

機械学習を用いた炉心特性予測のための特徴量重要度評価

Feature Importance Evaluation for Core Characteristics Prediction Using Machine Learning

*芳賀 周¹, 笠間 陸斗¹, 遠藤 知弘¹, 山本 章夫¹

¹名古屋大学

炉心計算は計算コストが高いため、炉心計算コードの代替として機械学習による炉心特性予測が検討されている。機械学習の予測精度には、機械学習に入力するデータ（特徴量）が大きく影響する。そこで、Permutation Importance を用いて燃料装荷パターンの特徴量重要度を定量化し、予測精度の向上を図った。

キーワード：機械学習、炉心計算、燃料装荷パターン、ニューラルネットワーク、特徴量重要度

1. 緒言：燃料装荷パターン最適化において、機械学習を用いることで炉心特性評価を高速化することが試みられている[1]。本研究では、機械学習の精度向上を目的として Permutation Importance(PI)[2]を用いて学習に用いる入力パラメータについて、学習への寄与度合（重要度）の定量化を行った。

2. 手法：PI の評価手順を図 1 に示す。まず、訓練データを用いてニューラルネットワークの学習を行う。次に、学習時に用いた 1 つの特徴量の中身をシャッフルする。それを検証データとし、学習したモデルを用いて予測データを算出する。予測データと訓練データとの誤差を相対誤差(RE)により評価する。RE が大きいほどモデルの予測においてシャッフルした特徴量が重要な役割を果たしていることを示している。




図 1 PI を用いた重要度の算出方法




図 2 各特徴量における重要度

3. 数値実験：3 ループタイプ PWR の寿命初期を対象とし、燃料装荷パターンの濃縮度・燃焼度・無限増倍率・2 群巨視的断面積などの計 10 種類を入力データ(特徴量)、燃料集合体毎の相対出力分布を出力データとした。入力データと出力データがセットで訓練データとなる。燃料配置をランダムに交換した 8000 セットの訓練データで学習を行い、PI により入力データの重要度を評価した。また、重要度の高い特徴量のみを用いた学習を行い、すべての特徴量を用いた学習と予測精度の比較を行った。

4. 結果：各特徴量の重要度を図 2 に示す。特徴量を 10 種類用いた場合、無限増倍率の重要度が最も高いという結果が得られた。

また、表 1 に示すように重要度の低い特徴量 3 種類を除いた 7 種類を用いた学習モデルの方が、特徴量が 10 種類の場合より誤差が小さかった。これは、特徴量が増えることにより、全てのパターンを網羅するための必要なデータ数が増えたこととクラスタリングの難易度が上がりデータの判別が難しくなったことで、モデルの予測精度が悪化したためであると考察した。

参考文献[1] Yamamoto A. Application of Neural Network for Loading Pattern Screening of In-Core Optimization Calculations. Nuclear Technology. 2003;144:63–75.

[2] Altmann A, Toloşi L, Sander O, et al. Permutation importance: a corrected feature importance measure. Bioinformatics. 2010;26:1340–1347.

* Amane Haga¹, Rikuto Kasama¹, Tomohiro Endo¹, Akio Yamamoto¹,

¹Nagoya University

表 1 特徴量 10 種類と 7 種類との比較

特徴量	RE [%]	MAX(RE) [%]
10	1.51	9.08
7	1.48	5.61