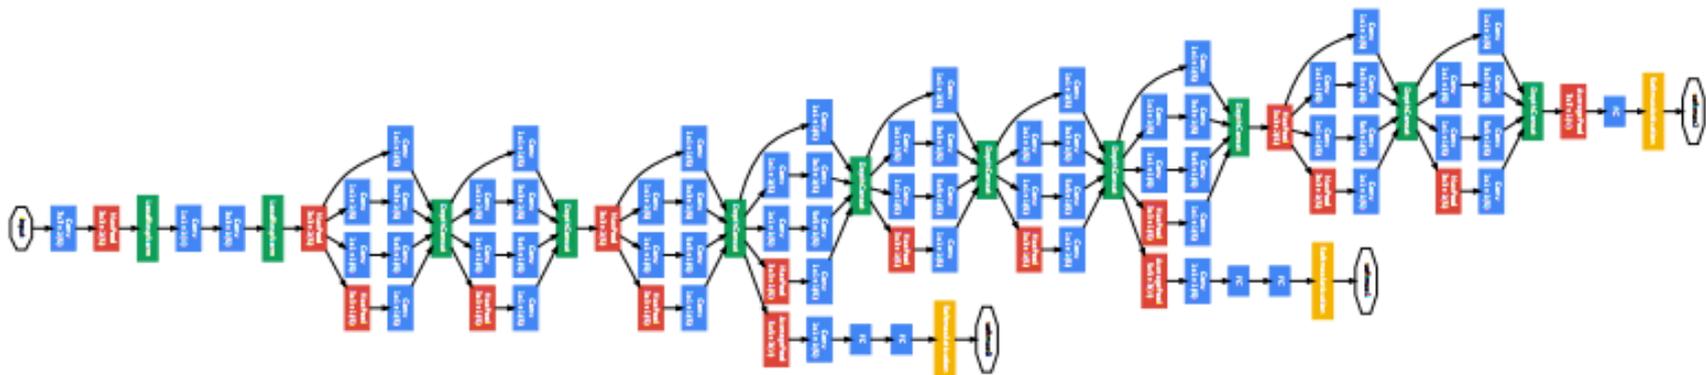
\mathbf{x}_e : Gravitation center of element e

N_g : Number of Gaussian bases G_j

提案手法

◆ GoogLeNet

- ✓ 深層学習の一つであるGoogLeNetを用いた.
- ✓ GoogLeNet は畳み込みニューラルネットワーク(CNN)のひとつ.
- ✓ ILSVRC – 2014における画像識別分野で優勝したネットワークである.
- ✓ 22層で構成されている.

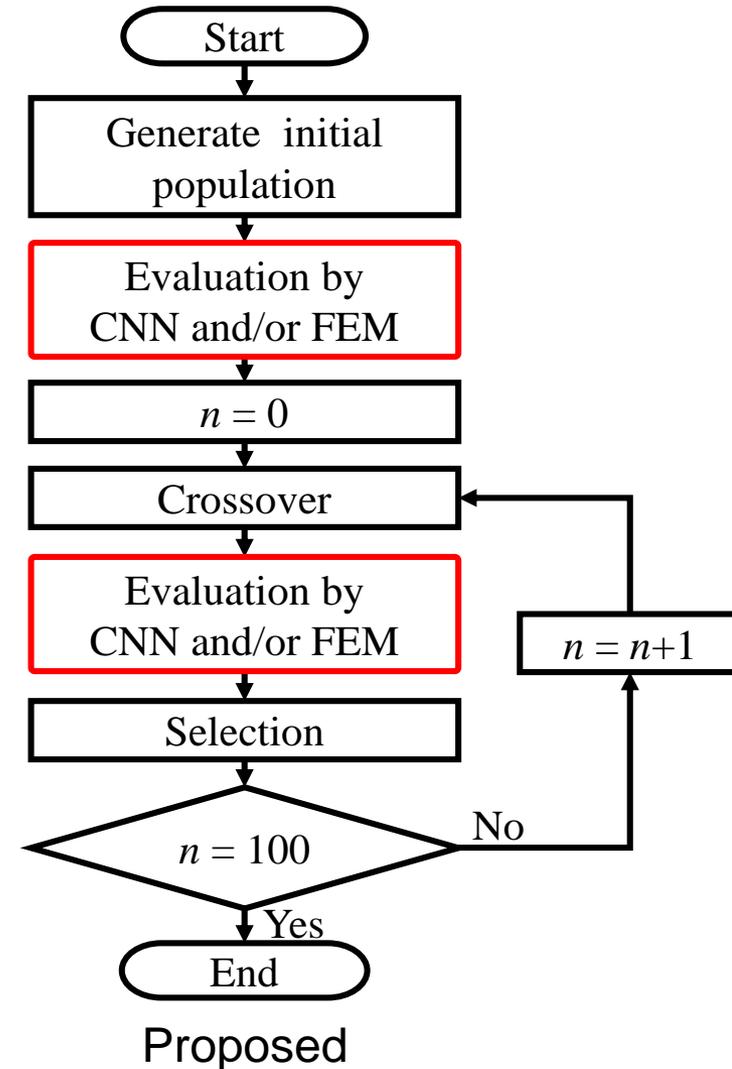
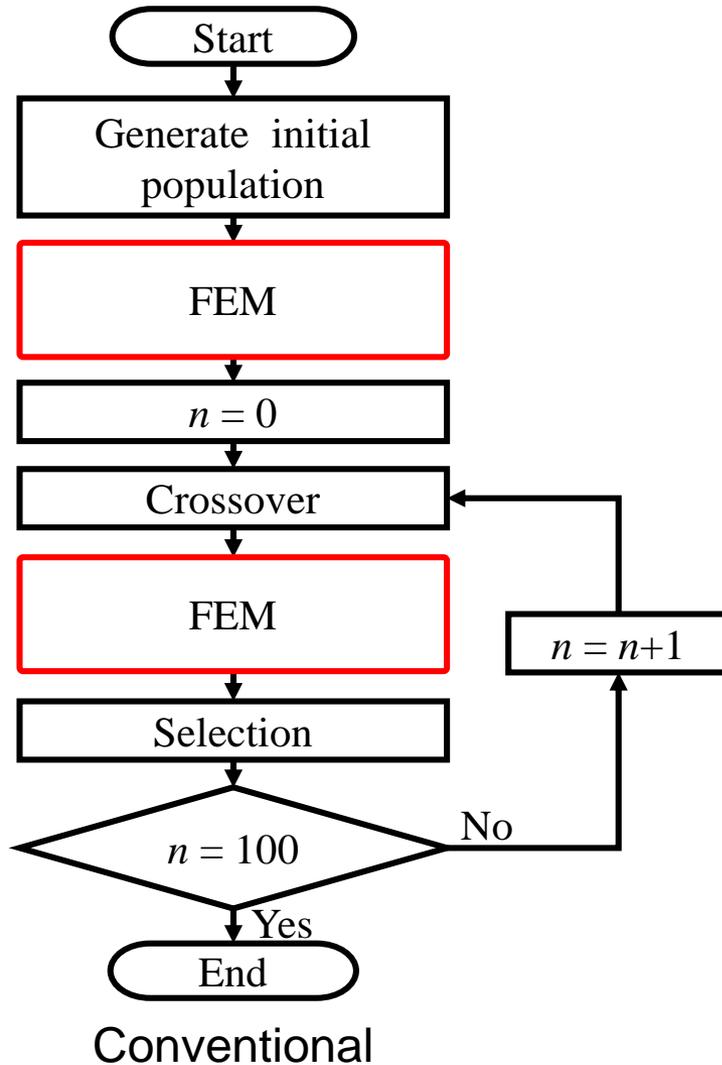


GoogLeNet 文献[3]より引用

[3] Szegedy, Christian, et al. "Going deeper with convolutions." Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.

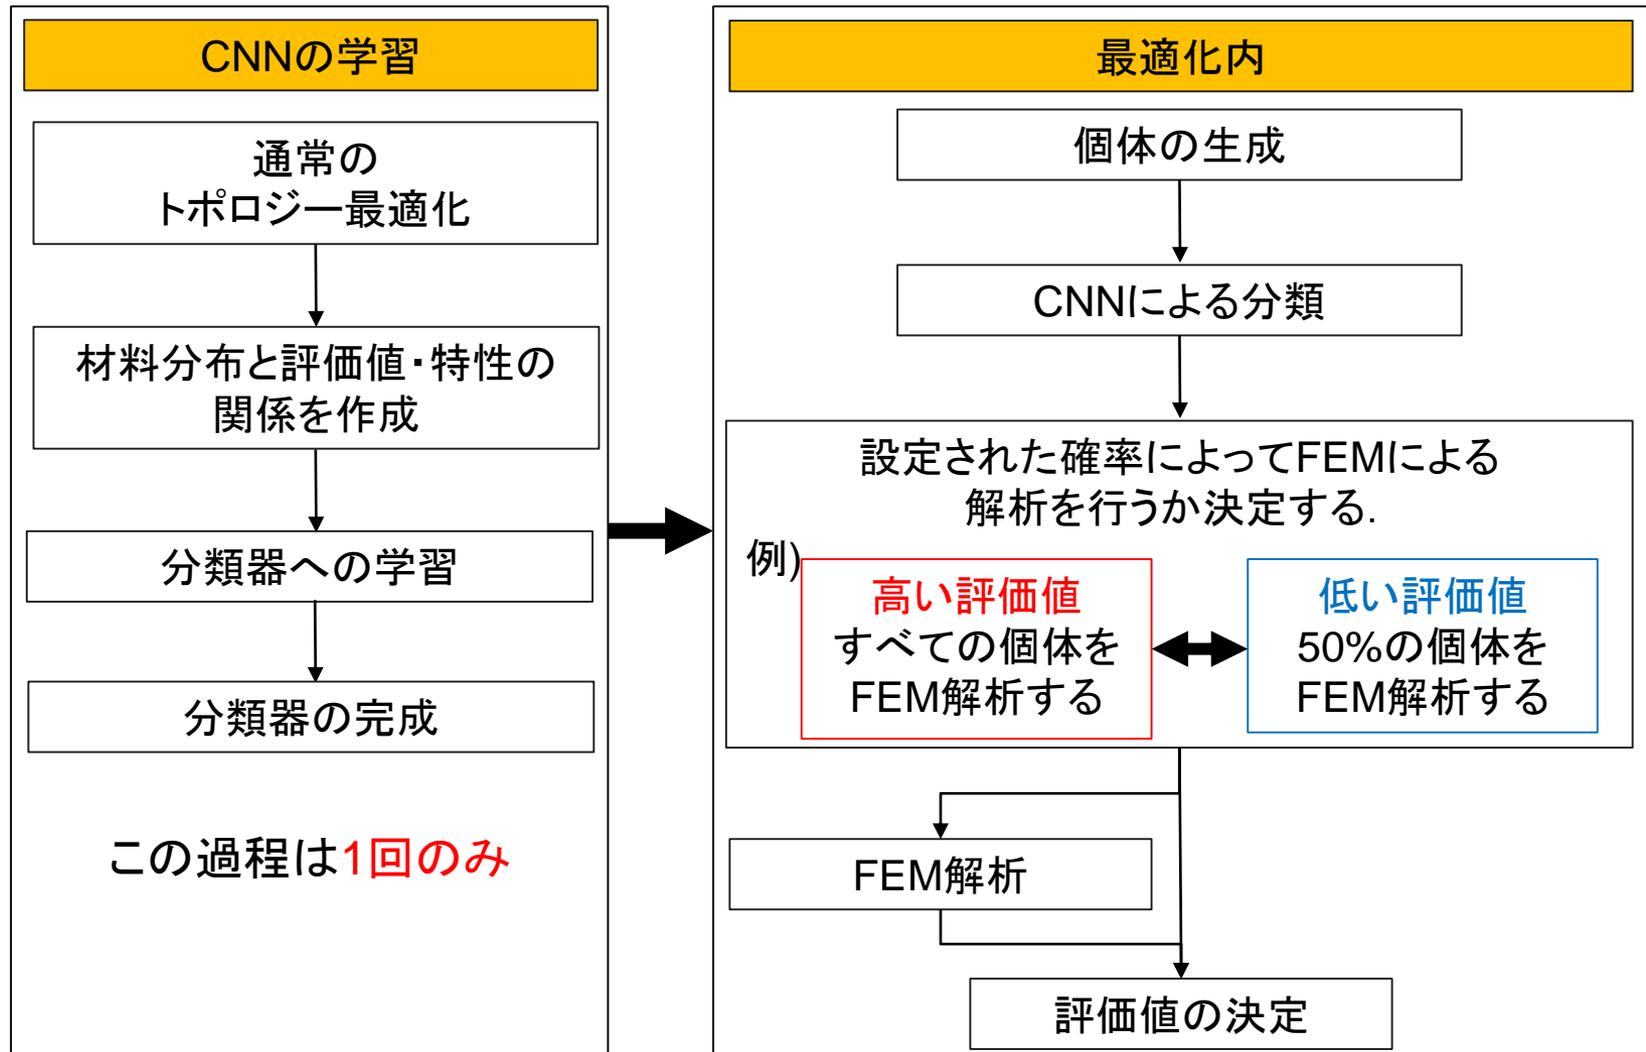
提案手法

- ◆ CNNを最適化中に組み込むことを考える.



提案手法

- ◆ 全体フローは以下のようなになる。

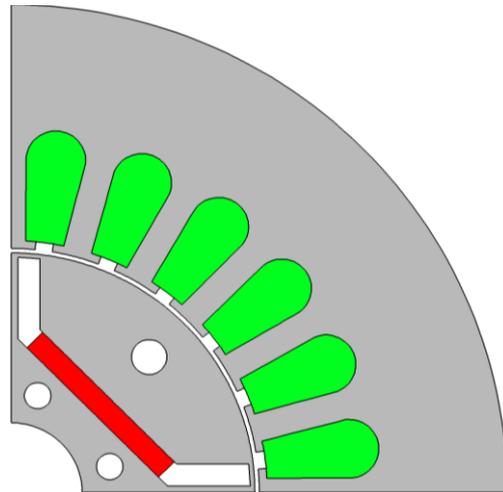


目次

- 研究概要・目的
- 提案手法
- 最適化設定
- 最適化結果
- 結論

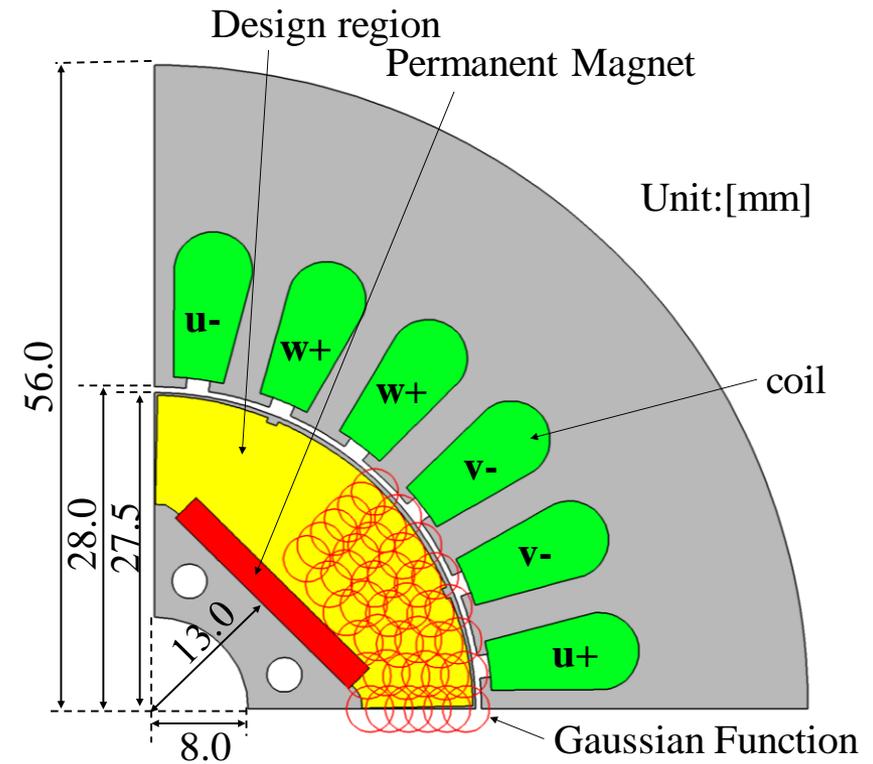
最適化設定

- ◆ 本研究では電気学会Dモデル^[4]であるIPMモータの回転子の最適化を行った。



$$T^0 = 2.08 \text{ Nm}$$

| | |
|------------------------------|--------|
| Current phase angle [degree] | 30 |
| Current effective value [A] | 4.2425 |
| Number of turns [turn] | 35 |
| Residual flux density [T] | 1.25 |



[4] Technical report of the institute of electrical engineering of Japan," *Industry application society*, No. 776, 2000.

最適化設定

- ◆ IPMモータの平均トルク最大化問題を解く.
- ◆ 目的関数を以下に示す.

$$F = \frac{T}{T^0} \rightarrow \max. \quad \text{Sub.to.} \quad N_{\text{area}} < 2$$

T : Average torque

T^0 : Average torque of original model

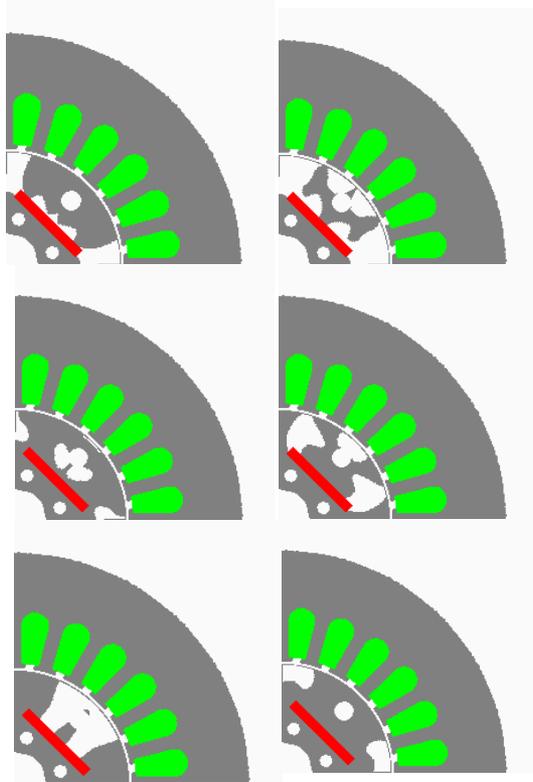
N_{area} : The number of separated rotor cores

Optimization setting

| | |
|---------------------------|-----|
| The number of genes | 42 |
| The number of individuals | 800 |
| The number of children | 160 |

最適化設定

- ◆ 4000個体の材料分布と特性値の関係をCNNに学習させる。



Bit map showing material distribution
(224 × 224)



| Classification | |
|----------------|-----------|
| CNN | FEM |
| 1.1 | 1.05~ |
| 1.0 | 0.95~1.05 |
| 0.9 | 0.85~0.95 |
| 0.8 | 0.75~0.85 |
| 0.7 | 0.65~0.75 |
| 0.6 | 0.55~0.65 |
| 0.5 | 0.45~0.55 |
| 0.0 | ~0.45 |

■: Iron ■: Permanent magnetic ■: Copper □: Air

最適化設定

- ◆ CNNの性能をテストするために他の4000個体を用いてCNNに分類させた結果と実際にFEMを用いて解析した結果を比較する。

Relationship between evaluation value by CNN and FEM

制約条件の影響

| | | Label by CNN F_i^{CNN} | | | | | | | | |
|--------------------------|-------|--------------------------|-----|-----|-----|-----|-----|-----|-----|-------|
| | | 0 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1 | 1.1 | TOTAL |
| Label by FEM F_i^{FEM} | 0 | 513 | 46 | 10 | 6 | 2 | 7 | 0 | 0 | 584 |
| | 0.5 | 18 | 397 | 75 | 1 | 0 | 0 | 0 | 0 | 491 |
| | 0.6 | 0 | 83 | 392 | 79 | 0 | 0 | 0 | 0 | 554 |
| | 0.7 | 0 | 1 | 73 | 462 | 39 | 1 | 0 | 0 | 576 |
| | 0.8 | 0 | 0 | 0 | 32 | 377 | 29 | 0 | 0 | 438 |
| | 0.9 | 0 | 0 | 0 | 6 | 40 | 463 | 28 | 0 | 537 |
| | 1 | 0 | 0 | 0 | 0 | 0 | 21 | 368 | 26 | 415 |
| | 1.1 | 0 | 0 | 0 | 0 | 0 | 0 | 10 | 395 | 405 |
| | TOTAL | 531 | 527 | 550 | 586 | 458 | 521 | 406 | 421 | 4000 |

| e | The number of individual | Ratio[%] |
|-------|--------------------------|----------|
| 0 | 3367 | 84.2 |
| 0.1 | 599 | 15.0 |
| 0.2 | 19 | 0.5 |
| 0.3 | 6 | 0.2 |
| 0.4 | 2 | 0.1 |
| 0.5 | 7 | 0.2 |
| 0.6 | 0 | 0.0 |
| 0.7 | 0 | 0.0 |
| TOTAL | 4000 | 100.0 |

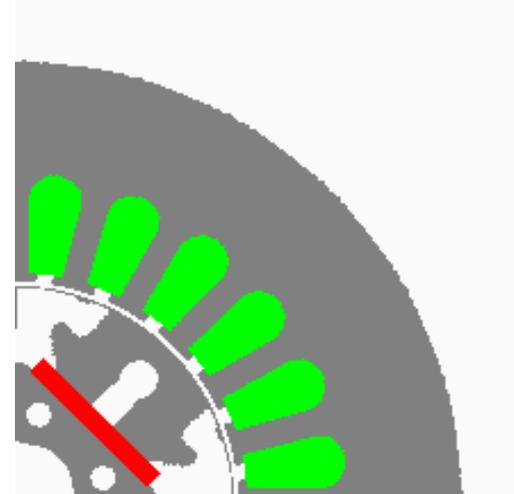
- ◆ 99パーセント以上の個体が0.1以内の誤差で分類できている。

最適化設定

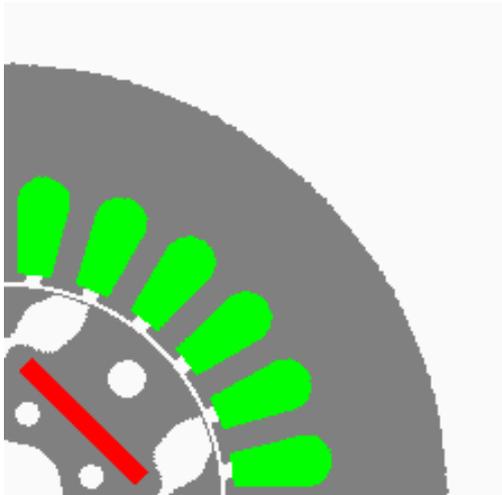
◆ 分類結果の例を示す.



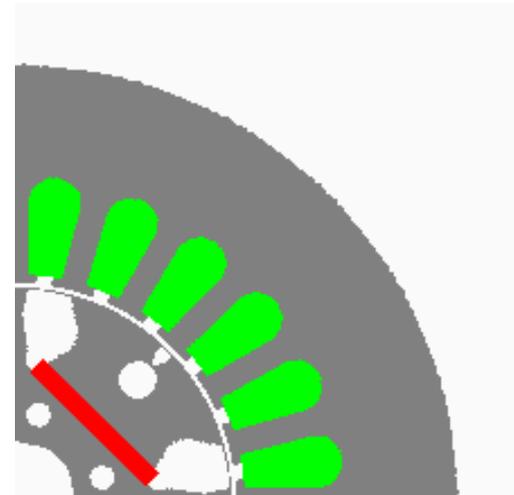
CNN: 0.50 FEM: 0.50



CNN: 0.90 FEM: 0.90



CNN: 0.70 FEM: 0.70



CNN: 1.10 FEM: 1.09

最適化設定

- ◆ 本研究では5種類のFEM解析確率を用いて最適化を行った.

| CNN Output | Probability for FEM analysis [%] | | | | |
|--------------|----------------------------------|-------------|-------------|-------------|----------|
| | (a) | (b) | (c) | (d) | (e) |
| 0 | 100 | 0 | 0 | 0 | 0 |
| 0.5 | 100 | 40 | 20 | 0.78125 | 0 |
| 0.6 | 100 | 50 | 25 | 1.5625 | 0 |
| 0.7 | 100 | 60 | 30 | 3.125 | 0 |
| 0.8 | 100 | 70 | 35 | 6.25 | 0 |
| 0.9 | 100 | 80 | 40 | 12.5 | 0 |
| 1 | 100 | 90 | 45 | 25 | 0 |
| 1.1 | 100 | 100 | 50 | 50 | 0 |
| Total | 100 | 61.3 | 30.6 | 12.4 | 0 |

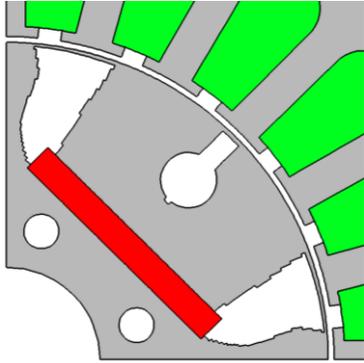
- ✓ 100世代目で十分に収束していると判断し、その時点での形状を最適解とした.

目次

- 研究概要・目的
- 提案手法
- 最適化設定
- 最適化結果
- 結論

最適化結果

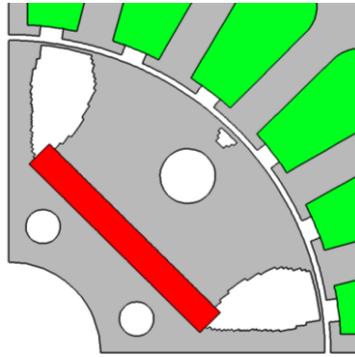
◆ 最適化結果を示す



$$F = 1.106$$

$$T_{\text{ave}} = 2.32 \text{ Nm}$$

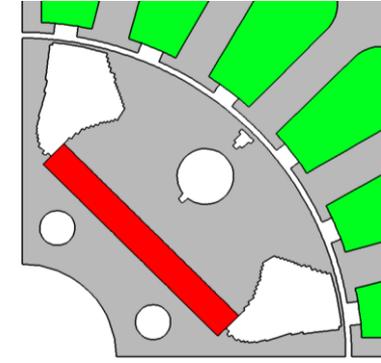
(a) 100% FEM evaluations



$$F = 1.098$$

$$T_{\text{ave}} = 2.31 \text{ Nm}$$

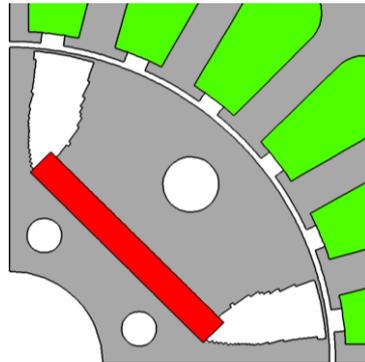
(b) 61.3% FEM evaluations



$$F = 1.109$$

$$T_{\text{ave}} = 2.33 \text{ Nm}$$

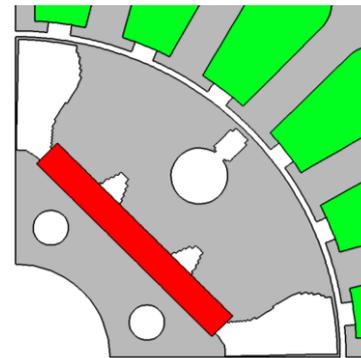
(c) 30.6% FEM evaluations



$$F = 1.101$$

$$T_{\text{ave}} = 2.31 \text{ Nm}$$

(d) 12.4% FEM evaluations



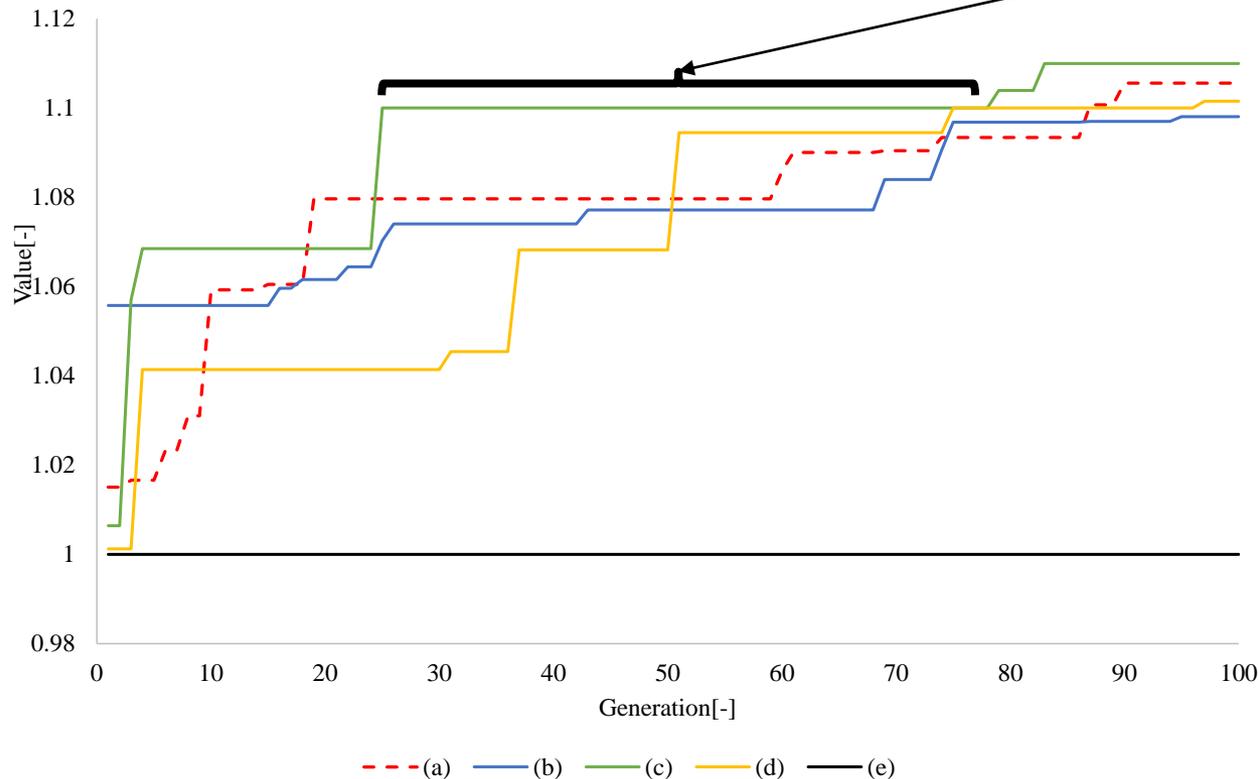
$$F = 1.000$$

$$T_{\text{ave}} = 2.08 \text{ Nm}$$

(e) 0.0% FEM evaluations

◆ 評価値の推移を示す.

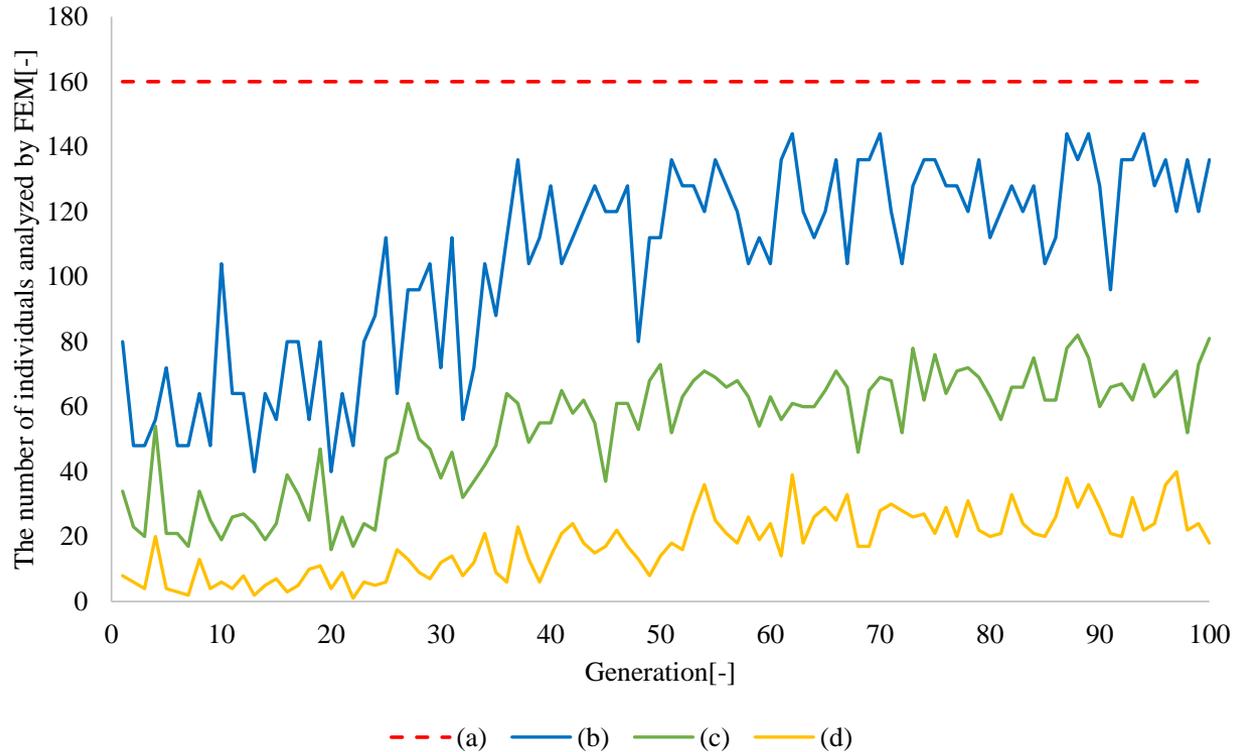
CNNのみによる評価個体が最適解となっている。



- ✓ FEMを用いた場合, すべて同様の評価値に収束している.
- ✓ CNNにより良好な解と判定された個体はすべてFEM解析するほうが望ましい.

最適化結果

◆ 評価個体数の推移を示す.



- ✓ 世代を追うに連れて、評価値の高い個体が多くなることから、解析回数も徐々に上昇している.

最適化結果

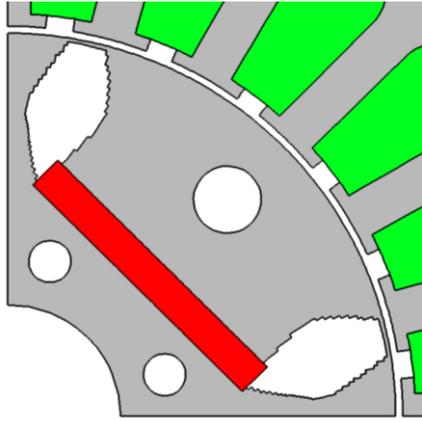
◆ FEMによる解析回数を示す.

| | The number of individual analyzed by FEM | Ratio [%] |
|-----|--|-----------|
| (a) | 16000 | 100.0 |
| (b) | 10528 | 65.8 |
| (c) | 5293 | 33.1 |
| (d) | 1774 | 11.1 |

- ✓ 設定(d)にて最適化を行った結果, (a)の約11%の解析個体数で最適化を行うことが出来た.

最適化結果

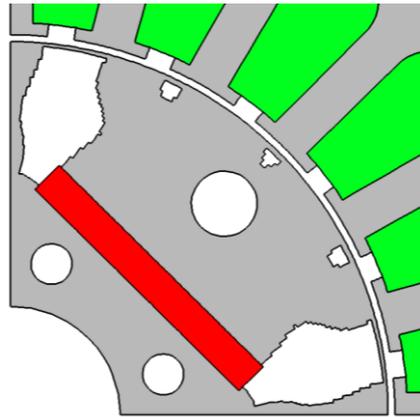
◆ SEED値を変更した場合の結果を示す。



$$F = 1.114$$

$$T_{\text{ave}} = 2.34 \text{ Nm}$$

(b) MAX 100%
FEM evaluations

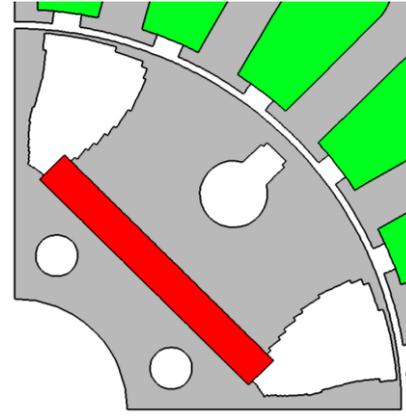


$$F = 1.117$$

$$T_{\text{ave}} = 2.35 \text{ Nm}$$

(c) MAX 50%
FEM evaluations

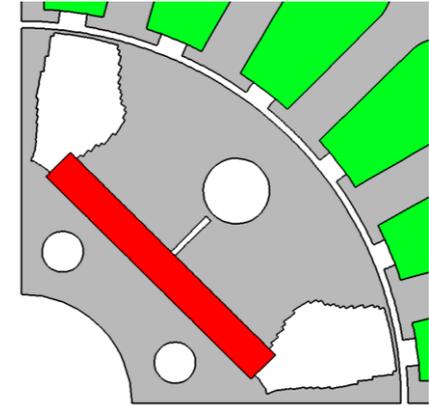
SEED A



$$F = 1.101$$

$$T_{\text{ave}} = 2.31 \text{ Nm}$$

(b) MAX 100%
FEM evaluations



$$F = 1.124$$

$$T_{\text{ave}} = 2.36 \text{ Nm}$$

(c) MAX 50%
FEM evaluations

SEED B

- ✓ 7種の最適化の平均トルクの標準偏差は $1.83 \times 10^{-2} \text{ Nm}$.
- ✓ SEED値を変えても、同様な形状を得た。

提案手法の有用性

- ◆ 提案手法によって以下のようなメリットが考えられる.
- ✓ 目的関数, 拘束条件を変えた最適化を高速に実行できる
 - ・一度, 最適化を実行し, それによりトルク T , トルクリップル T_r , 損失 L , 応力 σ などを出力する複数のCNNを構成
 - ・上記の特性値を任意に組み合わせた目的関数・拘束条件の最適化を高速に実行できる.
e.g. $F = w_1T + w_2T_r + w_3L + w_4\sigma$
 - ・多目的最適化も高速に実行できる. e.g. $F_1 = T, F_2 = T_r$
- ✓ シード値を変更した最適化にも同様の分類器を使用可能.
- ✓ 様々な形状・配置のモータを学習させることで, 最適化対象を変えても同じ分類器を使用して最適化可能.

目次

- 研究概要・目的
- 提案手法
- 最適化設定
- 最適化結果
- 結論

- ✓ CNNを用いたトポロジー最適化手法を提案した.
- ✓ 提案手法を用いると解析回数を削減することが可能となる.
- ✓ 従来手法で得られた形状と大きな違いは見られなかった.

今後の予定

- ✓ 他のモデルに適用する.
- ✓ 複数のモデルを学習させたCNNの有用性の検証.
- ✓ 複数の分類器を作成し, 目的関数・拘束条件を変えた最適化に適用.