

# 原子力発電所の電気系アイソレーション計画の深層学習による自動生成 Automatic Planning of Electrical Isolation with Deep Learning in Nuclear Power Plant

内藤 晋<sup>\*1</sup>  
Susumu Naito

高倉 啓<sup>\*1</sup>  
Kei Takakura

芝 広樹<sup>\*1</sup>  
Hiroki Shiba

<sup>\*1</sup> 東芝エネルギーシステムズ(株)  
Toshiba Energy Systems & Solutions Corporation

We study automatic planning of electrical isolation with deep learning, one of applications of artificial intelligence to enhance operation and maintenance. Currently, a skilled engineer plans electrical isolation procedure with hundreds of the circuit diagrams and the related documents, taking man-hours. If this task becomes automatic, it is very efficient. A major issue of the automatic planning is much calculation time of electrical circuit simulator, searching billions of electrical conducting paths. We performed a simplified case study of the electrical isolation. We applied a deep neural network (DNN) for dropping in the calculation time. We trained the responses of the circuit simulator to the DNN, constructing an optimized path search algorithm in the DNN. The calculation time of the DNN was shorter by a factor of 560, compared with that of the electrical circuit simulator. There was no significant difference in accuracy between Multi-Layer Perceptron and Graph Convolutional Network.

## 1. はじめに

現在、人工知能技術は、高性能かつ低コストの計算機環境と、使い易いコーディングツールのおかげで容易に利用できる。我々は原子力発電所のオペレーション&メンテナンス高度化のために、人工知能を活用した様々なアプリケーションを開発している。現場支援においては、深層学習を用いた電気系アイソレーション計画の自動生成を試みている[1]。電気系アイソレーションは、検査/工事対象機器を電氣的に隔離する作業であり、感電や他の系統および機器の機能喪失等の誤動作・誤不動作を起こすことなく、実施する必要がある。現在、熟練した技術者が、数百もの回路図や関連図書を用いて、工数をかけてアイソレーション手順の計画を作成している。この作業が自動化されれば非常に効率的である。

自動計画には二つの課題がある。一つは、膨大な電気導通経路を全て探索するためには、汎用の電気回路シミュレータでは非常に計算時間がかかること。もう一つは、作業のし易さなど

の曖昧な情報の解釈である。深層学習はこれらの解決に役立つ。なぜなら深層学習は、複雑な情報からより良いルールを見つける手段である。深層学習には、高精度な予測と分類のための適用例が数多くあるが[2-5]、電気回路、特に計算の高速化の例はない。

我々は、電気系アイソレーションの簡略化したケーススタディを実施した。深層ニューラルネットワーク(DNN)を計算時間削減に適用し、効率的な経路探索アルゴリズムをDNNの内部に構築した。計算時間削減においては、多層パーセプトロン(Multi-Layer Perceptron: MLP)を適用し、さらに、より高速化を狙い、グラフ畳み込みネットワーク(Graph Convolutional Network: GCN)の適用を試みた。また深層Qネットワーク(DQN)を曖昧な情報の解釈に適用した。DQNは、機器配置図、線量、および熱中症を防ぐための湿球温度(WBGT)の値による作業負荷の観点から、アイソレーション手順を最適化した。最終結果の正しさは人が確認する必要があるが、大量の情報から手順を導く作業とは異なり、この作業は容易である。本論文では、前者の計算時間削減を対象とし、次節以降、詳細を述べる。

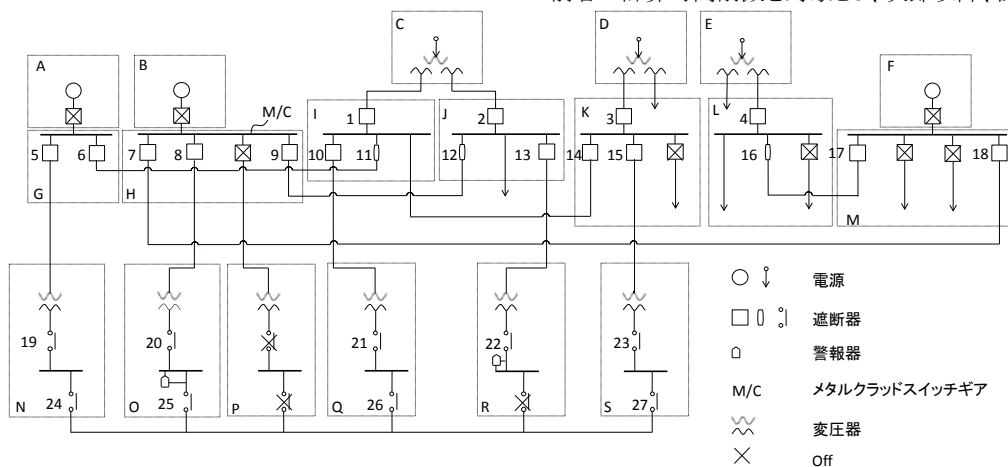


図 1. モデルケース図

連絡先: 内藤 晋、東芝エネルギーシステムズ(株)  
横浜市磯子区新杉田町8、TEL:045-770-2379、  
E-mail: susumu.naito@toshiba.co.jp

## 2. 方法論とケーススタディ

### 2.1 全体概要

図1と図2にモデルケース図と自動計画手順を示す。モデルケース図は、単線結線図であり、3つの電源、27の遮断器、2つのアラームを含む76の機器で構成される。A～Sのセクションは各機器の位置を示す。検査対象はメタルクラッドスイッチギア(M/C)であり、検査する前に警報を鳴らすことなく隔離する必要がある。自動計画手順を以下に説明する。最初に、単線結線図から、M/Cを隔離する遮断器オン/オフパターンを導出する。第2に、作業負荷の観点からパターンを選別する。推奨されるパターンとその手順を導出する。計算環境は、High Performance Computer (Intel Xeon E5-2690、RAM:192GB、GPU: Tesla K20Xm)と“TensorFlow” [6]を使用した。




図 2. 自動計画手順

### 2.2 無警報で電気遮断する遮断器オン/オフパターンの導出

警報のない状態で検査対象物を隔離する遮断器オン/オフパターンは、電気導通経路の探索機能を有する従来の電気回路シミュレータを用いて導き出すことができる。しかしながら膨大な数の遮断器オン/オフパターンが存在するため、計算時間がかかる。ケーススタディでは、27個のブレーカが $2^{27}$ のオン/オフパターンを生成する。シミュレータは、すべてを計算し、検査対象物を隔離するパターンを見つける必要がある。高速な計算が必要である。深層学習が、電気経路探索アルゴリズムを最適化し、警報なしでターゲットを隔離する遮断器オン/オフパターンの導出に特化したアルゴリズムを導出することを期待した。

深層学習は、学習データから論理を自動的に構築する能力を有する。我々は、深層ニューラルネットワーク(DNN)に回路シミュレータの応答を学習させた。図3に、使用したDNN図を示す。6層の隠れ層と各層300ユニットの多層パーセプトロン(MLP)を使用した。現在のところ、一般化された選択方法が存在しないため[7-9]、隠れ層とユニット数は経験的に選択した。活性化関数はReLUを使用した。入力は、27個の遮断器( $x_1, x_2, x_3, \dots, x_{27}$ )の遮断器オン/オフパターンであり、遮断器 $i$ のオン/オフ状態は $x_i = 0$  or  $1$ で表される。出力は、検査対象 $y_1$ と2つの警報器 $y_2/y_3$ の導通状態( $y_1, y_2, y_3$ )であり、導通状態は、 $y_i = 0$  or  $1$ で表される。学習データと検証データは( $x_1, \dots, x_{27}$ )と( $y_1, y_2, y_3$ )の組である。学習データと検証データは、回路シミュレータにランダムに遮断器オン/オフパターンを入力して作成した。DNNが計算を高速化しても、学習と検証データの作成に多くの時間を要すると意味がない。DNNの学習には、学習データ12,000個と検証データ413,000を使用した。これは、合計 $2^{27}$ パターンのわずか0.01%と0.3%である。

図4に、12,000の学習データに対する学習時間と413,000の検証データに対するDNNの正答率を示す(学習係数:0.03、ドロップアウト:無)。正答率は、急速に上昇し、学習開始1分後に99%を超えた。学習時間は非常に短時間だった。

413,000の検証データを用いて学習済みDNNの計算時間を測定した。1つの遮断器オン/オフパターン( $x_1, x_2, x_3, \dots, x_{27}$ )に対する導電状態パターン( $y_1, y_2, y_3$ )の平均計算時間は0.0011秒であった。同じコンピュータ環境下で、幅優先探索(BFS)を使用した回路シミュレータでは計算時間は0.95秒だった。学習済みDNNは回路シミュレータよりも560倍高速だった。

学習済みDNNを使用し、すべての遮断器オン/オフパターン( $2^{27}$ パターン)について、( $y_1, y_2, y_3$ )を計算し、無警報で検査対象を隔離する遮断器オン/オフパターン、即ち( $y_1, y_2, y_3$ )=(0,1,1)となるパターンを導出した。図5は、オフにする遮断器の数と、導出されたパターンの数を示す。オフにする遮断器の数は3~19の範囲であった。パターンの数は10で最大であった。このケーススタディでは合計798,217パターンが得られた。多数の隔離パターンが存在し、スクリーニングする必要がある。スクリーニングは、単に遮断器オフ数が少ないものにする等、様々な観点がありえる。作業のし易さの観点で、深層強化学習DQNの適用を試みており[1]、方法論は構築できている。




図 3. 深層ニューラルネットワーク(DNN)の構成




図 4. 学習時間 vs. 正答率




図 5. オフにする遮断器数 vs. 無警報で検査対象を隔離する遮断器オン/オフパターン数

### 2.3 グラフ畳み込みネットワークの適用

前節で、学習済み DNN は正答率 99%超が得られた。計算速度は DNN の規模(隠れ層の数、ユニット数)に依存するので、小規模でも良い正答率が得られるなら、更なる高速化が図れる。そこで、グラフ畳み込みネットワーク(GCN)の適用を試みた。

GCN は、グラフをそのまま入力できる深層学習ネットワークである。既知のルールを最初からネットワークに反映して、精度と速度の向上を狙う。近年活発な研究がされており、化学の分子構造をグラフにして分子の性質を従来手法よりも 30 万倍高速に予測した例[10]や、知識ベースでのデータの関係性に用いて関係性の予測精度向上[11]など、研究成果が発表されている。本ケースでは Schlichtkrull らの手法 [11]をアレンジして、図1の単線結線図へ適用した。グラフは、機器をノード(節)、配線をエッジ(辺)をとした。エッジの重みをパラメータにし、各ノードの近接エッジの重みを畳み込み演算して、多層ニューラルネットワークの次の層へと連結した。

単線結線図へのアレンジの詳細を述べる。ノード  $v_i \in V$ 、エッジ  $(v_i, r, v_j) \in E$ 、エッジの種類  $r \in R$  とした、グラフ  $G = (V, E, R)$  に対し、GCN の各層は、次式(1)の構成をとる[10]。

$$h_i^{(l+1)} = \sigma \left( \sum_{r \in R} \sum_{j \in N_i^r} \frac{1}{c_{i,r}} W_r^{(l)} h_j^{(l)} + W_0^{(l)} h_i^{(l)} \right) \quad (1)$$

ここで、 $h_i^{(l)} \in R^{d^{(l)}}$  はノード  $v_i$  の  $l$  層目の隠れ層の状態、 $d^{(l)}$  は  $l$  層目の隠れ層の次元、 $\sigma$  は活性化関数、 $N_i^r$  は  $r \in R$  関係下でのノード  $i$  の隣接ノード、 $c_{i,r}$  は問題特有の正規化定数である。 $W_r^{(l)}$  は次式(2)で表される。

$$W_r^{(l)} = \sum_{b=1}^B a_{rb}^{(l)} V_b^{(l)} \quad (2)$$

$W_r^{(l)}$  は、基底変換  $V_b^{(l)} \in R^{d^{(l+1)} \times d^{(l)}}$  と係数  $a_{rb}^{(l)}$  (スカラー)の積で表される。 $B$  は基底関数の数を表す。単線結線図では、このGCNを以下のアレンジで実装させた。

- 電気回路では、各機器の特徴はユニークに決まっているため、中間プロセスとして自己符号化器等による特徴量抽出は行わない。
- ノード(機器)とエッジ(配線)情報が隠れ層の何処へ行ったかを明確に同定して、機器同士の結線関係をGCN 全層において正確に反映させるために、各層のユニット数は機器数と一致させる。

これらは、式(2)において、基底変換を恒等写像としてとり扱うことでGCNに導入し、

$B$  = 入力層の入力チャンネル数、 $V_b^{(l)}$  は単位行列、とした。

GCN は、入力 76 チャンネル(=機器数)、2層の隠れ層と各層

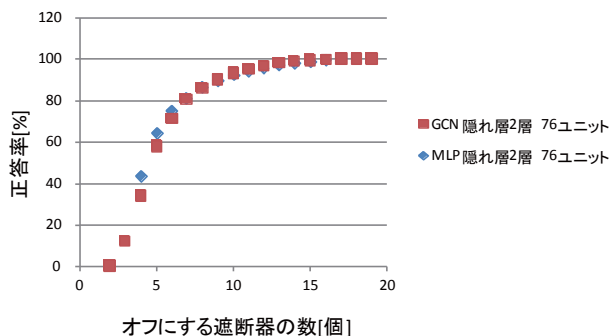


図 6. GCN と MLP の小規模構成での正答率の比較

76 ユニットで構成した。比較用の多層パーセプトロン(MLP)も同じ構成とした。これらは、前節で使用した 6 層の隠れ層と各層 300 ユニットの MLP に比べて、小規模の構成となっている。ケーススタディに対する正答率は、GCN が 91.6%、MLP が 92.0% となった。図6にオフする遮断器数と正答率の関係をしめす。GCN と MLP はほぼ同一の正答率となっており、有意な差はなかった。また、GCN は、6層の隠れ層で構成した場合についても試評価を行い、正答率 99.7%と非常に高い値が得られたが、MLP もほぼ同じ値となった。

### 3. 考察と結論

我々は、深層学習を用いた電気系アイソレーション計画の自動生成に関し、簡略化したケーススタディを実施した。深層ニューラルネットワーク(DNN)に回路シミュレータの応答を学習させ、DNN に最適化された経路探索アルゴリズムを構築した。DNN の計算時間は、電気回路シミュレータの場合と比較して、560 倍短縮された。

計算時間がなぜ短縮したのかは、DNN の内部がブラックボックス状態ゆえ、明確には分からないが、もともとは複雑な経路探索の問題であったのが、DNN によって取り扱う問題の性質が変わり、画像認識などと似た、パターン認識の問題に置き換わったと推測する。

学習済み DNN は稀に間違いを起こす。ケーススタディでは正答率は 99%以上だったが、100%にはならなかった。実運用では、DNN が導出した結果を、作業のし易さ等でスクリーニングしたのち、残った最終結果の正しさを人が確認する必要がある。しかしながら、膨大な数の遮断器オン/オフパターンを確認するのは異なり、最終結果、すなわち 1 つまたは複数の推奨されるアイソレーション手順を人が確認することは容易である。

GCN はケーススタディにおいては MLP と有意差はなかった。図1の単線結線図は、機器と配線のルールが単純明快であるので、小規模の MLP でも容易にルールを学習・発見でき、GCN のメリットが活かせなかったのではと推測する。

我々は、原子力発電所のオペレーション&メンテナンス高度化の一つとして、深層学習による電気系アイソレーションの自動計画を報告した。この研究は、現場作業の効率化を目的としたものであり、また、火災等での電気系統の一部喪失によるプラント全体の影響評価等にも発展できる。我々は、継続して原子力発電所への人工知能応用の研究開発を進める。

本論文に掲載の商品の名称は、それぞれ各社が商標として使用している場合があります。

### 参考文献

1. S. NAITO et al., "Applications of Data Mining Technology to Enhance O&M: Automatic Planning of Electrical Isolation with Deep Learning," *10th International Conference on Nuclear Plant Instrumentation, Control, and Human-Machine Interface Technologies* (2017).
2. A. ESTEVA et al., "Dermatologist-level Classification of Skin Cancer with Deep Neural Networks," *Nature* **542**, 115–118 (2017).
3. D. S. WEI et al., "Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic

- Populations with Diabetes,” *Journal of the American Medical Association*, 318(22), 2211-2223 (2017).
4. S. RAMOS et al., “Detecting Unexpected Obstacles for Self-Driving Cars: Fusing Deep Learning and Geometric Modeling In Demos,” *30th Annual Conference on Neural Information Processing Systems* (2016).
  5. R. MIYAJIMA, “Deep Learning Triggers a New Era in Industrial Robotics,” *IEEE MultiMedia* 24 (4), 91-96 (2017).
  6. M. ABADI et al., “TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems,” *Google Inc. White Papers*, arXiv preprint arXiv:1603.04467 (2015).
  7. Y. BENGIO, “Practical Recommendations for Gradient-based Training of Deep Architectures,” *Neural Networks: Tricks of the Trade*, 2nd ed., Springer, Berlin (2012).
  8. J. BERGSTRA et. al, “Random Search for Hyper-Parameter Optimization,” *Journal of Machine Learning Research* 13, 281-305 (2012).
  9. J. SNOEK et. al., “Practical Bayesian Optimization of Machine Learning Algorithms,” *26th Annual Conference on Neural Information Processing Systems* (2012).
  10. J. Gilmer et al., “Neural Message Passing for Quantum Chemistry,” arXiv preprint arXiv: 1704.01212 (2017).
  11. M. Schlichtkrull et al., “Modeling Relational Data with Graph Convolutional Networks,” arXiv preprint arXiv: 1703.06103 (2017).