

AI を活用した圧力容器鋼中性子照射脆化予測の高度化

Modeling for Prediction of Irradiation Embrittlement of RPV steels using AI

京都大学
京都大学

中筋 俊樹
森下 和功

Toshiki NAKASUJI Student Member
Kazunori MORISHITA Member

Abstract

In order to keep nuclear safety, management of irradiation embrittlement of LWR pressure vessel steels is the one of important issues. In this study, we focus on the prediction of irradiation embrittlement. Conventionally, irradiation embrittlement prediction is performed by a numerical model based on the mechanism. In recent years, research in fields such as AI and Bayesian statistics has rapidly progressed. Therefore, in this study, in order to advance the irradiation embrittlement prediction, the irradiation embrittlement was predicted using AI. The development of a new irradiation embrittlement prediction method using AI was discussed in comparison with the current embrittlement prediction method.

Keywords: Irradiation Embrittlement, RPV steels, Multiscale Modeling, AI

1. はじめに

原子力発電所の構造物や機器は時間経過とともに劣化する。発電所の健全性を維持するために劣化した部品の修復や交換といった保全活動が必要となっている。一方で、圧力容器や格納容器などといった修復や交換ができない機器もあり、これらの機器の劣化が発電所そのものの稼働寿命を決定する要因の1つとなっている。発電所の安全を担保するには、取り替えられない機器の劣化評価が重要となる。

重要な経年劣化現象の1つに圧力容器鋼の中性子照射脆化が挙げられる。中性子の照射を受けると、圧力容器鋼は脆化する。脆化の指標として延性脆性遷移温度 (DBTT) が用いられており、脆化すると DBTT 値は上昇する。照射脆化の管理は、照射脆化予測式による DBTT 変化量の予測と圧力容器内に装荷された監視試験片の衝撃試験による DBTT 値の確認によって行われている^{[1][2]}。衝撃試験は JEAC4201-2007 の保全規定で定められた間隔で実施され、得られた DBTT データは脆化予測式の妥当性の確認やさらに精度の高い予測式の構築に用いられる。

照射脆化による DBTT 変化のデータ (Δ DBTT) は原子

炉の運転を開始した 40 年ほど前から得られている。そのデータ数は、国内商業軽水炉および材料試験炉で得られたものを合わせると 400 点程度存在する。日本の規制で使われている照射脆化予測式は、脆化のメカニズムに基づいたモデル式にこれらの DBTT データをフィッティングして構築されたものである。

近年は、人工知能 (AI) やベイズ等のデータサイエンスの研究が盛んに行われており、めざましい進展がみられる。そこでは具体的には、ビッグデータを活用して世論の動向調査などが行われている。照射脆化のデータは 400 点程度であり、ビッグデータと言うまでは無いが、AI 等を用いることができるほどのデータ数ではある。そこで、本研究では、データサイエンスの分野を参考にしてデータの高度利用を検討する。データの利用による照射脆化予測の高度化を行うため、AI により照射脆化の予測法の構築を試みた。現行の脆化予測法と比較して、AI を活用した新しい照射脆化予測法の構築を議論した。

2. 方法

AI は、SONY 社が提供している Neural Network Console を用いた。照射脆化の実測データ (Δ DBTT) は、すべて公開されていないため、現行規制の脆化予測式^{[1][2]}によって得られる DBTT の照射による変化量 (Δ DBTT) を実測値として取り扱った。特徴量は、従来の脆化予測法を参考に

表1 学習させたデータの照射条件および材料条件

Neutron flux [n/cm ² /s]	10 ⁸ , 10 ⁹ , 10 ¹⁰ , 10 ¹¹ , 10 ¹²
Neutron fluence [n/cm ²]	0 – 7.5 × 10 ¹⁹
Cu [wt%]	0.04, 0.1, 0.15, 0.20
Ni [wt%]	0.5, 0.6, 0.7




図1 ΔDBTTの実測値とAIによる計算値

して、中性子束、中性子照射量、Cu濃度、Ni濃度とした。学習に用いたデータセットの照射条件および材料条件を表1に示す。学習用データ総数は1980であり、学習用データを再現できるニューラルネットワーク構造をAIによって得る。

3. 結果および考察

AIで得られる最適なニューラルネットワーク構造により計算されたΔDBTTと実測データの間を関係を図1に示す。図中の1:1線の上にプロットがあると、実測値とAIによる計算値が一致することを示す。実測値が0°CとなるところでAI計算値と一致しない箇所が見られるが、脆化が進みΔDBTTが高くなった条件ではAI計算値が比較的良好に実測値を再現している。このときのAI計算値と実測値の差は、平均-0.1[°C]、標準偏差3.2[°C]に従う。

図2には、中性子束、Ni濃度を固定し、Cu濃度[wt%]が0.1, 0.07, 0.04のときのΔDBTTの照射量依存性をそれぞれ示す。なお、Cu:0.1, 0.04[wt%]の条件は学習用データかつ評価用データとしてAIに読み込ませている条件である。また、学習用データの間の脆化計算値を確認するため、現行規制の脆化予測法^{[1][2]}で得られる脆化計算値も図中に示す。図2から、Cu:0.1, 0.04[wt%]の条件では、学習させた点は勿論、学習させた点の間についても再現でき

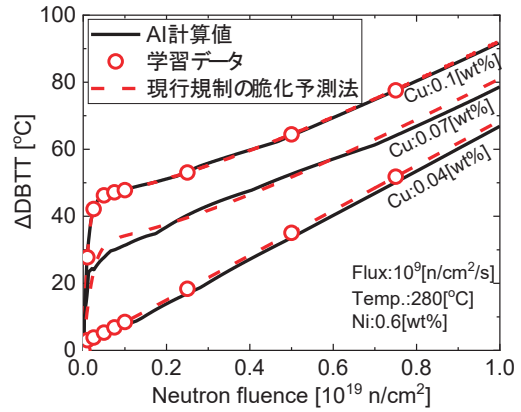


図2 ΔDBTTの照射量依存性

ていることが分かる。また、学習させたデータの照射量の最大値は7.5 × 10¹⁹ [n/cm²]であるが、それより高い照射量でもAIによる計算値と現行規制の脆化予測法による計算値は一致していることが確認できる。学習および評価に用いていないCu:0.07[wt%]の条件については、現行規制の脆化予測法による計算値とAI計算値の差の標準偏差は1.8[°C]程度であり、この範囲でAIによる照射脆化量の予測が可能であることが示された。

4. まとめ

照射脆化予測の高度化を目的に、AIによる照射脆化予測の検討を行った。実測データがないため、現行規制で用いられている脆化予測式によって得られたデータを実測値として取り扱い、AIに学習させた。その結果、学習させたデータとAIによる計算値は、標準偏差3.2[°C]で一致した。また、学習や評価に用いていない条件では、ΔDBTTが標準偏差1.8[°C]の範囲でAIによる計算値と現行規制の脆化予測法による計算値が一致することが分かった。この程度の範囲内でAIによる照射脆化予測が行えると考えられる。

参考文献

- [1] (社)日本電気協会, “原子炉構造材の監視試験方法”, JEAC 4201-2007, 2007.
- [2] (社)日本電気協会, “原子炉構造材の監視試験方法”, JEAC 4201-2007 [2013年追補版], 2013.