

令和5年度

文部科学省 国家課題対応型研究開発推進事業

原子力システム研究開発事業

人工知能技術と熱流動の融合による
データ駆動型プラント安全評価手法の開発

成果報告書

令和6年3月

国立大学法人 東京大学

本報告書は、文部科学省の原子力システム研究開発事業による委託業務として、国立大学法人 東京大学が実施した令和 3 年度－令和 5 年度「人工知能技術と熱流動の融合によるデータ駆動型プラント安全評価手法の開発」の成果を取りまとめたものです。

目次

概略	vi
1. はじめに	1-1
2. 業務計画	
2.1 全体計画	2.1-1
2.2 令和5年度の成果の目標および業務の実施方法	2.2-1
3. 令和5年度の実施内容および成果	
3.1 データ駆動型熱流動モデル開発【R3-R5】	3.1-1
3.1.1 空気-水系円管における流動様式遷移モデルの開発【R3-R5】	3.1-1
3.1.2 沸騰系矩形管における流動様式遷移モデルの開発 (再委託先：電気通信大学)【R3-R5】	3.1-5
3.1.3 AIモデル構築・評価(東京大学、再委託先：電気通信大学)【R3-R5】	3.1-15
3.2 データ駆動型熱流動解析手法開発(再委託先：原子力機構)【R3-R5】	3.2-1
3.2.1 JUPITERによる垂直上昇二相流解析【R3-R5】	3.2-1
3.2.2 JUPITERによる噴流着水解析【R3-R5】	3.2-4
3.3 データ駆動型評価モデル開発(東京大学、再委託先：NEL)【R3-R5】	3.3-1
3.3.1 GRAPEによるLOCA事故事象データベース構築+AIモデルの構築と評価 【R3-R5】	3.3-1
3.3.2 運転員操作を有する事故事象パラメータ解析【R3-R5】	3.3-3
3.3.3 AIモデル評価【R3-R5】	3.3-11
3.4 研究推進	3.4-1
4. 結言	4-1
5. 参考文献	5-1
添付資料	A-1

表一覧

表 2.1.1-1	本事業における全体計画	2.1-1
表 3.1.2-1	スラグ流への流動様式遷移直前における加熱壁近傍ボイド率	3.1-10
表 3.1.3-1	「明確に分類可能な流量条件」における識別実行結果	3.1-16
表 3.2.1-1	JUPITER による垂直上昇二相流解析の流動条件	3.2-1
表 3.2.2-1	物体検出モデル学習のためのハイパーパラメータ	3.2-8
表 3.3.2-1	試評価版 SGTR 解析条件（モデル学習およびモデル評価のための解析）	3.3-5
表 3.3.2-2	試評価版 SGTR 解析ケース（モデル学習およびモデル評価のための解析）	3.3-6
表 3.3.2-3	試評価版 SGTR 解析条件（モデル学習のための解析 54 ケース）	3.3-7
表 3.3.2-4	AI モデルに学習させたパラメータのリスト	3.3-7
表 3.3.2-5	SGTR 解析条件（モデル学習のための解析 150 ケース）	3.3-10
表 3.3.2-6	SGTR 解析条件（モデル評価のための解析 3 ケース）	3.3-10
表 3.3.3-1	LSTM モデルにおけるハイパーパラメータ最適値のまとめ	3.3-11
表 3.3.3-2	データセットカット割合を変化させた場合の LSTM 分類器の性能	3.3-15
表 3.3.3-3	LSTM 予測モデルのハイパーパラメータのまとめ	3.3-15

図一覧

図 3. 1. 1-1	流動様式判定基準検証のための単純構造 CNN (A)	3. 1-2
図 3. 1. 1-2	予測確率のフィッティング例	3. 1-4
図 3. 1. 1-3	流動様式遷移領域の定義	3. 1-5
図 3. 1. 2-1	沸騰系二相流可視化実験装置	3. 1-7
図 3. 1. 2-2	試験部および透明ヒーターの構造	3. 1-7
図 3. 1. 2-3	実験中における高速度カメラと赤外線カメラの配置状況	3. 1-8
図 3. 1. 2-4	高速度カメラと赤外線カメラにより得られる画像データの 1 例	3. 1-8
図 3. 1. 2-5	沸騰系二相流における流動様式遷移の観察例 ($G=300 \text{ kg/m}^2\text{s}$, $qW=1.3 \text{ MW/m}^2$)	3. 1-9
図 3. 1. 2-6	熱流束の増加に伴う気泡サイズの変化	3. 1-9
図 3. 1. 2-7	非近接発泡核 A, B における蒸気泡生成の様子	3. 1-11
図 3. 1. 2-8	近接発泡核 C, D における蒸気泡生成の様子	3. 1-12
図 3. 1. 2-9	非近接発泡核 A, B における局所壁面温度の時間変化	3. 1-13
図 3. 1. 2-10	近接発泡核 C, D における局所壁面温度の時間変化	3. 1-13
図 3. 1. 2-11	気泡生成頻度 f_B と発泡核離脱時気泡径 d_B の関係	3. 1-14
図 3. 1. 2-12	実験定数 C^* と干渉率 η の関係	3. 1-14
図 3. 1. 3-1	流動様式遷移領域における画像の識別傾向	3. 1-18
図 3. 1. 3-2	流動様式遷移領域におけるモデルの予測確率時間変化	3. 1-19
図 3. 1. 3-3	j_g の変化に応じた流動様式予測確率の時間平均値の変化 (1/2)	3. 1-20
図 3. 1. 3-4	j_g の変化に応じた流動様式予測確率の時間平均値の変化 (2/2)	3. 1-21
図 3. 1. 3-5	(A) Simple CNN モデルのプーリング層における特徴量マップの例	3. 1-22
図 3. 1. 3-6	物体検出アルゴリズムにより検出されたボイド率変動	3. 1-25
図 3. 1. 3-7	物体検出アルゴリズムにより検出された気泡離脱径	3. 1-25
図 3. 2. 1-1	垂直上昇二相流計算結果。左からケース A、ケース B1、ケース B2。 各ケースの左図および右図がそれぞれ令和 4 年度、令和 5 年度の結果。 右端図はケース B2 の実験結果	3. 2-2
図 3. 2. 1-2	CNN による JUPITER コードによる解析結果の分類： スラグ流の条件における中間層のヒートマップを図示	3. 2-4
図 3. 2. 2-1	$FrD_{FrL}=0.25$ (a)、1.25 (b)、3.8 (c) での気泡群形状の実験結果	3. 2-5
図 3. 2. 2-2	$FrD_{FrL}=0.25$ (a)、1.25 (b)、3.8 (c) での気泡群形状の解析結果	3. 2-6
図 3. 2. 2-3	ノズルピッチに対する侵入長さ	3. 2-7
図 3. 2. 2-4	物体検出モデル学習のためのデータ拡張方法	3. 2-7
図 3. 2. 2-5	物体検出モデルによる解析結果	3. 2-8
図 3. 2. 2-6	物体検出モデルによる気泡侵入長さの実験値と比較	3. 2-9
図 3. 2. 2-7	物体検出モデルによる気泡群形状パラメータの抽出	3. 2-9
図 3. 3. 1-1	LSTM モデルを用いた水位予測性能	3. 3-2
図 3. 3. 1-2	LSTM モデルを用いたホットレグ温度予測性能	3. 3-3

図 3.3.1-3	LSTM モデルを用いた冷却水流量予測性能	3.3-3
図 3.3.2-1	令和5年度における AI モデル学習用データ拡充のための 解析条件の概要	3.3-9
図 3.3.3-1	ルックバック値ごとの LSTM モデルの予測プロット	3.3-12
図 3.3.3-2	ルックバック値あたりの LSTM モデルの絶対誤差分布	3.3-13
図 3.3.3-3	(a)最適水位、(b)ホットレグ温度、(c)一次冷却材流量の予測結果	3.3-13
図 3.3.3-4	データセットカット割合を変化させた場合の LSTM 回帰の性能	3.3-14
図 3.3.3-5	LSTM 回帰の予測曲線最適値のまとめ (8%データセットカット)	3.3-15
図 3.3.3-6	MICN 全体構造 文献[27]より引用	3.3-17
図 3.3.3-7	MICN の内部構造詳細 文献[27]より引用	3.3-17
図 3.3.3-8	MICN の学習における損失関数の推移	3.3-20
図 3.3.3-9	評価用データセットでの積算流量の推移と推定結果	3.3-20
図 3.3.3-10	追加学習時の損失関数の推移	3.3-21

略語一覧

AI	: Artificial Intelligence	(人工知能)
BOC	: Beginning of Cycle	(サイクル初期)
BWR	: Boiling Water Reactor	(沸騰水型軽水炉)
CFD	: Computational Fluid Dynamics	(数値流体力学)
CNN	: Convolutional Neural Network	(畳み込みニューラルネットワーク)
CR	: Closure Relations	(閉包関係)
GPU	: Graphics Processing Unit	(画像処理装置)
IMPS	: Impedance Sensor	(インピーダンスセンサー)
IT	: Integral Test	(積分判定法)
ITO	: Indium Tin Oxide	(酸化インジウムスズ)
LOCA	: Loss of Coolant Accident	(冷却水喪失事故)
LSTM	: Long Short Term Memory	(長・短期記憶)
MICN	: Multi-scale Local and Global Context	(多スケールコンテキスト)
NEL	: Nuclear Engineering, Ltd.	((株) 原子力エンジニアリング)
PWR	: Pressurized Water Reactor	(加圧水型軽水炉)
RMSE	: Root Mean Squared Error	(二乗平均平方根誤差)
SET	: Separate Effect Test	(個別作用判定法)
SGD	: Stochastic Gradient Descent	(確率的勾配降下法)
SGTR	: Steam Generator Tube Rupture	(蒸気発生器細管破断)
SPDS	: Safety Parameter Display System	(安全パラメータ表示システム)
TH	: Thermal Hydraulics	(熱流動)
TRAC	: Transient Reactor Analysis Code	(過渡時熱水力解析コード)
TRACE	: TRAC/RELAP Advanced Computational Engine	(原子炉過渡事象解析コード)
WMS	: Wire Mesh Sensor	(ワイヤーマッシュセンサー)

概略

原子力プラントにて生じる熱流動事象は、あらゆる時空間スケールでの質量・運動量・エネルギー輸送が複雑にリンクする多次元・マルチスケール現象として知られる。熱水力学解析の精度は、保存則の解法に必要な閉包関係や構成方程式に大きく依存しており、近年重要視されている高解像度解析を効率的に実施するためにも、モデルの精度向上はこれまで以上に重要視されている。近年、熱水力学計測機器の発展等から、多次元かつ多量のビッグデータが整備されやすくなっており、AI (Artificial Intelligence : 人工知能) 技術と熱流動の技術統合プラットフォーム構築が期待されるが、AI 技術により実現可能な具体的な解析が明らかにされておらず、熱流動分野における機械学習の有効性、優位性が未解明なのが現状である。

原子力プラントにて生じる熱流動事象は、あらゆる時空間スケールでの質量・運動量・エネルギー輸送が複雑にリンクする多次元・マルチスケール現象として知られる。熱水力学解析の精度は、保存則の解法に必要な Closure Relations (閉包関係 : 以下、CR と略記。) や構成方程式に大きく依存しており、近年重要視されている High-resolution, High-fidelity 解析を効率的に実施するためにも、CR 開発の精度向上はこれまで以上に重要となっている。原子力システムコードに用いられる保存則を解く上で必要となる CR 或いは構成方程式・物理モデルを開発するにあたり、従来手法では、実験等により説明可能となる現象論によるものが一般的である。これらの構成方程式開発は、実事象からのスケール則に基づき設計された Integral Test (積分判定法 : 以下、IT と略記。) や Separate Effect Test (個別作用判定法 : 以下、SET と略記。) から詳細な高解像度データを取得し、①力学ベースの機構論的モデルや、②関数フィッティングをベースとした実験相関式等のアウトプットを導出する形が一般的である。さらに、気液二相流の流動様式遷移条件や、蒸気凝縮モードを整理した凝縮マップ等においては、熱水力学解析コード開発初期の 1970~1980 年代以降の目視に基づいた③観測モデルが依然として使われているのが現状である。原子力プラントの安全解析は CR の精度に依存しているが、RELAP (Reactor Excursion Loop Analysis Package : 軽水炉熱力学安全解析コード) や TRACE (TRAC/RELAP Advanced Computational Engine : 原子炉過渡事象解析コード) 等の現行の熱流動解析コードに使用されている偏微分方程式群では、上述した①、②、③によるモデルが多様に混在しており、実事象への適用範囲やモデル精度にバラツキが存在する。この抜本的解決には、①による CR 開発が理想的である。しかしながら、時間的コストに加え、複雑な気液界面挙動変化に伴う熱流動においては現在の計測技術ですべての主要パラメータの高精度計測を実施するには困難を伴う。その結果、SET による②、③のアプローチが現実的な CR 開発手法として 1990 年代以降繰り返し継続されている。このような長期に及ぶモデル開発プロセスが、新型原子炉の設計や、前例の無い新たな熱水力学事象の解析の実現に制約となるのに加え、異なる開発源による構成方程式の組み合わせは偏微分方程式の不良設定 (ill-posed) や、数値的不安定を起因する原因ともなる。また、③のアプローチにより開発される目視観測モデルに付随する観測者の主観に伴ったバイアスの定量化に関しても、課題が残る。

第三次 AI ブーム以降、機械学習や深層学習を活用した研究が多種多様な分野において提唱されている。特に、データ駆動型研究への期待は年々高まっており、原子力安全の研究開発においてはアイダホ国立研究所やノースカロライナ州立大学が AI 技術を取り入れた先駆的な研究を展開している。熱流動分野においても、近年、計測機器の高精度化や、高速度カメラやサ

ーモカメラの普及に加え、大規模計算機資源の低コスト化や記憶媒体の大容量化等により、多次元かつ多量のデータ（ビッグデータ）が整備・蓄積しやすい分野へと発展しており、AI 技術と熱流動の技術統合プラットフォームができつつあると言える。しかしながら、AI 普及に必要なビッグデータは構築できるものの、熱流動分野において実際に何が実現でき、如何なる事象に活用可能であるかといった点が可視化できておらず、熱流動分野における機械学習の有効性、優位性が未解明であるのが現状である。また、AI モデルを構築する際の学習に用いられるデータの品質・精度次第で解析結果がバイアスされる懸念等も存在するが、モデルによる出力の検証手法が確立されていない点も懸念事項として存在する。

本業務においては、画像認識と物体検出を軸とした AI 技術に着目し、従来のモデル開発では困難な、データベースに潜む関係性を捉える「データ駆動型アプローチ」を検討する。本業務においては、大学、研究機関、民間企業を含めた 4 機関による知見共有の下、AI 融合によるデータ駆動型モデル開発に向けた検討を目的とし、AI 技術と熱流動の融合によるデータ駆動型プラント安全評価手法の開発を目指す。特に、目視で行われることも多い画像データからの流れ場解析等においては、畳み込みニューラルネットワーク（Convolutional Neural Network：以下、CNN と略記。）によるシーン認識や物体検出アルゴリズムを用いることで、観測者によるバイアスを低減させ、データ主体の流れ場認識や、気泡追跡による界面抗力評価が可能となる。

本業務では、「認識」、「検出」の AI 技術に着目し、前述した①、②、③による従来手法では困難な、データベース背後に潜む関係性を捉えるアプローチとして、AI 融合によるデータ駆動型モデル開発に向けた検討を目的とする。これにより、AI 技術と熱流動（Thermal Hydraulics：以下、TH と略記。）の融合によるデータ駆動型プラント安全評価手法の開発を目指す。本業務により検討される手法は原子力熱流動を基盤としたプラント安全解析のみに留まらず、気液二相流が生じる熱交換システム、化学プラント、並びに天然資源輸送等の分野においても利用が期待される。本業務では、AI 技術と熱流体力学の融合を検討する上で 3 つのサブテーマを提案する。具体的には、流動様式遷移現象を念頭に置いた (1) データ駆動型熱流動モデル開発、CFD（Computational Fluid Dynamics：数値流体力学）による計算データベースを基とした (2) データ駆動型解析手法の開発、そしてモデル応用を念頭に置いた (3) データ駆動型評価モデルの開発、である。

本業務 3 年目の令和 5 年度においては、これまでに構築したデータベースを基に、AI モデルの構築および検証を実施した。課題 (1) においてはこれまでに取得した広範囲に及ぶ流動様式遷移の画像を基に、データ駆動型遷移モデルを構築し、データに基づいた客観的な流動様式判別手法を開発した。課題 (2) においては、CFD 解析により出力された気液界面形状の分類が可能な機械学習モデルを構築し、客観的な気泡群の形状評価が可能なデータ駆動型モデルの構築を行った。課題 (3) においては、これまでに RELAP5 により構築したデータベースを用い、AI 技術に基づいた事象評価モデルを構築し、評価を行った。本報告書においては、令和 3 年度～令和 5 年度の実施項目の成果を最終年度報告としてまとめる。

1. はじめに

原子力プラントにて生じる熱流動事象は、既存の一次元解析コードや、多次元 CFD 解析等が示すように、あらゆる時空間スケールでの質量・運動量・エネルギー輸送が複雑にリンクする多次元・マルチスケール現象として知られている。原子力熱流動等の解析に使用される二流体モデルをはじめとした支配方程式の精度は、保存則の解法に必要な閉包関係や構成方程式に大きく依存している。特に、近年重要視されている高解像度 (High-resolution、High-fidelity) 解析を効率的に実施する上でも、気液界面輸送項をはじめとした閉包モデルの精度検証並びに向上は、これまで以上に重要な課題となっている。近年、熱水力計測機器の高度化や汎用化により多次元かつ多量のビッグデータが整備されやすくなっており、AI 技術と TH の技術統合プラットフォームの構築が期待される。しかしながら、AI 技術を TH 現象へ応用する具体的な手法は依然として手探り状態であり、熱流動分野における機械学習の有効性、優位性が未解明なのが現状である。

本業務においては、近年の機械学習モデルが得意とする「認識」、「検出」の分野に着目し、これまでに閉包モデルとして採用されている関数フィッティングや目視観測によるモデル開発手法を改め、データベース背後に潜む関係性を捉えるアプローチの構築を目指す。具体的には、AI 融合によるデータ駆動型モデル開発を目的とし、AI 技術と TH の融合によるデータ駆動型プラント安全評価手法の開発を目指す。

上述した観点から、本業務においては 3 つのサブテーマ (課題) を設定し、多角的方面からの AI 技術と TH の融合を検討する。はじめに、流況観察や圧損データからの目視観測による従来手法がスタンダードとなっている流動様式線図に着目する。本課題においては、高速度カメラを使用し、取得された画像データベースを深層 CNN 等の機械の「目」により識別・クラスタリングを試み、既存の流動様式遷移条件との比較検証を目指す。様々な条件による流動様式を検証するため、円管・断熱系 (東京大学) と、矩形管・沸騰加熱系 (電気通信大学) におけるデータベースの修得を目指す。2 つ目のサブテーマとしては、原子力機構との協力の下、CFD 解析により得られた円管・断熱系における流動様式と、着水現象に起因する気泡巻き込み現象に着目し、数値解放により得られた流動様式遷移と、気泡侵入形状のクラスタリングを試みる。3 つ目のサブテーマは熱流動モデルの応用に着目し、安全解析コードやシミュレータからのデータ出力による機械学習モデルの構築を行い、軽水炉における事故事象の特定や、事故分類等の手法構築を目指す。本課題においては、(株) 原子力エンジニアリング (Nuclear Engineering, Ltd. : 以下、NEL と略記。) と協力し、PWR 向けの RELAP コードを活用した事故時プラント挙動のデータ群を取得する。また、シミュレータを用いたプラント操作訓練を行う際に取り上げられる事故事象や操作事象を取り上げ、Utility 現場における具体的な AI 活用・応用の提案を目指す。

以上に示した通り、本業務は基礎から応用を網羅した 3 課題が軸となっており、産学連携による多角的観点からデータ駆動型プラント安全評価手法の開発に取り組むものである。

2. 業務計画

2.1 全体計画

本業務の全体計画図を表 2.1-1 に示す。本業務は 3 年計画となっており、環境整備、データベース構築、AI モデル構築、そして評価・検証の順に進める流れとなっている。信頼性の高い AI モデルの構築には膨大なデータ（ビッグデータ）が必要不可欠であることから、初年度の令和 3 年度においては高速度画像データ収集のための実験環境整備（課題 1）、CFD 解析による計算環境整備（課題 2）、安全解析コード GRAPE を実行する上での計算環境整備（課題 3）を中心に進めた。2 年目の令和 4 年度は主にデータ収集に注力し、実験並びに解析より出力されたデータベースの構築を行った。3 年目の令和 5 年度は、過去 2 年間に亘り構築を行ってきたデータベースを基盤に、AI モデルの構築並びに評価を行い、各課題にて構築したデータ駆動型熱流動モデルの評価を行った。

表 2.1-1 本事業における全体計画

項目	年度	令和3年度	令和4年度	令和5年度
(1) データ駆動型熱流動モデル開発	① 空気-水系円管における流動様式遷移モデルの開発	試験装置構築	実験データ収集	試験及び評価まとめ
	② 沸騰系矩形管における流動様式遷移モデルの開発 (再委託先：電気通信大学)	試験装置構築	実験データ収集	試験及び評価まとめ
	③ AI モデル構築・評価（東京大学、再委託先：電気通信大学）	文献調査・情報収集	AIモデル構築・評価	
(2) データ駆動型熱流動解析手法開発（再委託先：原子力機構）	① JUPITERによる垂直上昇二相流解析	計算環境整備 予備解析	計算データ出力	深層学習モデル構築 評価まとめ
	② JUPITERによる噴流着水解析	計算環境整備 予備解析		深層学習モデル構築 評価まとめ
(3) データ駆動型評価モデル開発（東京大学、再委託先：NEL）	① GRAPEによるLOCA事故事象データベース構築+AIモデルの構築と評価	計算環境整備	データベース構築期間	評価まとめ
	② 運転員操作を有する事故事象パラメータ解析	計算環境整備・解析対象の選定	データベース構築期間	評価まとめ
	③ AI モデル評価	文献調査・情報収集		評価モデル構築
(4) 研究推進		まとめ・評価	まとめ・評価 関係者間打合せ	まとめ・評価 関係者間打合せ

2.2 令和5年度の成果の目標および業務の実施方法

令和5年度の本業務の計画概要を以下に記す。

課題(1) データ駆動型熱流動モデル開発

- ① 空気-水系円管における流動様式遷移モデルの開発
二相流画像データベース構築より流動様式遷移モデルの開発を行い、構築されたモデルの出力検証（試験）と評価を行う。
- ② 沸騰系矩形管における流動様式遷移モデルの開発（再委託先：電気通信大学）
沸騰二相流画像データベースより流動様式遷移モデルの開発を行い、構築されたモデルの出力検証（試験）と評価を行う。
- ③ AIモデル構築・評価（東京大学、再委託先：電気通信大学）
訓練データを用いたAIモデルの構築を行い、従来の画像処理方法との比較検証を行い、AIモデルのメリット/デメリットを評価する。

課題(2) データ駆動型熱流動解析手法開発（再委託先：原子力機構）

- ① JUPITERによる垂直上昇二相流解析
CFDにより得られた垂直上昇二相流データからデータ駆動型熱流動評価として深層学習モデルの構築を行い、得られた出力結果の評価を行う。
- ② JUPITERによる噴流着水解析
CFDにより得られた計算データベースから、データ駆動型の噴流着水解析手法として深層学習モデルの構築を行い、得られた出力結果の評価を行う。

課題(3) データ駆動型評価モデル開発（東京大学、再委託先：NEL）

- ① GRAPEによるLOCA事故事象データベース構築+AIモデルの構築と評価
GRAPEにより取得したデータベースから、事故事象評価モデルの構築を行い、出力結果を評価し、成果をまとめる。
- ② 運転員操作を有する事故事象パラメータ解析
対象事例において構築したデータベースより、パラメータ解析を実施する。
- ③ AIモデル評価（東京大学、再委託先：NEL）
 - ①、②におけるAIモデルを構築し、モデルの出力結果の評価を行う。

(4) 研究推進

研究代表者の下で各研究項目間の連携を密にして、研究を進める。研究実施計画を推進するための関係者間の打ち合わせを実施する。

3. 令和5年度の実施内容および成果

3.1 データ駆動型熱流動モデル開発【R3-R5】

3.1.1 空気-水系円管における流動様式遷移モデルの開発【R3-R5】

【R3-R4】

令和3年度は、二相流データベースの構築に必要な実験装置の立ち上げを行った。

令和4年度は、深層学習による画像分類および物体検出アルゴリズムを適用し、垂直上昇二相流における流動様式識別モデルを構築して画像解析を行った。様々な流量条件の画像で学習および解析を行うため、高速度カメラを使用し、東京大学に設置されている空気-水系二相流実験装置を使用し、二相流画像データベース構築を実施した。

気液二相流ループ実験装置にて、画像および流量計、Impedance Sensor (IMPS: インピーダンスセンサー)、WMS (Wire Mesh Sensor: ワイヤメッシュセンサー) の各計測データを取得した。本装置において、気体は圧縮機で圧縮した常温の空気、液体は水道水と脱イオン水を混合した常温の水である。二相流ループの垂直上昇部は、内径 29 mm の透明なアクリル配管である。撮影部の配管周囲にはアクリル製のウォータージャケットを設置し、配管周囲を水で満たした。これにより、管内の壁近傍を通過する気液相が、光の屈折によって見切れた画像となる現象を緩和できる。

ウォータージャケット外部に高速度カメラを設置し、1つの流量条件につき20秒間撮影を行った。また、撮影部近傍の流路にIMPSとWMSを設置しボイド率信号を取得したほか、水と空気の体積流量をそれぞれ計測した。これは、流動様式の教師データを作成する上で、観測者によるバイアスを低減させるため、ボイド率の確率密度分布図とも照らし合わせながらラベルデータを作成するためである。データ取得は気液流量を様々に変化させ、1セットあたり80または99条件を4セット行い、合計377の流量条件でデータを取得した。

空気-水系円管においては、8種類のネットワークを学習させ、流動様式分類モデルの構築を行った。Data1とData2の正解ラベル付き流量条件105種類の画像210,000枚を学習に用い、そのうち8割を学習用、2割を検証用とした。バッチサイズはGPU (Graphics Processing Unit: 画像処理装置) メモリの使用状況に応じ、モデルごとに8から64の間で設定した。損失関数はクロスエントロピー誤差、最適化手法は確率的勾配降下法 (Stochastic Gradient Descent: 以下、SGDと略記。) を用いた。学習率は初期値を0.01とし、エポック10回ごとに0.1倍ずつ減少させた。過学習対策として、Validation loss (精度検証データにおける損失) が最小値を更新してから10エポック以内に次の更新が行われない場合、学習を終了するEarly stoppingを導入した。エポック数の上限は100としたが、実際にはすべてのモデルがEarly stoppingにより学習を終了した。本課題に使用したネットワークの詳細については令和4年度の成果報告書を参照いただきたい。

既存モデルの一般的な精度向上方法として、計算リソースの大きさに応じ、モデルの深さ(層の数)、幅(チャンネル数)、解像度(画像サイズ)を増加させるスケールアップが挙げられる。3者を適切なバランスで増加させることで、効率の良いスケールアップ手法を検討する研究が行われ、その中で開発されたのがEfficientNetである。B0~B7の8種類のモデルが作られ、ベースラインのEfficientNet-B0は、モバイル用モデルを最適に設計したMnasNetを利用している。B0を段階的にスケールアップしてB1~B7が開発され、B7

は同等精度の既存モデルに比べ、少ないパラメータ数と短い学習時間を達成した。

ネットワークの訓練においては正解ラベル付き流量条件からなる 105 種類の画像 210,000 枚を学習に用い、そのうち 8 割を学習用、2 割を検証用とした。最終的なモデルの Validation loss と Validation accuracy として、Accuracy (精度検証データにおける正解率) はすべての転移学習モデルにおいて 99.8%以上に達していることから十分な精度に達したと言える。Loss が最も低く Accuracy が最も高いモデルは(F) ResNet152 であった。全体的に、層構造が複雑で高性能とされるネットワークほど学習精度が高い傾向にあると言えることが分かった。以上が、令和 4 年度までの課題(1)①の概要である。

【R5】

令和 5 年度は、令和 4 年度に構築した気液二相流画像データベースより流動様式遷移モデルの開発を行った。二相流モデルの構築にあたり、令和 4 年度までに構築した CNN を最適化し、図 3.1.1-1 に示したネットワーク構成とした。

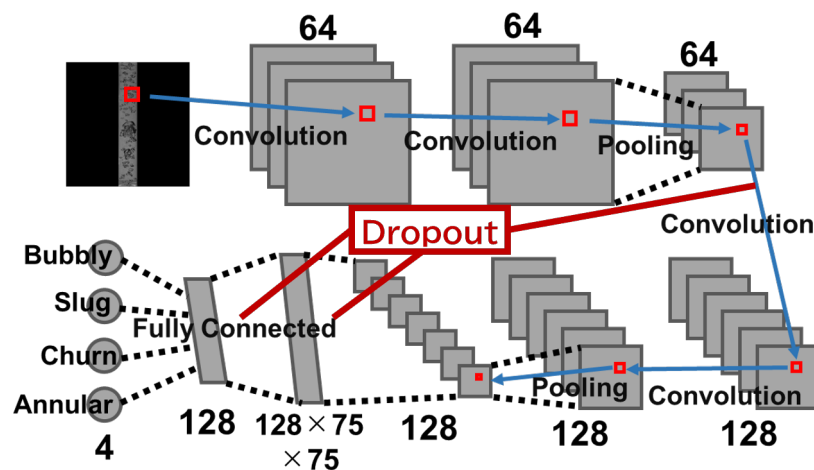


図 3.1.1-1 流動様式判定基準検証のための単純構造 CNN (A)

構築した流動様式遷移モデルの出力検証 (試験) と評価を行った。

AI を用いた流動様式遷移領域を定量的に定義するため、離散値である遷移領域流動条件の予測確率を、 j_g を変数とする連続関数として定義した。フィッティング関数として、 x 方向に線対称であり、 y 方向に 0 から 1 の間で連続的に変化する以下のロジスティック関数を用いた。

$$p_{\text{regime}} = \frac{1}{1 + \exp\{-k(j_g - j_{g0.5})\}} \quad \text{式(3.1.3-1)}$$

ここで、 p_{regime} ($0 \leq p_{\text{regime}} \leq 1$) は各流動様式の予測確率であり、 $j_{g0.5}$ は $p_{\text{regime}} = 0.5$ となる j_g である。また、 k は曲線の形状を特徴付けるパラメータである。 j_g は各点 (流量条件) において既知であるため、 k および $j_{g0.5}$ を段階的に変化させて p_{regime} の誤差が最も小さくなる k および $j_{g0.5}$ を求めた。気泡流とスラグ流遷移領域の気泡流確率、スラグ流とチャー

ン流遷移領域のスラグ流確率、チャーン流と環状流遷移領域の環状流確率に対するフィッティング結果例を図 3.1.1-2 に示す。図 3.1.1-2 のように、0 付近と 1 付近以外の中間領域に 2 つ以上の点が存在する場合は、概ね妥当なフィッティングとなった。I、II、III のような遷移領域のグループを Data1 から Data4 で複数作り、フィッティング結果が概ね妥当となるものを選別した結果、気泡流－スラグ流、スラグ流－チャーン流、チャーン流－環状流でそれぞれ 5 種類、9 種類、6 種類の遷移領域フィッティング関数が定義された。ここで、 $p = 0.05$ と $p = 0.95$ に対応する $j_{g0.05}$ と $j_{g0.95}$ の間を遷移領域と定義し、 $j_{g0.5}$ を遷移中間点とする。遷移領域と遷移中間点を図 3.1.1-3 に示す。図 3.1.1-3 より、スラグ流からチャーン流への遷移は、Mishima-Ishii 線図と比較し、大幅に小さい j_g で生じる結果が得られ、その差は j_f が大きい場合により顕著である。チャーン流と環状流の遷移は Mishima-Ishii 線図よりやや小さい j_g で始まるが、遷移の終端は概ね線図と一致している。気泡流とスラグ流の遷移は Mishima-Ishii 線図より小さい j_g で始まるが、 j_f が大きい場合は遷移の終端が線図と一致しているのに対し、 j_f が小さい場合は線図より小さい j_g で遷移が終わる傾向が見られた。Mishima-Ishii 線図ではボイド率 0.3 で気泡流からスラグ流への遷移が起こると仮定し、以下の式に $\alpha = 0.3$ を代入して遷移式としている。

$$j_f = \left(\frac{1}{C_0 \alpha} - 1 \right) j_g - \left(\frac{\sqrt{2}(1-\alpha)^{1.75} \sigma g \Delta \rho}{C_0 \rho_f^2} \right)^{0.25} \quad \text{式(3.1.3-2)}$$

ここで、遷移基準の α を 0.3 より小さい値とした場合の線図を図 3.1.1-3 に示す。 j_f が大きい場合は、ボイド率がおよそ 0.2 から 0.3 にかけて遷移が生じる。一方で j_f が小さい場合は、0.15 よりも小さいボイド率で遷移が始まり、0.2 前後で既にスラグ流に遷移している。このため実際の気液二相流では、一定のボイド率で気泡流からスラグ流への遷移が生じるのではなく、液相流量が小さいほど小さいボイド率で遷移が生じると推測できる。

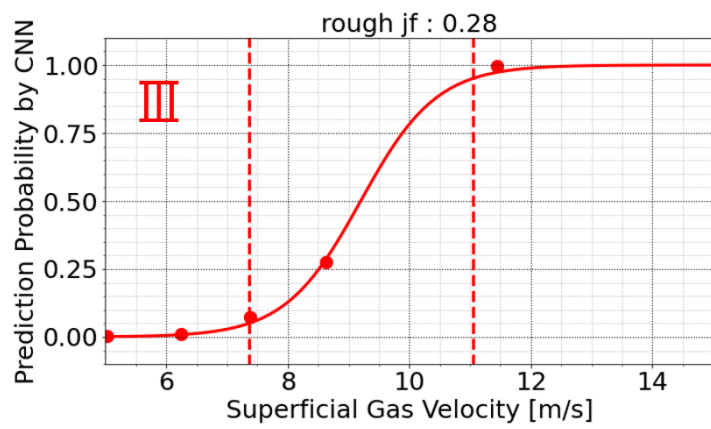

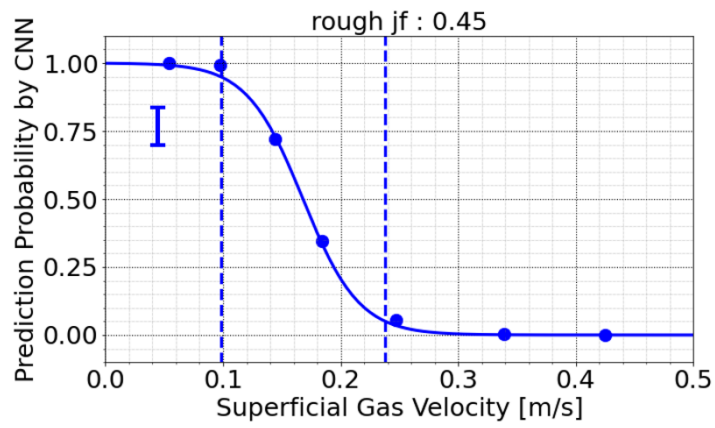
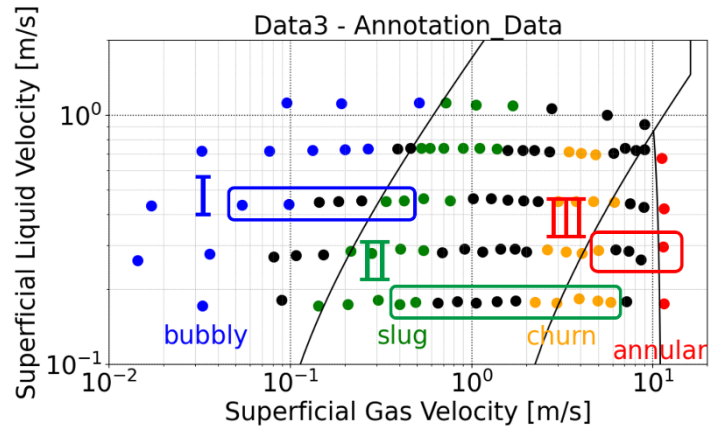


図 3.1.1-2 予測確率のフィッティング例

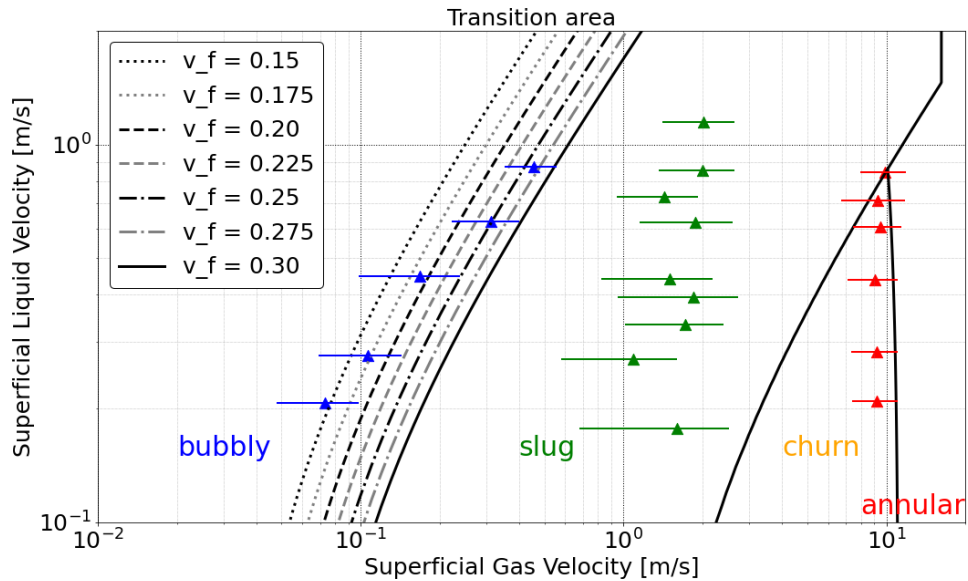


図 3. 1. 1-3 流動様式遷移領域の定義

3. 1. 2 沸騰系矩形管における流動様式遷移モデルの開発（再委託先：電気通信大学）

【R3-R5】

【R3-R4】

令和 3 年度は、実験データベース構築に必要な試験装置の立ち上げを行った。

令和 4 年度は、蒸気-水系矩形管実験装置を使用し、沸騰二相流画像データベースを構築した。AI モデル構築用の訓練データベースを構築するための第一ステップとして、可視化が最も容易な低質量流束条件で実験を実施した。質量流束を $G=500 \text{ kg/m}^2\text{s}$ 、壁面熱流束を $q_w=1,000 \text{ kW/m}^2$ で一定として、入口流体温度 T_{in} を $65\sim 95^\circ\text{C}$ の範囲において 5°C 刻みで設定して画像データを収集した。 $T_{in}=65, 70^\circ\text{C}$ では小気泡のみが存在するが、 $T_{in}=75^\circ\text{C}$ 程度より T_{in} の低下とともに気泡サイズが徐々に大きくなり、 $T_{in}=90, 95^\circ\text{C}$ では流路を覆うような大気泡が形成され、流動様式は気泡流からスラグ流に遷移している様子が見られる。ここで、水・空気系に代表される通常の気液二相流では、気液混合部から十分に下流の準平衡状態でボイド率等の計測および画像データの収集が行われる場合が多い。このため、相分布等は比較的安定した状態にある。一方、別に実施した沸騰二相流では、加熱壁で蒸気生成が行われつつ相分布が空間発展していく途中過程を捉えているため、気泡の合体と分裂を複雑に繰り返す過程で気泡は激しい変形を伴っている。特に、 $T_{in}=90, 95^\circ\text{C}$ における画像を見ると、水・空気二相流中でよく見られる美しい流線形の大気泡とは異なり、複雑な形状を呈していることが分かる。これより、水・空気二相流の画像データを用いて構築した AI モデルをそのまま沸騰二相流に適用すれば、許容できない予測誤差を生じる可能性が示唆された。以上が、課題(1)②の令和 4 年度までの実施概要である。

【R5】

令和 5 年度は、令和 4 年度に構築した沸騰二相流画像データベースより、流動様式遷移モデルの開発を行った。空気-水系に代表される非加熱で相変化を伴わない気液二相流で、

特に気相と液相の流量が一定の場合、圧力変化に起因する気相の密度変化、気泡の合体・分裂に伴う気液界面積の変化、環状流中における液膜・液滴間の質量輸送等の影響は有るものの、流動は概ね発達した状態にあり、流れ方向の変化は顕著ではない場合が多い。一方、原子炉内の冷却材流路で生じる沸騰系二相流では、加熱壁からの熱入力により蒸気流量が軸方向に増加する。また、特に液温が飽和温度に満たないサブクール沸騰域では、発泡核における気泡成長とサブクール液中における気泡凝縮により、個々の気泡のサイズおよび形状は、時々刻々極めて複雑に変化する。このため、画像解析に基づく気液二相流の流動状態の把握は、非加熱系二相流よりも相対的に困難となる。このため、AI 技術に基づく画像認識と物体検出技術の高度化に資する沸騰系二相流画像データベースを構築するとともに、原子炉安全解析で重要となる流動様式遷移条件について考察するため、実験的検討を実施した。

図 3.1.2-1 に、実験ループの構造を示す。試験流体である水道水は、二段階のフィルターおよびイオン交換樹脂を通した後、まず貯水タンクに導き、脱気のため、タンク内に設置したヒーターを用いて、約 1 時間沸騰状態を継続した。次に、ループを真空引きし、試験流体を貯水タンクよりループに供給した。試験流体は、ポンプを用いて循環させるとともに、メイン流路とバイパス流路に設けた流調弁とタービン流量計を用いて流量を、フィードバック制御系を有する予熱器と試験部の入口に設置した熱電対を用いて温度を制御した上で、試験部に流入させた。試験部を出た後、流体は、大気開放の気液分離タンクに導かれ、この後、貯水タンクを経て、キャビテーションを避けるために熱交換器で温度を十分に低下させた上で循環ポンプに戻した。試験部および流体への熱入力に用いた透明ヒーターの構造を図 3.1.2-2(a), (b) に示す。試験流路は、幅 14 mm、高さ 10 mm の矩形で、流動方向は原子炉の冷却材流路と同様に鉛直上向きとした。高品質の画像データを取得するため、試験部は透明のポリカーボネートを用いて製作し、幅 14 mm の流路の一側面はサファイヤガラス製とした。サファイヤガラスの幅 10 mm の領域に導電性かつ透明の ITO (Indium Tin Oxide : 酸化インジウムスズ) 薄膜を成膜するとともに、その両端に電極膜として金・クロム・ニッケル合金薄膜を成膜し、ここに電線をハンダ付けして 550 Hz の高周波交流電源により通電することで、ジュール加熱により ITO 膜上で沸騰による蒸気泡の生成を行った。加熱長となる電極間距離は 170 mm とした。

実験は、高速度カメラを用いて蒸気泡の挙動を観察するとともに、高速度カメラと同期した赤外線カメラを用いて、壁面温度分布の時間変化の計測も実施した。高速度カメラと赤外線カメラの設置状況を図 3.1.2-3 に示す。高速度カメラによる撮影は伝熱面の表側より、赤外線カメラによる撮影は伝熱面の裏側より実施した。ここで、サファイヤガラスは赤外線に対して透明、ITO 膜は不透明のため、図 3.1.2-3 に示す配置で伝熱面となる ITO 膜の温度分布が計測される。得られた画像データの一例を図 3.1.2-4 に示す。図 3.1.2-4 より、高速度カメラにより気泡の瞬時画像が鮮明に捉えられているとともに、赤外線カメラ画像より、気泡の底部では伝熱面温度が大きく低下していることが分かる。これは、特に気泡の底部に形成される薄液膜の蒸発による潜熱および気泡成長によりその周囲に形成される局所的なサブクール液流の顕熱により、加熱壁から流体への熱輸送が極めて効率的に行われたことを示す結果と考えられる。

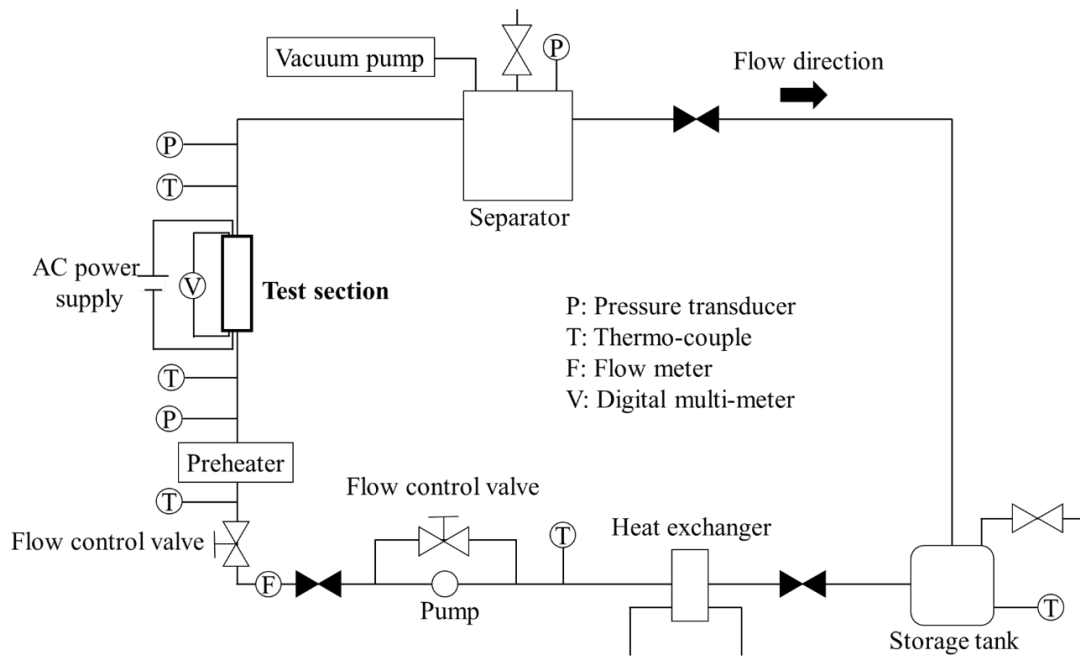


図 3. 1. 2-1 沸騰系二相流可視化実験装置

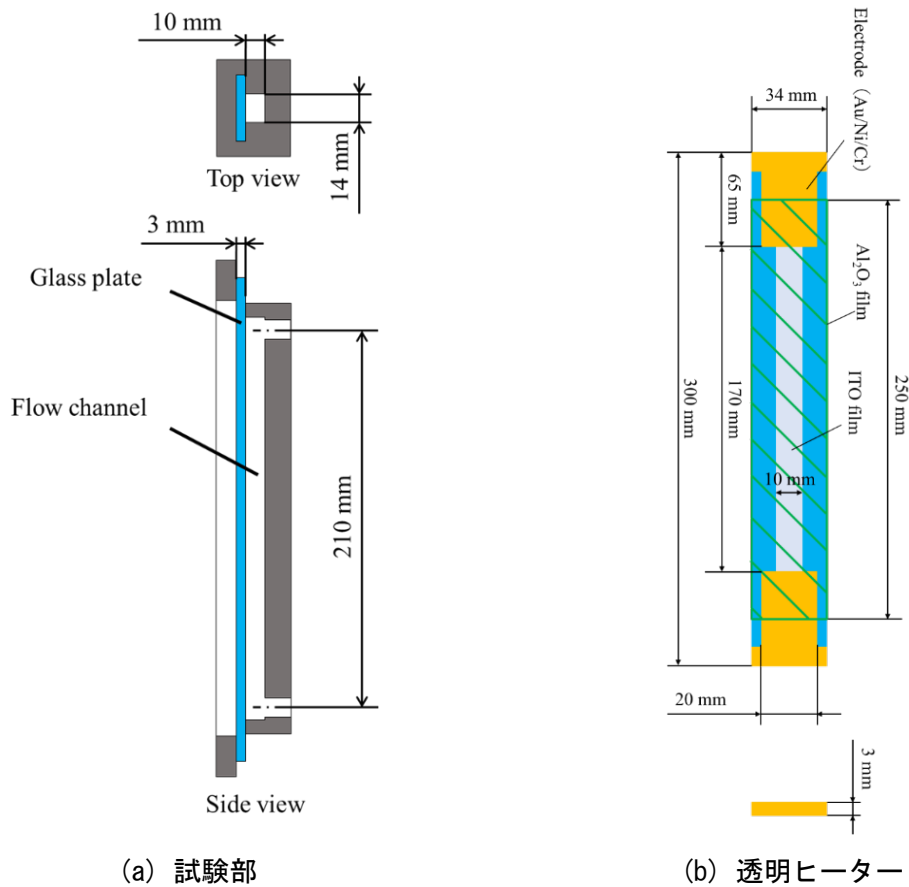


図 3. 1. 2-2 試験部および透明ヒーターの構造






図 3.1.2-3 実験中における高速度カメラと赤外線カメラの配置状況



(a) 高速度カメラ画像



(b) 赤外線カメラ画像

図 3.1.2-4 高速度カメラと赤外線カメラにより得られる画像データの 1 例

沸騰系二相流では、壁面熱流束 q_w の増加、サブクール度 ΔT_{SUB} の減少、質量流束 G の減少等に伴ってボイド率 α が徐々に増加するため、図 3.1.2-5 に示すように、小気泡の合体を経て流動様式が気泡流からスラグ流へと遷移する。そこで、沸騰系二相流における流動様式変化を定量的に調べるため、図 3.1.2-4(a) に示す高速度カメラの映像を用いて、壁面熱流束 q_w の増加に伴う気泡最大幅 d_w の変化を調べた。結果を図 3.1.2-6 に示す。図 3.1.2-6 に示すように、流量と液温を保ちつつ壁面熱流束 q_w を徐々に増加させると、いずれの条件においても気泡サイズは増加傾向となるが、 q_w が臨界値を超過すると、低熱流束条件では 1 ~ 3 mm 程度であった d_w の値が流路幅と同程度の 10~14 mm まで急速に増大し、流動様式が気泡流からスラグ流へと遷移することが分かる。そこで、流動様式遷移条件について検討するため、 d_w が 10 mm 以上となる直前の条件で取得した高速度カメラの画像を用いて、気泡の総投影面積を計測し、これを計測領域の面積で除した値を α_w とした。大気泡の形成前において、気泡は伝熱面のごく近傍に存在することから、 α_w は加熱壁近傍のボイド率と解釈

できる。5種類の実験条件における α_w の計測結果を表3.1.2-1に示す。表3.1.2-1より、スラグ流への流動様式遷移を生じる時の α_w の値は0.24~0.40の間に分布していることから、沸騰系二相流における流動様式遷移条件として、 $\alpha_w=0.3$ が推奨できる。ただし、 $G=600\sim 1,000\text{ kg/m}^2\text{s}$ の高流量条件で実施した実験では、流動様式遷移を生じる上で0.37~0.4のやや高いボイド率を必要としている。これは、液中に形成される乱流渦の影響により気泡合体が生じにくくなっていることが考えられ、今後、沸騰系二相流中における気泡流からスラグ流への遷移条件モデルを高度化する上で重要な知見となる可能性が有る。




図 3.1.2-5 沸騰系二相流における流動様式遷移の観察例 ($G=300\text{ kg/m}^2\text{s}$, $q_w=1.3\text{ MW/m}^2$)

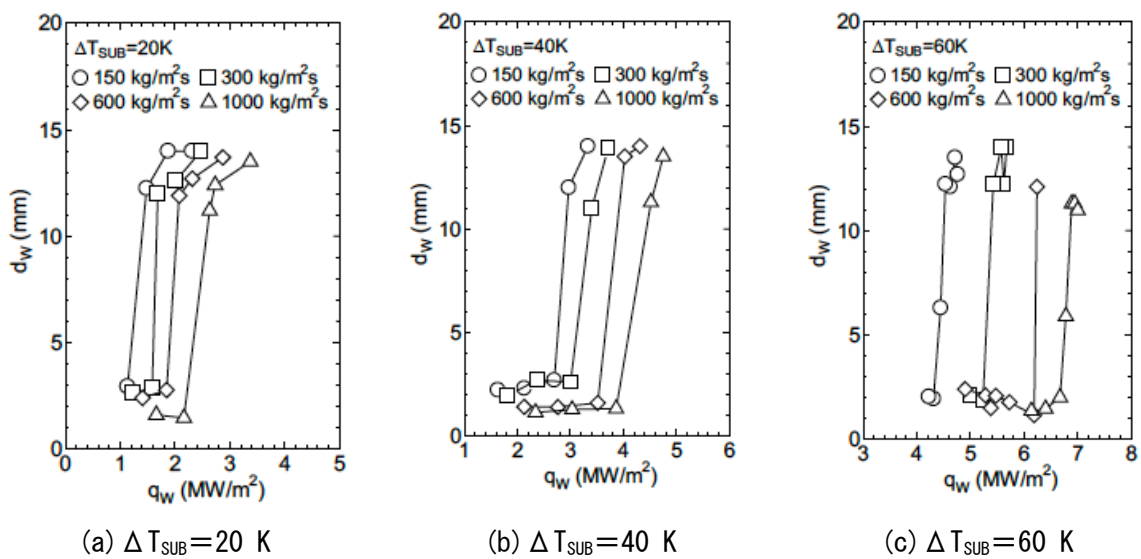


図 3.1.2-6 熱流束の増加に伴う気泡サイズの変化

表 3.1.2-1 スラッグ流への流動様式遷移直前における加熱壁近傍ボイド率

G (kg/m ² s)	ΔT_{SUB} (K)	q _w (MW/m ²)	α_w
300	23	1.0	0.24
300	28	1.3	0.27
300	33	1.5	0.30
600	26	1.5	0.40
1000	23	1.5	0.37

沸騰系二相流での流動様式遷移においても、非加熱系二相流と同様に、流路内におけるボイド率が重要な役割を果たすことが明らかとなった。このため、次に加熱流路内ボイド率の予測精度を向上するための方策について検討する。沸騰系二相流中でのボイド率の空間発展は、主に加熱壁における蒸気生成量とサブクール液中における凝縮量のバランスで決定され、蒸気生成が優位であればボイド率は増加、凝縮が優位であればボイド率は減少する傾向となる。このため、ボイド率の高精度予測では、蒸気生成量と凝縮量を正確に評価することが最重要課題となる。ここで、加熱壁における蒸気生成量を計算するためには、加熱壁面上における発泡核密度 N_S 、各発泡核で生成される蒸気泡の離脱時気泡径 d_B と離脱周期 f_B に関する相関式が必要となる。このうち、 N_S と d_B については、今後も精度向上の必要は有るものの、流動沸騰体系で多くの実験データが収集されているのに対し、 f_B については、プール沸騰体系で得られた実験データに基づく相関式が、流動沸騰体系でもそのままの形で使用されている状況にある。また、凝縮量の評価では、相変化が気液界面で生じることから、 d_B と凝縮熱伝達率 h_{COND} が重要となるが、 d_B について多くのデータが収集されていることは前記の通りであり、また h_{COND} については球周りの熱伝達に関する知見を流用できる。このため、蒸気生成量と凝縮量の評価で重要であるにもかかわらず、現状最も知見の乏しい f_B について実験的検討を実施した。

図 3.1.2-4 に示したように、ある発泡核で蒸気泡が生成されると、相変化による潜熱輸送とサブクール水による顕熱輸送が重畳して加熱壁から冷却液への熱輸送が促進される結果、蒸気泡の底部に局所的な低温部が形成される。G=300 kg/m²s、q_w=1 MW/m²、 ΔT_{SUB} =35 K の条件で、伝熱面上の 2 箇所を観測された蒸気泡生成の様子を図 3.1.2-7 と図 3.1.2-8 に示す。図 3.1.2-7 では、2 個の発泡核 A、B で蒸気泡生成が生じているが、発泡核間の距離が 1 mm 程度と離れているため、蒸気泡底部の低温域がもう一方の発泡核に及ぶことは無い。一方、図 3.1.2-8 では、図 3.1.2-7 と同様に 2 個の発泡核 C、D で蒸気泡生成が生じているが、発泡核間の距離が約 0.3 mm と近接しているため、一方の発泡核で気泡が生成された際に形成される低温域が、もう一方の発泡核にまで及ぶ場合の有ることが分かる。図 3.1.2-9 と図 3.1.2-10 に、発泡核 A、B および発泡核 C、D における局所壁面温度の時間変化を示す。ここで、図中の矢印は各発泡核で気泡生成が生じた時間を示しており、英小文字は図 3.1.2-7 と図 3.1.2-8 と対応している。図 3.1.2-9 より、非近接発泡核 A、B では、気泡生成が生じた時にのみに急激な温度の低下が生じるが、近接発泡核 C、D では、近隣発泡核での気泡生成により生じた低温域に取り込まれる結果、気泡生成を伴わずに壁面温度が急低

下する場合があり、特に発泡核Cでは、20～45 msの期間に5回の明確な温度低下が見られるが、この期間に気泡生成は一度も生じていない。




図 3.1.2-7 非近接発泡核 A, B における蒸気泡生成の様子


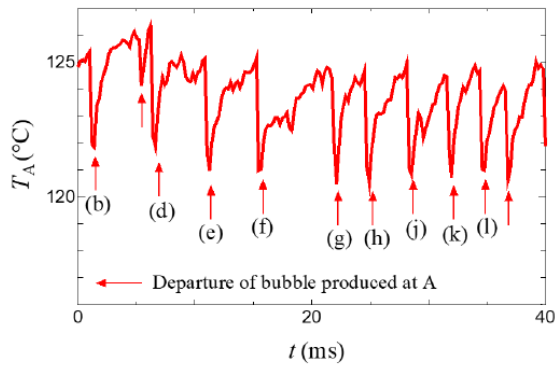
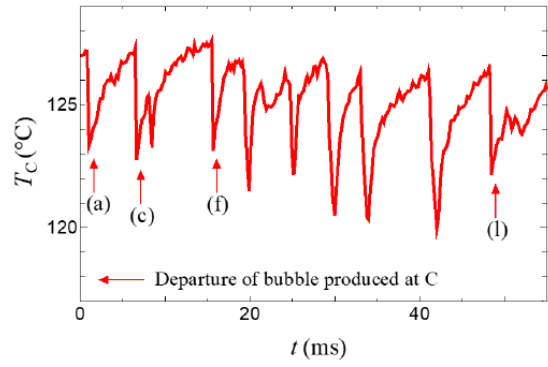


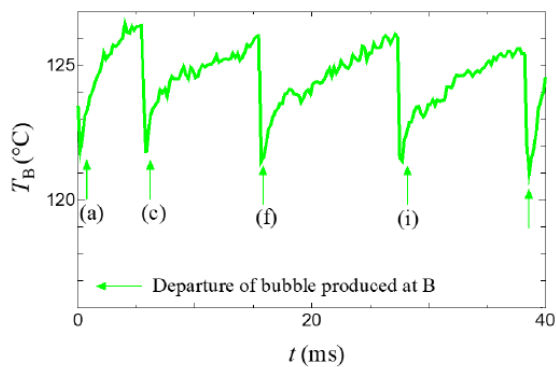
図 3.1.2-8 近接発泡核 C, D における蒸気泡生成の様子




(a) Nucleation site A



(a) Nucleation site C



(b) Nucleation site B



(b) Nucleation site D

図 3.1.2-9 非近接発泡核 A, B における
局所壁面温度の時間変化

図 3.1.2-10 近接発泡核 C, D における
局所壁面温度の時間変化

一般的に、伝熱面上の発泡核における蒸気泡の生成は、休止期間と成長期間に分けられる。図 3.1.2-9(b)からも理解できるように、休止期間には入熱により壁面温度が徐々に上昇し、壁面過熱度が十分に高い値になると、小気泡を形成して成長期間に移行する。成長期間には、液体から気体への相変化による潜熱輸送および気泡の成長に伴う局所的な流れにより促進されるサブクール液への顕熱輸送により、伝熱面から効率的に熱が除去される結果、発泡核の温度は急激に低下する。そして、気泡が十分に成長すると、発泡核を離脱するため、休止期間に戻り、発泡核温度は再び上昇を開始する。ここで、ある発泡核で蒸気泡を生成するためには、発泡核温度が十分に高い値になる必要が有るが、休止期間中に近隣発泡核の干渉を受けて温度低下する場合、気泡生成に必要な温度に達するまでにより長期間を要するため、近隣発泡核の及ぼす干渉効果により、 f_B は低下傾向になるものと予想される。ここで、発泡核で生成される気泡のサイズは発泡核ごとに異なっており、大気泡を生成する発泡核では、気泡成長により長時間を要するとともに、気泡離脱の際に伝熱面から除去される熱量も大きいため、成長期間と休止期間の両方が長期化する。このため、 f_B は d_B の減少関数として、 $f_B d_B^n = C$ の形式で相関される場合が多い。ここで、指数 n は 0.5 ~ 2 程度の定数、 C は主に流体物性値に依存する定数で、いずれも実験データを用いて経験的に定められる。以上の知見に基づき、本研究で各発泡核に対して計測された f_B と d_B の関係を図 3.1.2-11 に示す。ここで、近隣発泡核による干渉効果の有無を検討するため、計測期間中に近隣発泡核の干渉を受けた時間の割合を干渉率 η として定義し、図中では、 η

<0.04 の発泡核には一重記号、 $\eta > 0.04$ の発泡核には二重記号を用いて区別した。また、実験は、 $G=300$ または $600 \text{ kg/m}^2\text{s}$ に設定し、各質量流束条件で $q_w=1$ または 1.2 MW/m^2 として、計 4 条件で実施した。図 3.1.2-11 より、既存知見の通り、 f_B は d_B の増加とともに減少する傾向であるが、 $\eta < 0.04$ の低干渉発泡核と比較して、 $\eta > 0.04$ の高干渉発泡核では、 f_B が相対的に低い値となっており、近隣発泡核による干渉効果が当該発泡核における気泡生成周期 f_B に有意な影響を及ぼすことが分かる。なお、図 3.1.2-11 中の破線は、 $f_B d_B^{1.6} = 0.0022$ であり、低干渉発泡核に対する計測結果は概ね本相関式に従うが、高干渉発泡核の f_B は本相関式による計算結果よりも低い値となることが分かる。

発泡核間干渉の効果を定量化するため、指数 n は 1.6 に固定して、各発泡核に対して計測された d_B と f_B を $C=f_B d_B^n$ に代入し、各発泡核に対する C の最適値を求めた。次に、低干渉発泡核に対する C の平均値 0.0022 を C_0 として、 $C^*=C/C_0$ により、発泡核間干渉による f_B の低下率を表すこととした。 C^* と η の関係を図 3.1.2-12 に示す。想定した通り、 C^* は η の増加とともに減少する傾向であり、本実験条件の範囲内において、 $C^*=1-\eta$ でよく相関できることが分かる。




図 3.1.2-11 気泡生成頻度 f_B と発泡核離脱時気泡径 d_B の関係




図 3.1.2-12 実験定数 C^* と干渉率 η の関係

沸騰二相流画像データベースを用いて、沸騰系二相流における流動様式遷移条件について検討した。沸騰系二相流では、相変化による蒸気生成が主に加熱壁の近傍で生じる。このため、壁面近傍における局所ボイド率が 0.3 程度になると、気泡流からスラグ流への流動様式遷移が生じることを明らかにした。ただし、局所ボイド率の臨界値は、質量流束の増加とともに増大する傾向が認められたため、今後さらなる高度化の余地が有る。次に、流動様式遷移を生じる上でボイド率が重要なパラメータとなることから、沸騰流中のボイド率を決定する上で重要かつ既存の知見が特に不足している因子として、気泡生成周期についても実験的検討を実施した。この結果、気泡生成周期は、従来から指摘されている離脱時気泡径のほか、近隣発泡核での気泡生成による発泡核の温度低下の影響を受けること

を明らかにするとともに、この発泡核間干渉による気泡生成周期の低下幅は、単位時間当たりの干渉時間として定義される干渉率の関数として相関できることを示した。本研究では、各発泡核における気泡生成周期、離脱時気泡径、干渉率を手作業による画像解析により計測するため、比較的低発泡核密度となる条件で実験データを収集したが、気泡生成周期は干渉効果により約半分程度まで低下する場合は有った。高熱流束の強制対流サブクール沸騰では、1 cm² 当り 1,000 個程度の発泡核で気泡生成が行われる場合も有ることを考慮すると、発泡核間干渉は、沸騰系二相流における蒸気生成に多大な影響を及ぼす可能性があり、今後より詳細な検討が必要と考えられる。

3.1.3 AI モデル構築・評価（東京大学、再委託先：電気通信大学）【R3-R5】

【R3-R4】

令和 3 年度は、本課題を実施するにあたり必要となる知見、技術を習得するため、先行研究のレビューを兼ねた文献調査を実施した。

令和 4 年度は、課題(1)①にて構築したモデルにおいて、Data1～Data4 からなるすべての画像に対して流動様式識別を行った。正解ラベル付き流量条件の画像における正解ラベルと識別結果の合致率は、令和 4 年度の報告書を参照されたい。モデル構築に用いた Data1 と Data2 の画像に対しては、いずれのモデルも極めて高い精度で識別しており、VGG、ResNet、EfficientNet の各ネットワークを転移学習させたモデルの精度は 99.9%を上回った。モデル構築に用いていない Data3 と Data4 の識別精度は多くのモデルで 85%～95%に留まったが、学習画像と異なる流量条件、撮影条件の画像に対しても、十分に高い精度での識別が可能であることが示された。各 Data において最も識別精度の高いモデルは 1～4 のそれぞれで異なり、全体で最も識別精度の高いモデルは(B) VGG16 という結果が得られた。

正解ラベルと各モデルの識別結果の対応関係を表した混同行列の作成も実施した。ここから、誤識別の多くは、気泡流とスラグ流、スラグ流とチャーン流、チャーン流と環状流の間で生じていることが分かった。最も多いパターンは正解ラベルが気泡流の画像をスラグ流と識別する場合であり、次いでスラグ流をチャーン流と識別する場合が多く見られた。気泡流の誤識別は、スラグ流領域に近く液相流量が比較的大きい特定の流量条件において、モデルの種類にかかわらず顕著に生じやすいことが分かった。スラグ流についても、誤識別はチャーン流領域寄りの特定の流量条件で生じやすいことが示された。

課題(1)②で構築した沸騰系における気液二相流現象は、断熱系である空気-水系とは異なり、発泡・凝縮に付随した気泡の離脱・消滅が局所的に繰り返されることから、一般の CNN を応用した物体検出ネットワークの適用を試みた。代表的な物体検出アルゴリズムの 1 つである YOLO シリーズの YOLOv5 を用い、気泡流画像における気泡検出モデルを構築した。物体検出モデルの学習データ作成にあたり、一般的には学習および検証用画像に対して検出対象物体の領域を手動で指定する必要がある（アノテーション）。モデルの精度向上のために学習データの増量が有効とされているが、その分アノテーション作業に要する時間と労力も増大する。ネットワークは 24 の畳み込み層と 2 つの全結合層によって構成される。物体検出アルゴリズムにより検出された検出結果として、球形気泡が支配的な低熱流束条

件においては、一部の微細気泡を除いて大まかに検出できている傾向にあるが、改善の余地が有ることが確認された。特に、発泡面より離脱した気泡は温度勾配によっては流路内で消滅（凝縮）するため、検出の難易度は課題(1)①よりも高い傾向にある。また、小気泡による合体・クラスタリングが生じる際は気泡検出アルゴリズムのみでの特徴量抽出が困難であることも分かった。これは、サブクール沸騰～低核沸騰領域外での特徴量抽出は難易度が増し、異なる手法或いはアルゴリズムの改良等が必要となることが示唆された。以上が、令和4年度までの課題(1)③の実施概要である。

【R5】

令和5年度は、訓練データを用いてこれまでに構築したAIモデルを評価することを目標としている。まずはじめに、令和4年度より取り組みを開始した「明確に分類可能な流量条件」における流動様式識別結果について説明する。正解ラベル付き流量条件の画像における正解ラベルと識別結果の合致率を表3.1.3-1に示す。いずれのモデルも極めて高い精度で識別しており、本研究にて新規構築したシンプルなCNN層（モデル(A)）においても、転移学習モデルと同等のパフォーマンスにて流動様式識別が可能であった。モデル構築に用いたData1とData2の画像に対しては、いずれのモデルも極めて高い精度で識別しており、VGG、ResNet、EfficientNetの各ネットワークを転移学習させたモデルの精度は99.9%を上回った。モデル構築に用いていないData3とData4の識別精度は多くのモデルで85%～95%に留まったが、学習画像と異なる流量条件、撮影条件の画像に対しても、十分に高い精度での識別が可能であることが示された。Data3とData4の識別精度は、必ずしもモデル構築時のLossが小さいモデルほど高い傾向は見られなかった。前述した通り、画像撮影時の露光時間やレンズと配管の距離、レンズの種類といった撮影条件は、Dataごとにそれぞれ異なる。一定の撮影条件での画像を学習させて識別させる場合は、深い層構造を持つ高性能のネットワークが高い識別精度を示す傾向にある。しかし撮影条件が変化した場合の汎用性については、ネットワークの性能が高いほど汎用性が高いとは限らないことが分かった。各Dataにおいて最も識別精度の高いモデルは1～4のそれぞれで異なり、全体で最も識別精度の高いモデルは(B) VGG16という結果が得られた。

表 3.1.3-1 「明確に分類可能な流量条件」における識別実行結果

	Data1	Data2	Data3	Data4
(A)	97.55%	97.58%	93.15%	92.66%
(B)	99.97%	99.97%	91.52%	97.54%
(C)	99.97%	99.96%	93.02%	90.62%
(D)	99.99%	99.98%	91.59%	88.89%
(E)	99.97%	99.97%	94.45%	93.57%
(F)	99.99%	99.98%	92.54%	93.02%
(G)	99.99%	99.96%	90.18%	70.67%
(H)	99.98%	99.98%	90.63%	87.91%

もう1つのAIモデルの検証として、明確に分類可能な流動様式とは異なる、「遷移領域

近傍」のデータに着目し、検証を実施した。遷移領域の流量条件については、事前に正解ラベルを与えて識別結果の正誤を評価する手法は適切ではないことから、AI モデルによる識別結果がどのように遷移するかを検討した。Data1、2、3、4 のそれぞれの識別結果として、正解ラベル付きの評価で各 Data における合致率が最も高いモデル(G)、(F)、(E)、(B)の結果を用いることとした。図 3.1.3-1 に、遷移領域の画像が各流動様式と識別される傾向を表した jg-jf 平面を示す。各流動様式と識別された画像枚数が多い条件は白、少ない条件は黒、中間の条件は灰色でプロットしている。「明確に分類可能な」領域の間に位置する遷移領域では、遷移する 2 つの流動様式と識別される画像割合が段階的に増減する傾向が見られ、概ね想定通りの結果と言える。Mishima-Ishii 線図では jf が大きい場合、スラグ流からチャーン流を経ずに環状流に変化するが、識別結果では jf が大きい場合でもスラグ流からチャーン流へと移行した。

以上の結果を踏まえ、遷移領域を定量的に評価するため、画像分類モデルの最終的な出力値に注目した。出力値の数はクラス数（本研究では気泡流、スラグ流、チャーン流、環状流を含む「4」クラス）に対応しており、最も値の大きいクラスが画像の識別結果となる。出力値を softmax 関数で処理することで、出力値の合計は1となり、各クラスに対応する出力値はクラスごとの予測確率 p ($0 \leq p \leq 1$) と見なすことができる。同一流量条件の各画像に対する予測確率を画像時系列順に並べることで、予測確率の時間変化を追跡できる。気泡流とスラグ流、スラグ流とチャーン流、チャーン流と環状流の各遷移領域における予測確率時間変化の例を図 3.1.3-2 に示す。遷移領域では同一流量条件下であっても、遷移する 2 つの流動様式の予測確率が 0 付近と 1 付近の間で激しく時間変動する様子が見られる。予測確率 1 付近に着目すると、2 つの流動様式が一定の時間幅で交互に入れ替わる傾向が見られる。気液界面の挙動が一定の時間幅で変化するため、識別傾向も一定の時間幅で入れ替わると考えられる。

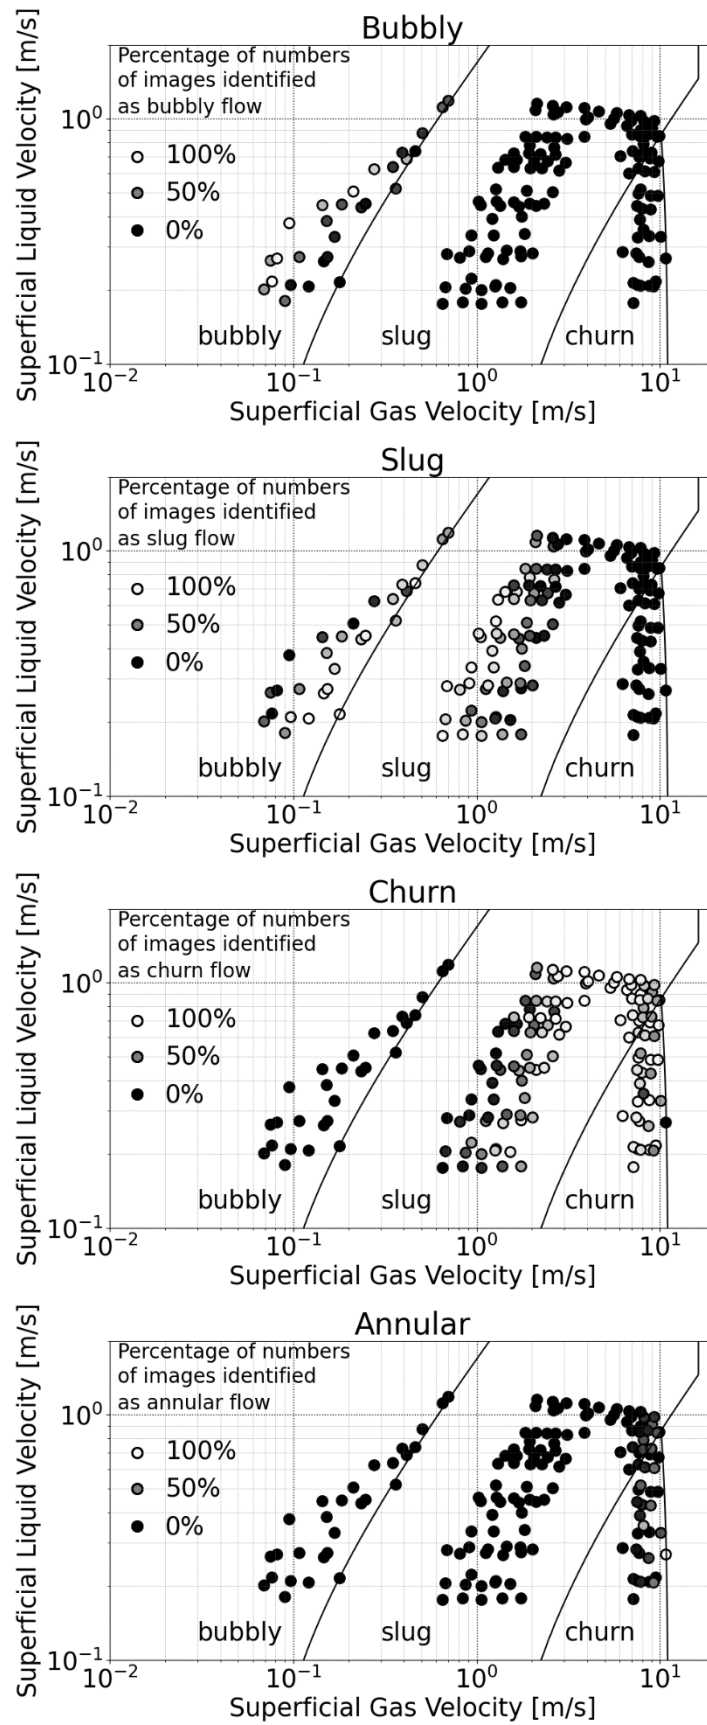


図 3.1.3-1 流動様式遷移領域における画像の識別傾向

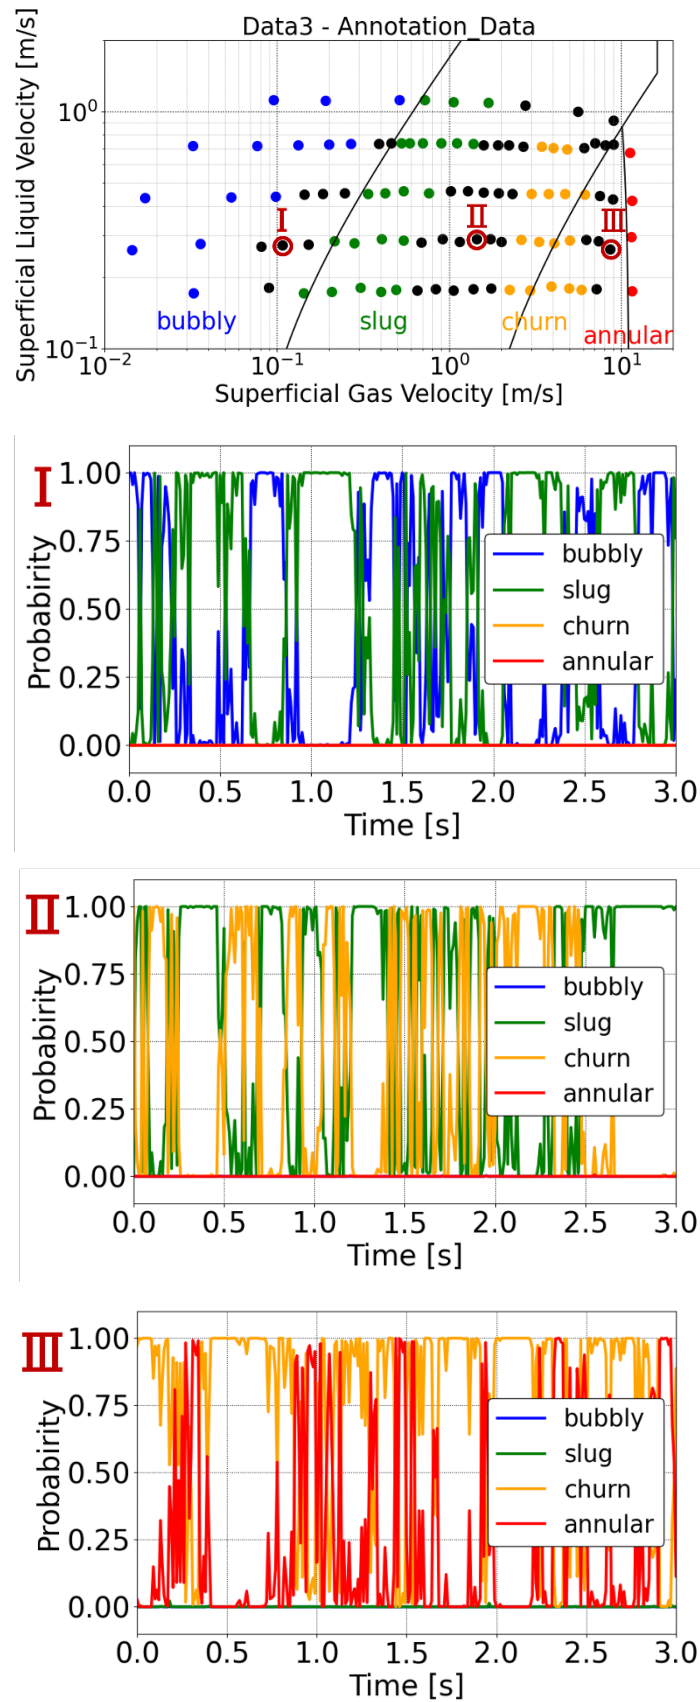


図 3.1.3-2 流動様式遷移領域におけるモデルの予測確率時間変化

流量条件ごとに予測確率の時間平均値を取ると、各流動様式の予測確率平均値は、 j_f を一定とした場合、 j_g の増加に従って漸次的に増減する。図 3.1.3-3 および図 3.1.3-4 にくつかの例を示す。気泡流とスラグ流の遷移領域では、気泡流予測確率の減少に合わせてスラグ流予測確率が増加する。スラグ流とチャーン流、チャーン流と環状流の遷移領域も同様である。予測確率が 0 と 1 の間で漸次的に増減することは、流動様式遷移現象が一定の気相流量に達した時点で瞬時に生じるのではなく、過渡的現象として遷移が生じることを反映していると考えられる。

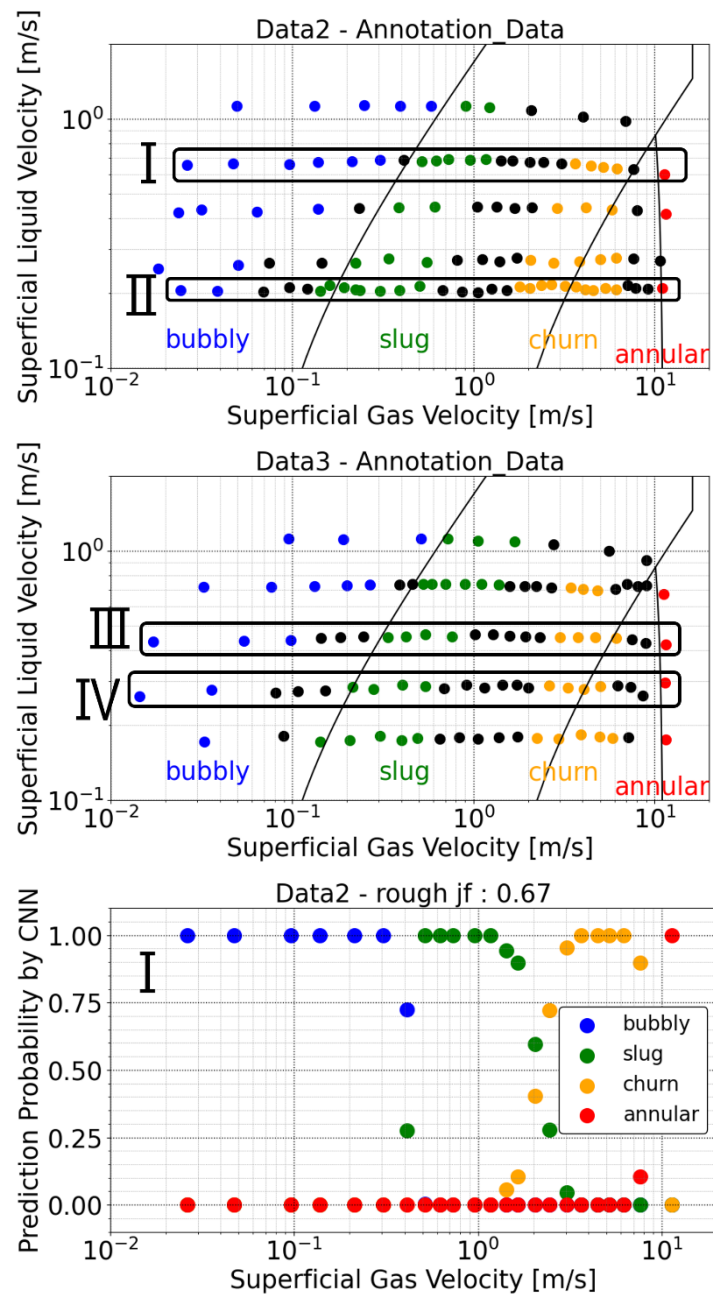


図 3.1.3-3 j_g の変化に応じた流動様式予測確率の時間平均値の変化 (1/2)




図 3.1.3-4 j_g の変化に応じた流動様式予測確率の時間平均値の変化 (2/2)

AI モデルを二相流画像識別に適用する上で、モデルが画像内のどのような気液分布の特徴に注目して識別を行うかについて知ることは有用である。中間層の出力をヒートマップに示し元の画像と合成することで、画像内における深層学習モデルによる注目箇所を可視化した。可視化対象としたのは、(A) Simple CNN モデルの 2 回目 (下流側) のプーリング層出力である。1 枚の画像に対し、サイズ 75×75 の特徴量マップ 128 種類が得られるため、128 種類の平均を取って平均特徴量マップをヒートマップに変換した (図 3.1.3-5)。気泡流では気泡よりも液相に注目する傾向があり、サイズが大きい気泡や気泡集合体の周縁部において、特徴量マップの値が大きくなる様子が見られた。スラグ流では、テイラー気泡先端部およびテイラー気泡と管壁の間隙にある液膜部分で値が大きくなった。テイラー気泡の先端部以外は、注目度が高い場合と低い場合の両方見られたが、微細な気泡が密集し

た液相スラグ部分の注目度は、多くの場合で低い傾向にあった。この傾向はチャーン流と識別される画像についても概ね同様であり、特徴量マップの差異から両者の識別基準を推測することは困難である。チャーン流から環状流への遷移過程では、管壁近傍の気液界面に注目する傾向の強まる様子が見られた。

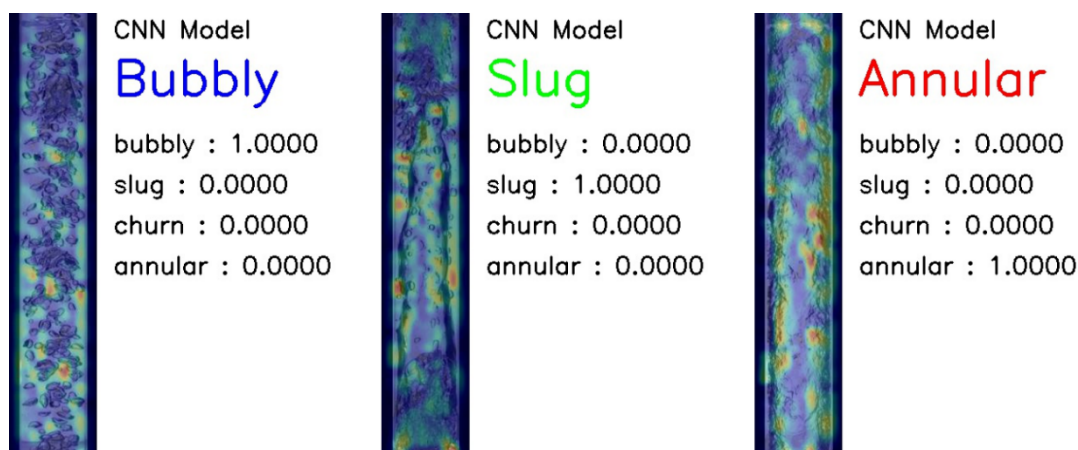


図 3.1.3-5 (A) Simple CNN モデルのプーリング層における特徴量マップの例

次に、課題(1)②で構築した沸騰系における気液二相流現象は断熱形態である空気-水系とは異なり、発泡・凝縮に付随した気泡の離脱・消滅が局所的に繰り返されることから、一般の CNN を応用した物体検出ネットワークの適用を試みた。代表的な物体検出アルゴリズムの1つである YOLO シリーズの YOLOv5 を用い、気泡流画像における気泡検出モデルを構築した。物体検出モデルの学習データ作成にあたり、一般的には学習および検証用画像に対して検出対象物体の領域を手動で指定する必要がある（アノテーション）。モデルの精度向上のために学習データの増量が有効とされているが、その分アノテーション作業に要する時間と労力も増大する。YOLO^[1]は物体を矩形領域（バウンディングボックス：以下、BBBox と略記。）として検出する物体検出アルゴリズムの代表的な1種である。BBBox の検出と物体の種類を2段階に分けて実行する従来の物体検出アルゴリズムに対し、1つの CNN が複数の BBBox とそれらのクラス確率の予測を同時に行う YOLO は、検出速度が速いという利点を持つ。加えて YOLO は画像の一部ではなく全体に着目して学習するため、背景を物体と誤検出する機会が少ないとされる。ネットワークは 24 の畳み込み層と 2 つの全結合層によって構成される。

物体検出アルゴリズムにより検出された検出結果では、球形気泡が支配的な低熱流束条件において、一部の微細気泡を除いて大まかに個々の気泡が検出できている傾向にあるが、改善の余地が有ることが確認された。特に、発泡面より離脱した気泡は温度勾配によっては流路内で消滅（凝縮）するため、検出の難易度は課題(1)①よりも高い傾向にある。本研究では、フレーム間ごとの気泡の追跡を可能とするため、検出（detection）と追跡（tracking）のアルゴリズムを融合させ、サブクール沸騰条件での気泡追跡を実現させた。図 3.1.3-6、図 3.1.3-7 に、高速度カメラにより撮影した一万フレーム数からなるサブクー

ル気泡画像より抽出したボイド率並びに気泡離脱径の時系列変化を示す。これらのパラメータの時系列変動を取得するためには、従来の方法では、例えば、先細な局所プローブ等を使う接触型か、複数のプロセスを有する画像処理等の手法に限定されていた。接触型手法では、時空間解像度による制限が伴うとともに、計測データより構築された実験相関式は平均化されたものが常であり、どの程度の変動幅を考慮すべきかが明瞭ではなかった。画像処理によるパラメータ抽出は、プロセスや抽出精度がプログラム作成者に依存してしまうことや、有効なプログラム作成に膨大な時間が必要となる短所が挙げられる。本課題により提案した手法は、学習を済ませてしまえば瞬時に解析が可能となることに加え、検出誤差も（同一の実験装置画像であれば）極めて低いことが確認されている。また、異なる実験装置により撮影された画像を学習データに組み込み、訓練範囲を広げることで、さらなる汎用性並びに拡張性も可能となる。

終わりに、本課題(1)により得られた成果をまとめる。流動様式遷移モデルの成果として、これまでに曖昧であり、原子力安全の研究においてはしばしば無視されてきた流動様式遷移近傍における流れの振る舞いを、人工知能による「機械の眼」を通して遷移幅を定量的に導く礎を築くことができたことが挙げられる。特に、従来の人工ニューラルネットワークではなく、高速度カメラにより取得した高解像度の二相流画像データを、最新の深層学習モデルによる識別を成功裏に遂行することができたことは、原子力システム分野への AI 技術の応用を進めて行く上で役立つ知見であると考えられる。また、深層学習を二相流画像へ適用する際の課題も見られ、特に、元来正確に定義することが困難な「チャーン流」の識別は、深層学習も不得意とすることが示唆された。これは、中間層の可視化からも見て取れるように、深層学習モデルは、連続相領域を流動様式と紐付けていると見られることから、チャーン流とスラグ流ではマクロ的な視点からは優位な差が得られないことが識別率を低下させる主要因の1つとなっている。このことから、高精度での識別を目的とする場合には、チャーン流を除いた、高液相流量条件下において本手法を流動様式識別に使用することが望ましい。チャーン流での精度を上げる場合には、チャーン流固有の特徴量（液柱、崩壊後のテイラー気泡画像）を訓練データに含める等の追加的措置が必要と考えられる。今後の展開として、安全解析コードに組み込まれている混相流モデルの多くは、1980年代～1990年代にかけて提案された相関式が多く搭載されており、±20～30%の精度のモデルが多数存在している。これらの従来の画像処理法との比較検証、再導出に関しても、本課題にて示したような機械学習モデルの適用が可能かと考えられる。本成果を実用する方法としては、安全解析コード等に遷移モデルを組み込み、遷移領域での計算結果の妥当性や、これまでに指摘されていた流動様式遷移の不連続性による数値的不安定等の解消の検証が必要不可欠である。今後の展開としては、原子力機構や原子力規制庁が保有する安全解析コードへの応用を検討し、本課題により得られた結果の有用性を検証していきたいと考える。

沸騰系矩形管における流動様式遷移モデルの課題は、気泡の発泡、凝縮現象が混在することから、空気-水系と比較し、AI モデルの構築は極めて難易度の高い課題であった。しかしながら、物体検出アルゴリズムでは、サブクール気泡環境下における気泡検出が極めて高い精度で実行できていたことから、「検出」から「情報抽出」までは十分な成果が得

られたものと考えられる。しかしながら、本課題の実験装置においては気泡の重なり合いが極めて低く、ほぼ二次元に近い試験体であったことから、実際の機器に広く用いられる三次元への応用についても検討していく必要が有る。例えば、複数台のカメラを用い、異なる視点から撮影した沸騰画像を三次元デジタル空間で再現し、より現実に近い流動場での特徴量抽出への展開が望ましいと考えられる。また、高発泡核密度条件では、手作業による画像解析は極めて困難となるため、AI 技術の応用が強く期待される。この際、通常使用される高速度カメラの映像に加えて、本研究でも使用した赤外線カメラによる伝熱面温度分布の画像を併用することで、解析結果の信頼性を向上できるものと考えられる。また、本研究では、干渉率の関数として干渉効果を相関したが、干渉率は通常の実験では既知の値ではない。このため、干渉率を、例えば発泡核密度と平均気泡径の関数として表すための試みも必要と考えられる。本研究では、蒸気生成量に多大な影響を及ぼす発泡核密度と離脱時気泡径は検討の対象外とした。これらの物理量については、多数の実験データと相関式が報告されてはいるものの、予測精度の向上は依然として必要である。既存相関式の予測精度が不十分である理由の 1 つとして、高信頼性の実験データの不足が挙げられる。このため、AI 技術の活用により、発泡核密度、離脱時気泡径、気泡生成周期等の物理量についても広範かつ高信頼性の実験データベースを構築することで、原子炉安全解析の信頼性向上を実現できる可能性が有ると考えられる。




図 3.1.3-6 物体検出アルゴリズムにより検出されたボイド率変動

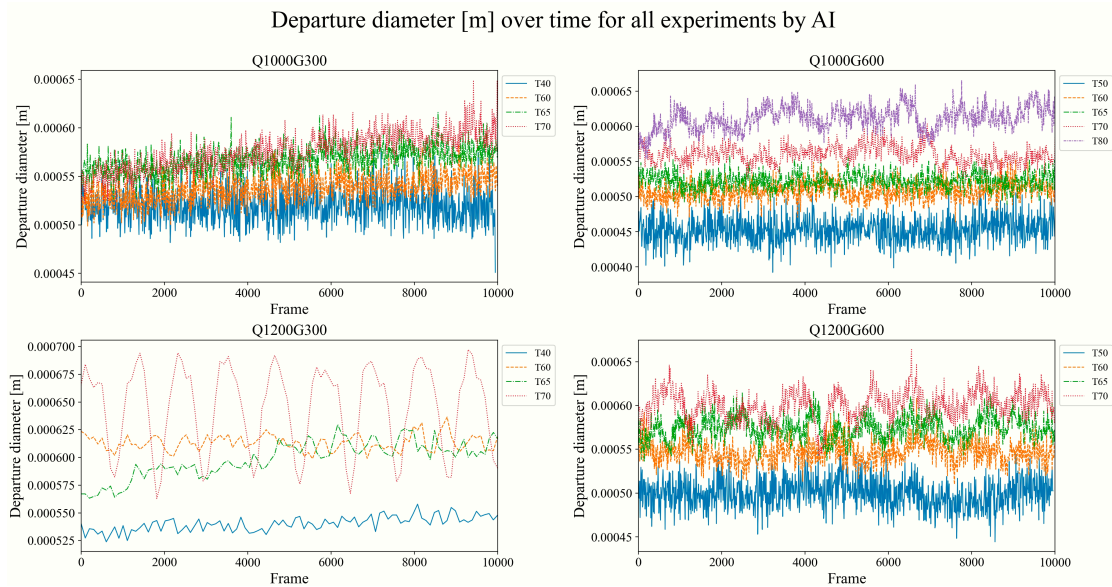


図 3.1.3-7 物体検出アルゴリズムにより検出された気泡離脱径

3.2 データ駆動型熱流動解析手法開発（再委託先：原子力機構）【R3-R5】

下記 3.2.1、3.2.2 に示す業務を遂行するため、令和 4 年度は AI モデル構築用のデータベースの構築を CFD コード JUPITER により行った。令和 5 年度においては、JUPITER の改善による感度解析およびデータベースの構築を実施した。

3.2.1 JUPITER による垂直上昇二相流解析【R3—R5】

【R3-R4】

令和 3 年度は、本課題を実施するにあたり必要となる計算環境の準備を行った。

令和 4 年度は、多次元混相流解析を実施する上での計算環境を整え、AI モデル構築用の CFD による計算データベース構築を行った。得られた結果より、まずは JUPITER コードによる流動様式遷移現象の計算結果を検証した。

AI モデル構築用の CFD による計算データベース構築として、令和 4 年度は垂直上昇二相流解析を表 3.2.1-1 に示す条件で行った。代表的な流動様式を得るための境界条件を表 3.2.1-1 に示す。課題(1)①と同様の体系において、気泡流、スラグ流、チャーン流の流動様式が計算コードにて再現可能か検証するため、気液境界面を図 3.2.1-1 のように色塗りし、実験画像との比較を行った。スラグ流、チャーン流の界面構造は実験での観察とほぼ類似した傾向にあるが、気泡流に関してはキャップ気泡が支配的な流動様式となっており、実験装置の気相注入方法と類似した境界面を再構築する必要があると考えられる。

表 3.2.1-1 JUPITER による垂直上昇二相流解析の流動条件

	流動様式	J_g [m/s]	J_f [m/s]
A	気泡流	0.029	0.215
B1	スラグ流	0.178	0.215
B2	スラグ流	0.330	0.223

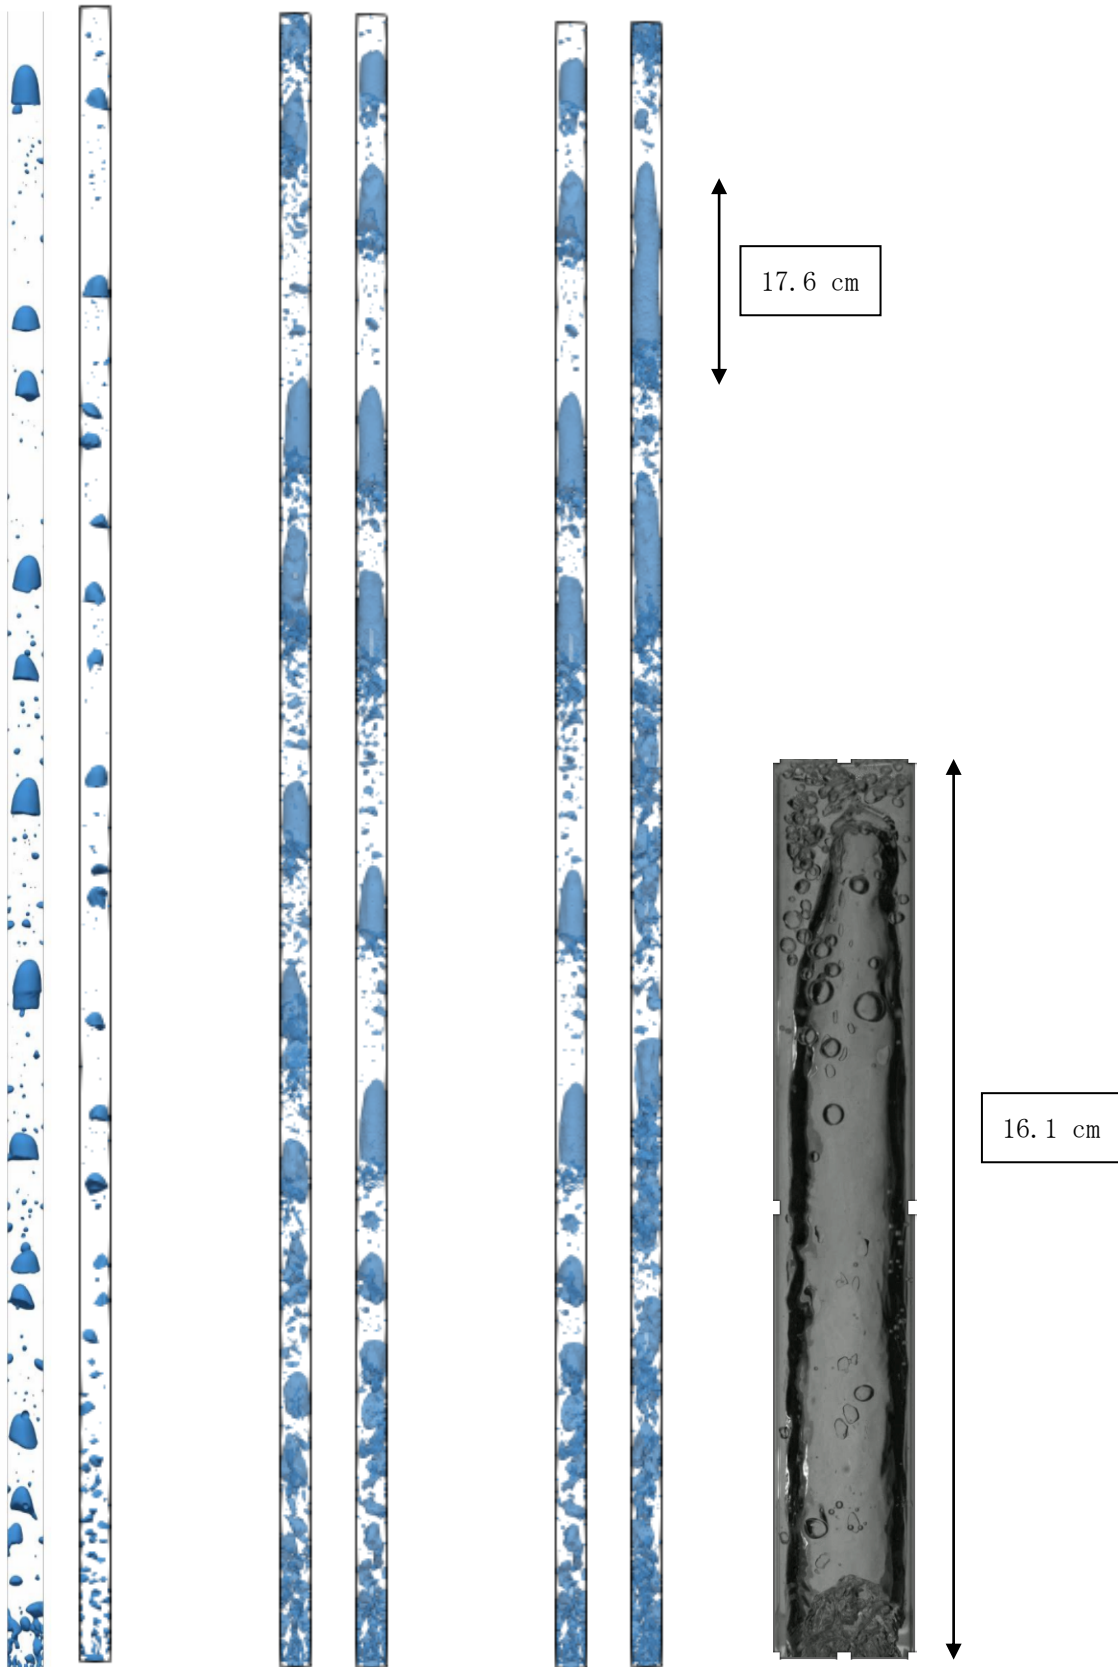


図 3.2.1-1 垂直上昇二相流計算結果：左からケース A、ケース B1、ケース B2
 各ケースの左図および右図がそれぞれ令和 4 年度、令和 5 年度の結果
 右端図はケース B2 の実験結果

【R5】

令和5年度は、令和4年度までに抽出した課題を解決した上で、CFDにより得られた垂直上昇二相流データから深層学習モデルを構築して、データ駆動型熱流動評価として流動様式識別の解析を実施した。各流動様式条件において、定性的に一致した傾向を示すことができた。しかし気泡流条件においてキャップ気泡が支配的となる傾向を示したため、界面捕獲スキームの拡散が影響していると考え、令和5年度の実施内容として、数値拡散を抑えたスキームに改良した。それを用いてケースAとBについて解析を行った。なお、ケースBについては流動様式線図の気泡流とスラグ流の堺に位置する条件とそれよりやや早い U_{ig} で解析し、スキームの感度解析を行った。図3.2.1-1に示すように、ケースAについては令和4年度の結果よりもキャップ気泡の数が減少し、細かい気泡が分散している傾向を示した。ケースBについてはスラグ気泡の長さが令和4年度の結果よりも長くなり、実験結果に近付くことが分かった。以上より、気泡流条件ではVOF (Volume of Fluid (Method) : VOF法 (数値流体解析の一手法)) の特性により気泡が合体してしまうものの、スキームの改善によりキャップ気泡は抑制できることが分かった。また、スラグ流に関しては実験結果と同程度の気泡長さを再現できることが分かった。

本解析により得られた出力結果について、課題(1)で作製したCNNモデルを用い、条件B1並びにB2により得られたJUPITER解析結果について流動様式識別を実施した。条件B1の出力は308枚、条件B2は365枚の画像を用いたところ、スラグ流における判定率は90%以上であった。図3.2.1-2に、中間層を可視化したヒートマップを示すが、気液界面の存在に対してネットワークは高感度で検知していることを示している。このことから、複雑な構造を有するスラグ流等の場合、高速度カメラの画像よりも、CFD解析結果を学習データとして用いる方法も有効な方法であることが示唆され、AI技術による完全なオートメーション化を検討する上で有用な手法となることが考えられる。本研究・開発により得られた知見を踏まえ、今後はチャーン流、環状流を対象としたCFD解析を展開していく予定であるが、計算コストの課題や、テイラー気泡が崩壊し、環状流への遷移の再現が可能なモデルの計算モデルの検討が必要である。




図 3.2.1-2 CNN による JUPITER コードによる解析結果の分類：
スラグ流の条件における中間層のヒートマップを図示

3.2.2 JUPITERによる噴流着水解析【R3-R5】

【R3-R4】

令和3年度は、本解析の実施に必要な計算環境の整備を行った。

令和4年度においては、AIモデル構築用のCFDによる計算データベース構築を行った。噴流着水解析について、既存文献の実験条件と同等の条件でJUPITERにより実施した。結果、複雑な流動を有する気液二相流に対して安定した計算が可能であることを確認した。また、JUPITERコードによる計算結果から得られた気泡侵入長さと、実験値の比較を行い、計算の妥当性を定量的に確認し、概ね良く一致することが分かった。

【R5】

令和5年度は、CFDにより得られた計算データベースから、データ駆動型の噴流着水解析手法として深層学習モデルの構築を行い、得られた出力結果の評価を行った。改良した界面捕獲スキームを用いて以下を実施した。

1. 噴流着水後に巻き込まれた気泡の形状分類
2. 複数噴流が気泡侵入深さに影響を及ぼすピッチ幅の確認

1. について、ノズル径 D とノズル高さを代表長さとするフルード数、 Fr_D および Fr_L の積が 0.25、1.25、3.8 の条件で、着水後の気泡群が図 3.2.2-1 のようになるかどうかを確認した (図 3.2.2-2)。




図 3.2.2-1 $Fr_D Fr_L = 0.25$ (a)、1.25 (b)、3.8 (c)での気泡群形状の実験結果

図 3.2.2-2 より、(b)については概ね同等の傾向を示したが、(a)において、実験では気泡が生成されていないのに対し、解析では生じていることが分かる。また、(c)では実験では大量の気泡が生成されているのに対し、解析では比較的少ない。これは格子点数が少ないため、細かい気泡が再現することができないためであると考えられる。また、VOF の特性により小さい気泡は合体してしまうため、水面近傍で気泡密度が疎になっていると考えら

れる。

2. について、ノズルピッチが気泡侵入深さに及ぼす影響を調査した。実験ではノズルピッチが 5 cm より狭くなると複数ノズルの影響により侵入深さが深くなることが分かっている。これに対し、JUPITER がその再現が可能かどうかを評価した。図 3.2.2-3 にノズルピッチに対する侵入長さを示す。令和 4 年度の結果はノズルピッチ 5 cm においてシングルノズルの結果を大幅に過大評価しているのに対し、令和 5 年度の結果は、ノズルピッチ 5 cm においてシングルノズルの結果に近付き、それより狭くなると侵入長さが深くなるという実験結果に対応した結果を得ることができた。以上より、気泡の影響が強くないと考えられる。侵入長さは実験結果と良い一致を示すが、気泡群の形状や密度は界面捕獲スキームや格子解像度の影響を比較的強く受けるため、適切なスキーム並びに格子解像度の設定が重要であると言える。

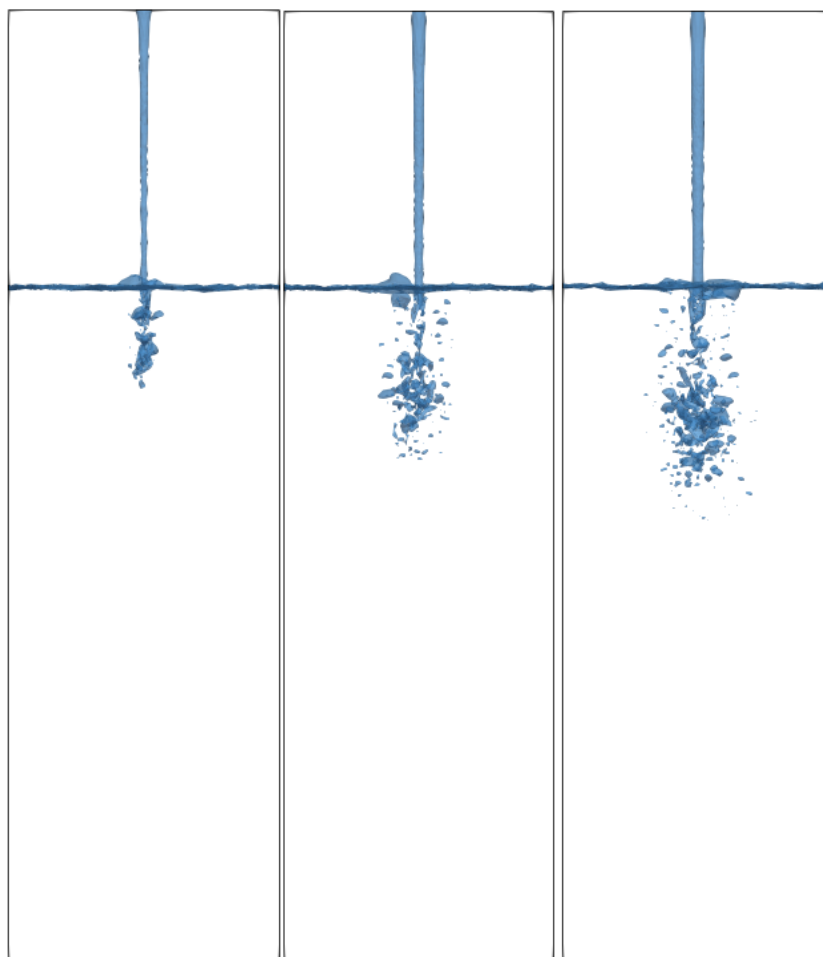



図 3.2.2-2 $FrDfrL=0.25$ (a)、 1.25 (b)、 3.8 (c)での気泡群形状の解析結果



ノズル径：0.013m、ノズル高さ：0.15m、プール深さ：0.7m、ノズル出口流速：3.0m/s

図 3.2.2-3 ノズルピッチに対する侵入長さ

これらの結果から、物体検出モデルの1つである YOLO を使い、AI による気泡群の特徴量抽出を行うモデルの構築を試みた。広範囲なデータセットに対応可能なモデルを構築するため、学習させるためのデータを水増して (図 3.2.2-4)、表 3.2.2-1 に示す内容でハイパーパラメータの調整を行った。本手法により得られた気泡群の検出結果を図 3.2.2-5 に示す。気泡群を囲った情報から、最大侵入長さを抽出し、実験値や既存の相関式との比較を行ったところ、±20%以内での精度で検出・予測ができていることが確認された (図 3.2.2-6)。また、本モデルを用い、気泡群の形状パラメータの瞬時検出も可能であることも示された。図 3.2.2-7 は気泡群の画像毎に抽出したパラメータの時刻歴データであり、気泡深さ (D)、最大幅 (W)、最大幅までの水深 (V)、気泡群の面積 (A)、気泡群周囲長さ (P) である (構成のため、図中では A/100, P/10 として表記)。これらの結果からも、複雑な二相流挙動からの特徴量抽出手法としての応用が期待される。

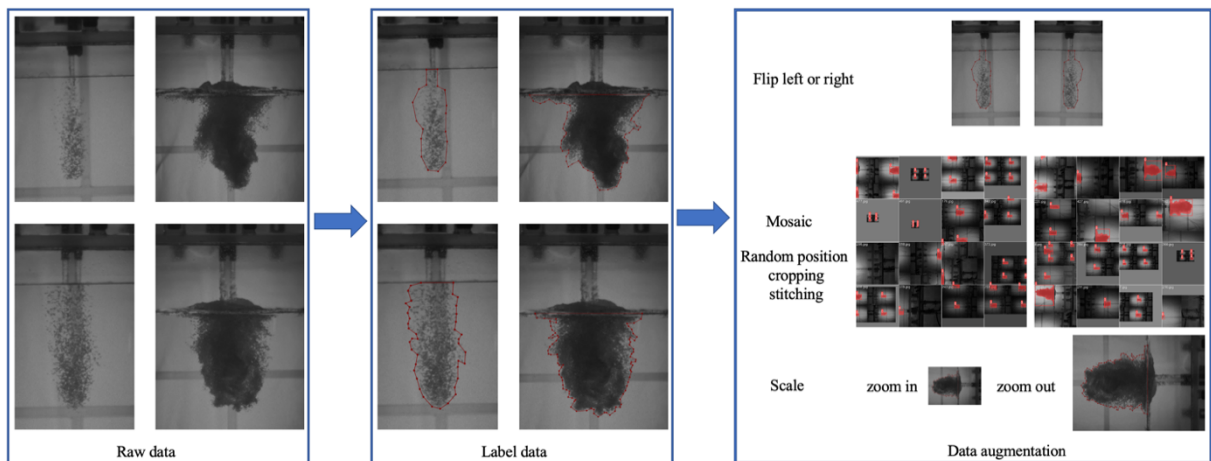


図 3.2.2-4 物体検出モデル学習のためのデータ拡張方法

表 3. 2. 2-1 物体検出モデル学習のためのハイパーパラメータ

Item	Value
Data augmentation	
hsv_h, hsv_s, hsv_v (image Hue, Saturation, Value augmentation (fraction))	0.015, 0.7, 0.4
translate (image translation (+/- fraction))	0.1
scale (image scale (+/- gain))	0.9
fliplr (flip left-right (probability))	0.5
mosaic (image mosaic (probability))	1.0
mixup (image mixup (probability))	0.1
copy_paste (segment copy-paste (probability))	0.1
Hyperparameter selection	
Predefined model	YOLOv5m-seg (230 layers, 22096646 parameters, 70.8 GFLOPs)
Optimizer	SGD
Learning rate	0.01, cosine lr
Batch size	25
Momentum	0.937
Maximum epoch	1000




図 3. 2. 2-5 物体検出モデルによる解析結果

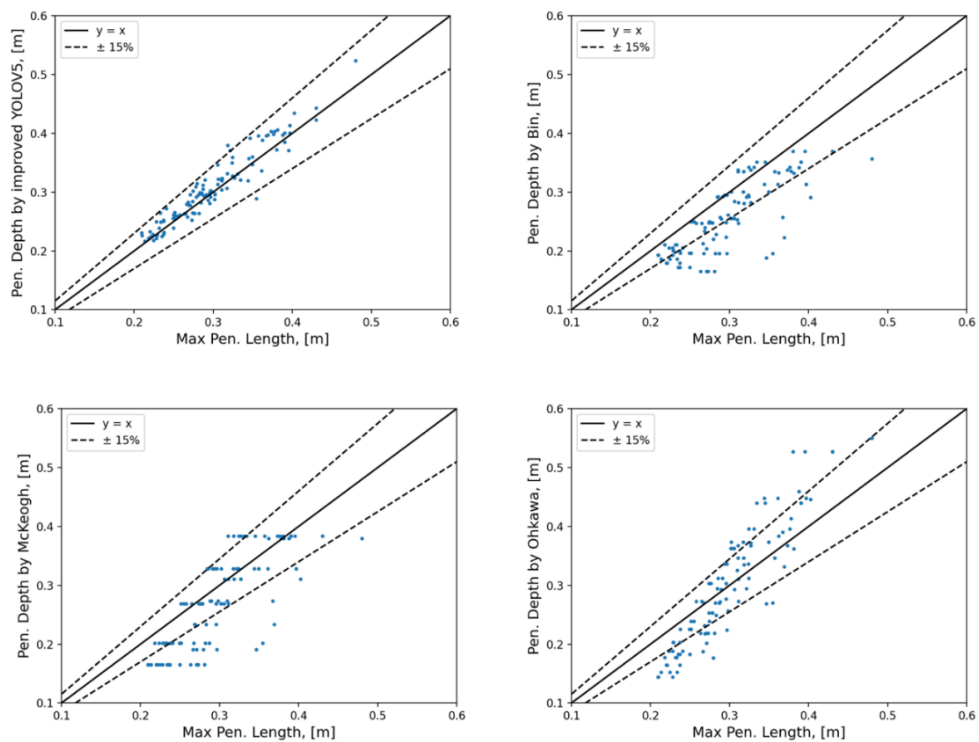


図 3. 2. 2-6 物体検出モデルによる気泡侵入長さの実験値と比較





図 3. 2. 2-7 物体検出モデルによる気泡群形状パラメータの抽出

終わりに、本課題(2)により得られた成果をまとめる。多次元数値解析コード、JUPITERを用いた垂直上昇二相流の解析においては、気泡流条件下におけるキャップ気泡の生成や、スラグ流の特徴等が概ね良い精度で再現できていることが確認された。また、CFDにより得られた結果を、機械学習モデルを構築する上での訓練データとして入力し、実験から得られる画像を識別・判定する手法の有用性も確認することができた。このアプローチは、複雑な流れを機械学習モデルに学習させる上で効果的であることが考えられ、今後は、異なる形態（例えば、蒸気-水系、大口径二相流等）への適用も検討の余地が有るかと考えられる。しかしながら、解析に組み込まれる数値解析モデルの選定により、結果が微妙に異なる課題も浮き彫りとなった。このことから、例えば、異なる数値アルゴリズムが搭載されている解析ソフトウェアの使用に際しては注意が必要である。また、三次元の計算を実施する際の膨大な計算コストもネックとなっていることから、CFD解析結果のみでの機械学習モデルの構築には、注意が必要であり、実験データによる検証や、異なるCFDソフトウェアとの比較が必須であると考えられる。また、本課題(2)により構築したモデルを実際の着水現象に応用する場合、高速度カメラ等による画像を新たに取得する必要があるとともに、データ拡張法等を用いた画像データの拡充が重要となる。しかしながら、自動運転等にも応用されている深層学習をベースとした物体検出アルゴリズムは、ロバスト性に優れていることが本課題でも再確認され、気泡群の形状や侵入長さの評価については、（鮮明な画像データが取得できる環境下との前提では）提案されている実験相関式の代替も可能なレベルに達していると考えられる。本手法を安全性評価に適用する際は、実機等において想定される高圧・高温条件下での着水現象にて同様の検証を行い、同等の検出能力が維持できているか否かの評価が必須であり、本課題を今後展開していく上での検討事項の1つであると考えられる。

3.3 データ駆動型評価モデル開発（東京大学、再委託先：NEL）【R3-R5】

3.3.1 GRAPE による LOCA 事故事象データベース構築+AI モデルの構築と評価

【R3-R4】

令和3年度は、本課題を遂行するために必要な計算環境の整備を行った。

令和4年度は、加圧水型軽水炉（Pressurized Water Reactor：以下、PWR と略記。）の冷却水喪失事故（Loss of Coolant Accident：以下、LOCA と略記。）事象解析を実施し、事故進展時の時系列データベース構築を進めた。学習モデルの入力データは事故発生時における原子炉システムの動作を計算し予測する原子炉シミュレータである RELAP5/SCDAPSIM コードを NEL 社がユーザビリティを向上させて再開発した GRAPE を用いた。本研究では実際の事故発生時に計測可能なデータを使用することを重視し、事故発生時にも比較的計測可能である液相温度、気相温度、圧力をプラント内各所計算し、データとして取得した。また、AI モデルの構築として、LSTM（Long Short Term Memory：長・短期記憶）をベースとした分類予測、進展予測の構築を実施した。

【R5】

令和5年度は、PWR の LOCA 進展予測における LSTM の能力を検証するため、GRAPE により取得したデータベースから事故時事象評価モデルの構築を行い、異なるルックバック値とエポックで学習させた LSTM 予測モデル（令和4年度報告書に概要記載）の性能を評価し、学習エポックとルックバック値を変化させた場合に予測性能がどのように変化するかを調べ、LOCA 時の水位、ホットレグ温度、1次冷却材流量の予測において最も性能の良いモデルを特定する。

図 3.3.1-1 は、テスト LOCA シナリオによる水位予測モデルの RMSE（Root Mean Squared Error：二乗平均平方根誤差）を示している。学習エポックとルックバック値を変化させても、予測精度に大きな変化は見られない。すべてのケースにおいて、LSTM モデルは正しい値から 0.5～8.5 単位、平均 4 単位の乖離を持つ水位予測を提供している。図 3.3.1-1 に、本解析により得られた RMSE 値の箱ひげ図（Box Plot）を示す。RMSE パーセント単位は、予測値のパーセント誤差ではなく、原子炉内の水の体積パーセント（%）で水位単位を表している。図 3.3.1-1～図 3.3.1-3 に示す箱ひげ図においては、最大値、最小値に加え、四分位数の情報が含まれる。四分位数は、データを小さい順に並べ替え、データのサンプル数で四等分した際の区切りを表しており、25%、50%、75%に該当する値で箱（Box）が構成される。即ち、箱の両端より延伸するエラーバーは、最小値、最大値を示し、箱の下端、上端、および、内部に示された横線は、それぞれ、25、75、50 パーセントに該当する。また、黒点で示された折れ線は、平均値を表す。ルックバック値を変化させた場合、予測性能には2つの傾向が見られる。第1に、エポック 100、200、500 において、モデルがより多くの過去データを取り込むにつれて、予測性能はわずかに向上する。次に、エポック 300 と 400 において、予測性能は $k=5$ でピークに達し、 $k=7$ で悪化する。同じルックバック値の中では、学習エポックが変わっても予測性能に明確な傾向は見られない。しかし、LSTM モデルはすべてのルックバック値において、最も短い訓練エポックで最も良い結果を示した。 $K=3$ と $k=7$ のいずれにおいても、100 エポックのモデルがそれぞれの RMSE 値

3.91%と 3.67%で最も良い結果を示した。K=5 の場合、300 回のエポックを行ったモデルが RMSE 値 3.73%で最良であったが、100 回のエポックを行ったモデルは RMSE 値 3.74%で拮抗した。




図 3.3.1-1 LSTM モデルを用いた水位予測性能

図 3.3.1-2 は、テスト LOCA シナリオから得られたホットレグ温度予測モデルの RMSE を示している。水位予測とは異なり、エポックとルックバック値を変化させると、高温部水温の予測性能に大きな変化が見られる。学習エポックが短いモデルは、ルックバック値が高いほど良い結果を示したが、エポックが長くなるにつれて、過去のデータポイントが少ないモデルの方が良い結果を示すようになり、傾向が変化した。また、一定のルックバック値の中で訓練エポックが変化しても、予測性能に明確な傾向は見られない。これは、一定のルックバック値では予測性能と訓練エポックは無相関であるため、一定のルックバック値で最適なエポックを見つけることは困難であることを意味している。k=3、5、7 で最も性能の良いモデルは、それぞれ 500、400、100 エポックであった。さらに、これらのモデルの平均偏差はそれぞれ 3.21℃、3.06℃、3.14℃であった。すべてのモデルにおいて、予測誤差の範囲は 1~8.5℃であり、平均誤差は 4℃であった。




図 3.3.1-2 LSTM モデルを用いたホットレグ温度予測性能




図 3.3.1-3 LSTM モデルを用いた冷却水流量予測性能

最後に、図 3.3.1-3 はテスト LOCA シナリオから得られた 1 次冷却材流量予測モデルの RMSE を示している。多くの外れ値が、図中の点で示された真の流量値から大きく乖離している。これらの外れ値は、LOCA 時の冷却材流量の突然の大きな低下を予測する LSTM モデルの不正確さを表している。不規則な大きな落ち込みは冷却材流量データのみに見られるものであるため、予測値の大きな乖離はこれまでの予測タスクでは観察されなかった。

同じエポック内で、ルックバック値を変化させた場合の予測性能にはいくつかの傾向が見られる。最も短い訓練エポックと最も長い訓練エポックでは、ルックバック値が大きくなるにつれて性能が向上する。訓練エポックが中間の値である 300 に近づくにつれ、予測性能に対するルックバック値の影響は小さくなる。最終的にエポック 300 では、ルックバック値の違いによる予測性能の差は殆ど見られなくなる。k = 3、5、7 で最も性能の良いモデルは、それぞれ 100、400、100 エポックの学習を受けた。

3.3.2 運転員操作を有する事故事象パラメータ解析（東京大学、再委託先：NEL）【R3-R5】

(1) 解析評価の目的

事故発生時には、国や周辺自治体に対して、事業者として事故進展状況の推定や予測の報告が必要であるが、実際の事故情報に基づく詳細なプラント挙動解析には時間を要するため、AI による迅速な評価ができると有益であると考えられる。このような状況に鑑み、本解析評価においては、運転員操作を有する事故事象として、SGTR（Steam Generator Tube Rupture：蒸気発生器細管破断）を選定し、その操作タイミング等の変動に伴う事故進展への影響を AI により迅速に評価を行うことを目的として、解析評価を実施することとした。

なお、今回の解析を実施した「SGTR 事象に対応する操作手順」については、電気事業者の現行の「事故時操作所則」に準拠している。「事故時操作所則」は、原子炉設置（変更）許可申請時における安全解析の前提、すなわち、プラントの安全性担保の前提条件となるものである。

AI による評価結果が実際の運転操作に反映されるためには、その安全性担保の考え方が安全審査で認められている必要が有るため、既設プラントに後から適用することは、その許認可上のハードルが非常に高いものとなることが予想される。このような考え方は、新規プラントの設計段階から取り入れて、安全審査で認められている必要が有ると考えられる。

上記の通り、AI 評価に基づき、運転員の操作方針を決定するようなシステムを既設プラントにおいて早期に実現することは困難と考えられるが、事故時のプラント挙動を迅速に予測できれば、事故時に中央制御室における運転員の活動を支援する事故対策本部などでは、事故収束活動にあたっての参考となり得ると考えられる。

【R3-R4】

(2) 令和3年度、令和4年度の実施概要および成果

令和3年度は、本解析の実施に必要な計算環境を整備した。

令和4年度は、運転員操作を有する事故事象パラメータ解析の対象事例として、SGTR 事故を選定し、試評価用の AI モデル学習および AI モデル評価のため、SGTR 事故解析を計 57 ケース（AI モデル学習用：54 ケース、AI モデル評価：3 ケース）実施した。

解析手法

解析においては、GRAPE により生成した国内 4 ループ PWR プラントを模擬した入力データをベースに、SGTR 解析に必要なモデルを追加した上で、RELAP/SCDAPSIM による SGTR のベースシナリオ解析とパラメータサーベイを実施した。

解析条件・解析ケース

令和4年度においては、AI モデルの学習のための解析（54 ケース）と AI モデル評価のための解析（3 ケース）の計 57 条件で SGTR 事故シナリオの解析を実施した。

各ケースの解析条件を表 3.3.2-1、表 3.3.2-2 および表 3.3.2-3 に記す。

表 3.3.2-1 試評価版 SGTR 解析条件 (モデル学習およびモデル評価のための解析)

	項目	実施条件	
起 因 事 象	SGTR 破断箇所 (①)	破断箇所：以下のいずれかの箇所を設定 ・ SG 細管入口 (高温側) ・ SG 細管上端 ・ SG 細管出口 (低温側)	解析ケースによっ て異なる破断箇所 を設定 (表 3.3.2-2 参 照)
	SGTR 破断面積	破断面積： $6.10 \times 10^{-4} [\text{m}^2]$ (SG 細管 1 本の両端破断に相当)	全ケース共通
事 故 条 件	外部電源	あり	全ケース共通
	安全機能の 喪失に対す る仮定	安全系の機器故障は想定しない	全ケース共通
運 転 操 作	破断側 SG 隔離 (②)	原子炉トリップから一定時間経過後に以下の操作を実施 ・ 主蒸気隔離弁閉止 ・ 補助給水停止 ・ タービン動補助給水ポンプ蒸気抽出ラインの閉止 ・ ブローダウンラインの閉止	解析ケースによっ て異なる操作タイ ミングを設定 (表 3.3.2-2 参 照)
	健全側 SG による 2 次 系強制冷却 (③)	主蒸気逃がし弁全開： 原子炉トリップから一定時間経過後に健全側 SG の主蒸気逃がし弁を全開にする	解析ケースによっ て異なる操作タイ ミングを設定 (表 3.3.2-2 参 照)
		主蒸気逃がし弁調整開 (開度 30%)： 健全側の 1 次冷却材高温側配管温度が 276℃以下になったら健全側 SG の調整開にする	全ケース共通
	1 次系 減圧操作	加圧器逃がし弁開操作： 健全側の 1 次冷却材高温側配管温度が破断側 SG の飽和温度 - 6℃に達した段階で 1 系統の加圧器逃がし弁開操作を実施	全ケース共通
		加圧器逃がし弁閉操作： 加圧器圧力が破断側 SG 圧力以下に達したら実施	全ケース共通
安全注入 停止	高压注入および低压注入の停止： 加圧器逃がし弁閉操作と同タイミングで実施	全ケース共通	
そ の 他	減速材 密度係数 (④)	事故時の減速材密度係数として以下の 2 ケースを実施 ・ BOC 相当 ・ EOC 相当	解析ケースによっ て異なる減速材密 度係数を設定 (表 3.3.2-2 参 照)

表 3.3.2-2 試評価版 SGTR 解析ケース（モデル学習およびモデル評価のための解析）

No.	解析ケース	①破断位置	②破断側 SG 隔離	③健全側 MSRV 開	④減速材密度係数
モデル学習のための解析 (No. 1~54)					
1	grape-sgtr-i_0106_e	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 6 分	EOC 相当
2	grape-sgtr-i_0106_b	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 6 分	BOC 相当
3	grape-sgtr-i_0108_e	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 8 分	EOC 相当
4	grape-sgtr-i_0108_b	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 8 分	BOC 相当
5	grape-sgtr-i_0110_e	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 10 分	EOC 相当
6	grape-sgtr-i_0110_b	SG 細管入口	原子炉トリップ後 1 分	原子炉トリップ後 10 分	BOC 相当
7	grape-sgtr-i_0306_e	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	EOC 相当
8	grape-sgtr-i_0306_b	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	BOC 相当
9	grape-sgtr-i_0308_e	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	EOC 相当
10	grape-sgtr-i_0308_b	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	BOC 相当
11	grape-sgtr-i_0310_e	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	EOC 相当
12	grape-sgtr-i_0310_b	SG 細管入口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	BOC 相当
13	grape-sgtr-i_0506_e	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	EOC 相当
14	grape-sgtr-i_0506_b	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	BOC 相当
15	grape-sgtr-i_0508_e	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	EOC 相当
16	grape-sgtr-i_0508_b	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	BOC 相当
17	grape-sgtr-i_0510_e	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	EOC 相当
18	grape-sgtr-i_0510_b	SG 細管入口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	BOC 相当
19	grape-sgtr-t_0106_e	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 6 分	EOC 相当
20	grape-sgtr-t_0106_b	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 6 分	BOC 相当
21	grape-sgtr-t_0108_e	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 8 分	EOC 相当
22	grape-sgtr-t_0108_b	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 8 分	BOC 相当
23	grape-sgtr-t_0110_e	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 10 分	EOC 相当
24	grape-sgtr-t_0110_b	SG 細管上端	原子炉トリップ後 1 分	原子炉トリップ後 10 分	BOC 相当
25	grape-sgtr-t_0306_e	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 6 分	EOC 相当
26	grape-sgtr-t_0306_b	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 6 分	BOC 相当
27	grape-sgtr-t_0308_e	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 8 分	EOC 相当
28	grape-sgtr-t_0308_b	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 8 分	BOC 相当
29	grape-sgtr-t_0310_e	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 10 分	EOC 相当
30	grape-sgtr-t_0310_b	SG 細管上端	原子炉トリップ後 3 分	原子炉トリップ後 10 分	BOC 相当
31	grape-sgtr-t_0506_e	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 6 分	EOC 相当
32	grape-sgtr-t_0506_b	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 6 分	BOC 相当
33	grape-sgtr-t_0508_e	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 8 分	EOC 相当
34	grape-sgtr-t_0508_b	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 8 分	BOC 相当
35	grape-sgtr-t_0510_e	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 10 分	EOC 相当
36	grape-sgtr-t_0510_b	SG 細管上端	原子炉トリップ後 5 分	原子炉トリップ後 10 分	BOC 相当
37	grape-sgtr-o_0106_e	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 6 分	EOC 相当
38	grape-sgtr-o_0106_b	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 6 分	BOC 相当
39	grape-sgtr-o_0108_e	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 8 分	EOC 相当
40	grape-sgtr-o_0108_b	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 8 分	BOC 相当
41	grape-sgtr-o_0110_e	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 10 分	EOC 相当
42	grape-sgtr-o_0110_b	SG 細管出口	原子炉トリップ後 1 分	原子炉トリップ後 10 分	BOC 相当
43	grape-sgtr-o_0306_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	EOC 相当
44	grape-sgtr-o_0306_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	BOC 相当
45	grape-sgtr-o_0308_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	EOC 相当
46	grape-sgtr-o_0308_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	BOC 相当
47	grape-sgtr-o_0310_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	EOC 相当
48	grape-sgtr-o_0310_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	BOC 相当
49	grape-sgtr-o_0506_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	EOC 相当
50	grape-sgtr-o_0506_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	BOC 相当
51	grape-sgtr-o_0508_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	EOC 相当
52	grape-sgtr-o_0508_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	BOC 相当
53	grape-sgtr-o_0510_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	EOC 相当
54	grape-sgtr-o_0510_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	BOC 相当
モデル評価のための解析 (No. 101~103)					
101	grape-sgtr-i_0409_b	SG 細管入口	原子炉トリップ後 4 分	原子炉トリップ後 9 分	BOC 相当
102	grape-sgtr-t_0207_e	SG 細管上端	原子炉トリップ後 2 分	原子炉トリップ後 7 分	EOC 相当
103	grape-sgtr-o_0406_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 10 分	BOC 相当

表 3.3.2-3 試評価版 SGTR 解析条件（モデル学習のための解析 54 ケース）

実施条件		ケース数
①破断位置	SG 細管入口、SG 細管上端、 SG 細管出口のいずれかで破断	3
②破断側 SG 隔離	原子炉トリップ後 1、3、5 分のいずれかで実施	3
③健全側 MSRV 開	原子炉トリップ後 6、8、10 分のいずれかで実施	3
④減速材密度係数	EOC 相当、BOC 相当のいずれかの 減速材密度係数で実施	2

AI モデルに学習させたパラメータ

SGTR 解析の出力のうち、AI モデルに学習させたパラメータのリストを表 3.3.2-4 に示す。

表 3.3.2-4 AI モデルに学習させたパラメータのリスト

01	原子炉出力 (NIS)
02	原子炉トリップ信号
03	安全注入信号
04	1 冷却材配管高温側温度 (健全側)
05	1 冷却材配管高温側温度 (破断側)
06	1 冷却材配管低温側温度 (健全側)
07	1 冷却材配管低温側温度 (破断側)
08	1 冷却材平均温度温度 (健全側)
09	1 冷却材平均温度温度 (破断側)
10	1 次冷却材圧力 (健全側ループ)
11	加圧器逃がし弁開度
12	加圧器圧力
13	加圧器水位
14	充てん流量
15	抽出流量
16	高圧注入流量
17	主蒸気圧力 (健全側)
18	主蒸気圧力 (破断側)
19	蒸気発生器狭域水位 (健全側)
20	蒸気発生器狭域水位 (破断側)
21	主蒸気隔離弁開度 (健全側)
22	主蒸気隔離弁開度 (破断側)
23	主給水流量 (健全側)
24	主給水流量 (破断側)
25	電動補助給水流量 (健全側)
26	電動補助給水流量 (破断側)
27	タービン動補助給水流量 (健全側)
28	タービン動補助給水流量 (破断側)
29	主蒸気流量 (健全側)
30	主蒸気流量 (破断側)

クロノロジ

令和 4 年度に実施した SGTR 解析結果のクロノロジについては、添付資料 A に記載した。

主要パラメータの解析結果

令和 4 年度に実施した SGTR 解析結果の主要パラメータの挙動については、添付資料 A に記載した。

【R5】

(3) AI モデル学習用の追加解析の目的及び概要

令和 5 年度は、学習データ拡充による AI 評価精度への影響について評価を行う目的で、対象事例において構築したデータベースを用いて、AI モデル学習用の SGTR 解析を新たに 96 ケース（令和 4 年度に実施した 54 ケースを含めると 150 ケース。）実施した。

また、新たに AI モデル評価用の SGTR 解析についても 3 ケースを実施した。

(4) 解析条件

解析手法

令和 5 年度においては、令和 4 年度と同様に GRAPE により生成した国内 4 ループ PWR プラントを模擬した入力データをベースに、SGTR 解析に必要なモデルを追加した上で、RELAP/SCDAPSIM による SGTR のベースシナリオ解析とパラメータサーベイを実施した。

解析条件・解析ケース

AI モデルの学習のための解析 150 ケース（令和 4 年度に実施した 54 ケースを含める。）と AI モデル評価のための解析（3 ケース）の計 153 条件で SGTR 事故シナリオの解析を実施した。（詳細については添付資料 A を参照。）

各ケースの主要な解析条件については、令和 4 年度に実施した 54 ケースと同様である（表 3.3.2-1 を参照。）。令和 5 年度においては、図 3.3.2-1 に記載されている「②破断側 SG 隔離」、および「③健全側 MSR/V 開」の操作タイミングについてマトリクスを細分化する方法で評価点の合計が 150 ケースとなるように拡充した。令和 5 年度における AI モデル学習用データ拡充のための解析条件の概要を図 3.3.2-1 に示す。「②破断側 SG 隔離」、および「③健全側 MSR/V 開」のタイミングは運転員操作に関わる条件であり、かつマトリクス細分化が行いやすいので AI モデル学習用のデータ拡充の対象とした。

AI モデル学習のための解析（150 ケース）の解析条件を表 3.3.2-5 に示す。（各ケースの詳細な解析条件については、添付資料 A を参照。）

表 3.3.2-5 SGTR 解析条件（モデル学習のための解析 150 ケース）

実施条件		ケース数
①破断位置	SG 細管入口、SG 細管上端、 SG 細管出口のいずれかで破断	3
②破断側 SG 隔離	原子炉トリップ後 1、2、3、4、5 分のいずれかで実施	5
③健全側 MSRVR 開	原子炉トリップ後 6、7、8、9、10 分のいずれかで実施	5
④減速材密度係数	EOC 相当、BOC 相当のいずれかの 減速材密度係数で実施	2

AI モデル評価のための解析（3 ケース）の解析条件を表 3.3.2-6 に示す。

表 3.3.2-6 SGTR 解析条件（モデル評価のための解析 3 ケース）

No.	解析ケース	①破断位置	②破断側 SG 隔離	③健全側 MSRVR 開	④減速材密度係数
201	grape-sgtr-test_01	SG 細管入口	原子炉トリップ後 2.5 分	原子炉トリップ後 7.5 分	BOC 相当
202	grape-sgtr-test_02	SG 細管上端	原子炉トリップ後 3.5 分	原子炉トリップ後 7.5 分	EOC 相当
203	grape-sgtr-test_03	SG 細管出口	原子炉トリップ後 4.5 分	原子炉トリップ後 6.5 分	EOC 相当

AI モデルに学習させたパラメータ

令和 5 年度においては、令和 4 年度と同様に、表 3.3.2-4 に記載されたパラメータを AI モデルに学習させた。

(5) 解析結果

クロノロジ

令和 5 年度に実施した SGTR 解析結果のクロノロジについては添付資料 A に記載した。

主要パラメータの解析結果

令和 5 年度に実施した SGTR 解析結果の主要パラメータの挙動については、添付資料 A に記載した。

(6) 解析結果の考察

SGTR 解析結果のモデル学習のための解析結果の考察については、添付資料 A に記載した。

3.3.3 AI モデル評価（東京大学、再委託先：NEL）【R3-R5】

(1) LOCA 事象に対する AI モデル評価（東京大学）

【R3-R4】

令和 3 年度は、AI モデル評価の前提として、事故時プラント解析にかかわる機械学習や AI を適用した事例を調査した。いずれの事例においても、原子力災害発生時の漏洩口径や配管の破断口径を推定したものであったが、破断口からの流量を予測するといった時間変化を伴う評価ではなく、原因箇所を推定するといった静的な評価に留まっていたことが確認できた。

令和 4 年度は、前年度より開始した文献調査の結果を踏まえ、選定する時系列データ解析モデルを LSTM に決定し、時系列データをインプットとするモデル構築を開始した。

【R5】

本項では、令和 5 年度に実施した AI モデル評価の項目について説明する。3.3.1 項、3.3.2 項における AI モデルを構築し、異なるエポックとルックバック値で学習させた LSTM モデルの予測性能を検証した。本 LSTM モデルでは、LOCA 時の水位、ホットレグ温度、1 次冷却材流量の時間推移を適切に予測することができた。これらのモデルのハイパーパラメータを表 3.3.3-1 に要約する。各予測タスクにおいて、一定のエポックでルックバック値を変化させると予測性能に一定の傾向が見られた。しかしながら、ルックバック値を維持したままエポックを変化させた場合には、予測精度への影響は見られなかった。このことから、それぞれのルックバック値と予測タスクで最も性能の良いモデルを特定した。

表 3.3.3-1 LSTM モデルにおけるハイパーパラメータ最適値のまとめ

Lookback (k)	Epoch	LSTM Depth	Number of Hidden Units	Initial Learn Rate
Water Level				
3	100	2	200	0.003
5	300	1	63	0.0024
7	100	1	157	0.0031
Hot Leg Temperature				
3	500	1	81	0.001
5	400	1	72	0.001
7	100	1	157	0.0031
Primary Coolant Flow rate				
3	100	2	200	0.003
5	400	1	72	0.001
7	100	1	157	0.0031

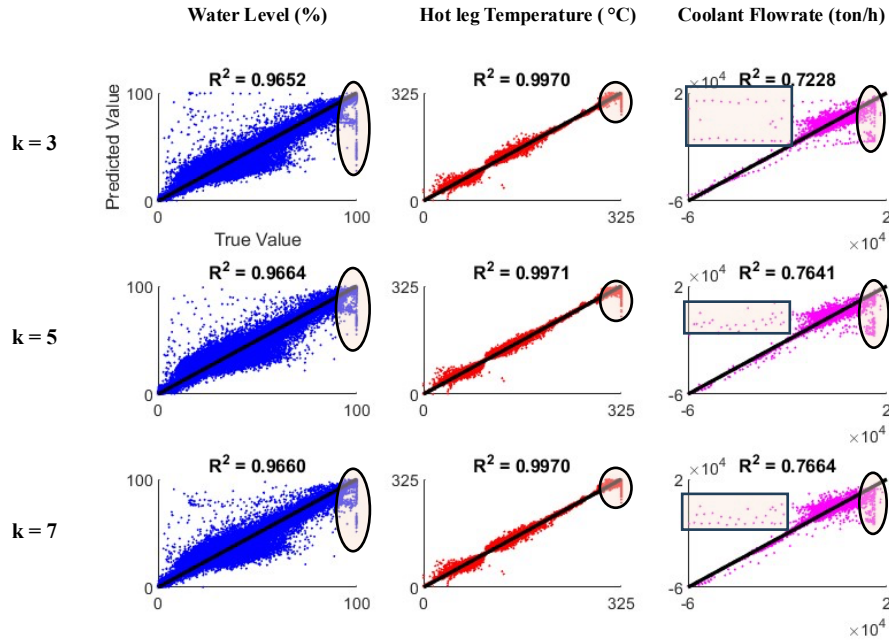


図 3.3.3-1 ルックバック値ごとの LSTM モデルの予測プロット

図 3.3.3-1 は、各ルックバック値および原子炉変数における最良の LSTM モデルの予測値をプロットしたものである。水位とホットレグ温度の予測モデルが、すべてのルックバック値において流量モデルよりも正確な予測結果を示している。流量予測プロットの枠で囲まれた部分によって強調されているように、本モデルが LOCA 時の急激な流量低下の予測が困難であることが考えられる。すべてのモデルで顕著な特徴は、プロットの囲み部分で示される原子炉変数の最大値付近の縦筋である。この縦筋は、LOCA 発生付近で発生する原子炉変数の最大値を予測するモデルの精度の低さを示している。つまり、原子炉変数やルックバック値にかかわらず、LOCA 発生から初期時間ステップを予測することは困難である。最後に、水位予測値の誤差は水位値の全範囲に及ぶが、ホットレグ温度予測値の誤差は 50 ~ 200°C に集中する。

各ルックバック値と原子炉変数における最良モデルの予測からの絶対誤差分布を図 3.3.3-2 に示す。殆どの水位予測は、k=3、5、7 のモデルにおいて、実際の値から 0.17、0.36、0.17 単位の範囲内に収まっている。ホットレグの温度予測については、k=3、5、7 のモデルで、殆どの予測値が 0.3、0.18、0.36°C の範囲内に収まっている。最後に、流量予測は、それぞれ毎時 205 トン、173.8 トン、163.2 トンの範囲内で乖離している。図 3.3.3-3 では、選択したテストサンプルと代表モデルを用いて、様々な反応器変数の予測を可視化している。代表モデルは、各反応器変数で最も良いパフォーマンスを示したモデルの中で最も良いものとして選択されている。

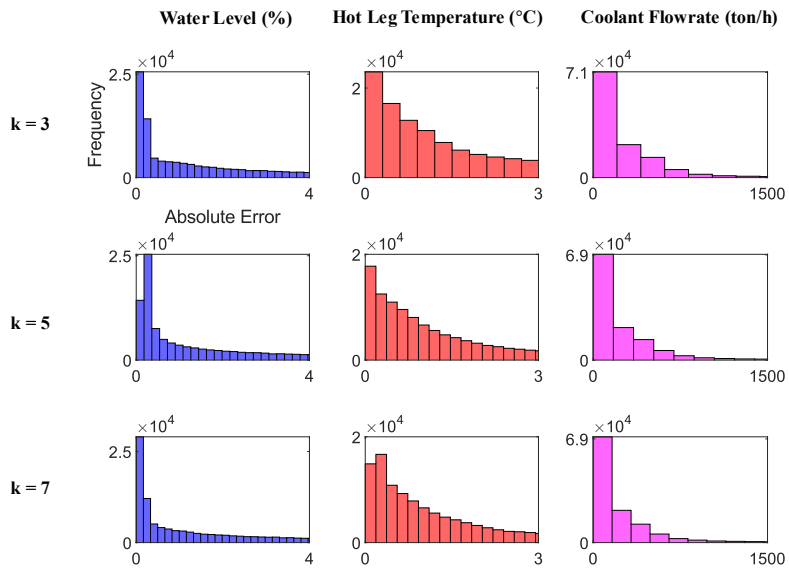


図 3.3.3-2 ルックバック値あたりの LSTM モデルの絶対誤差分布

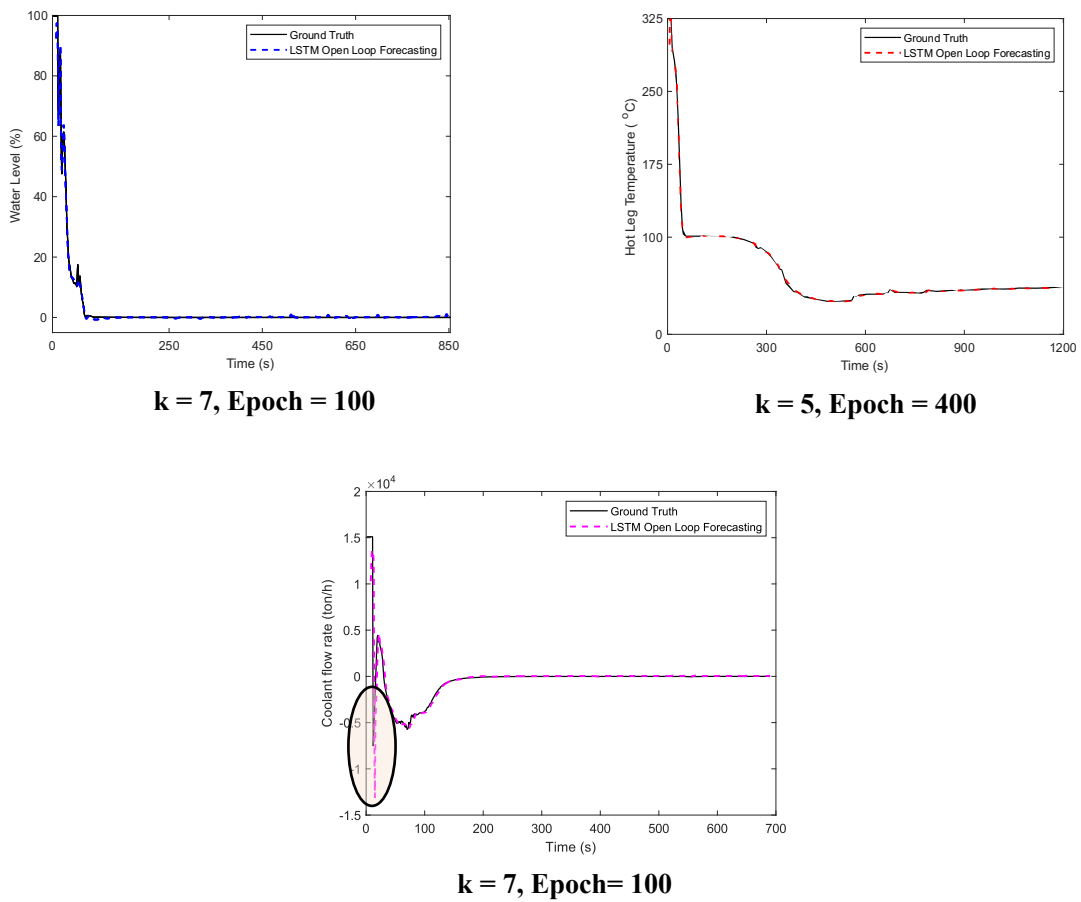


図 3.3.3-3 (a)最適水位、(b)ホットレグ温度、(c)一次冷却材流量の予測結果

LOCA 時の配管損傷の位置と範囲の予測

本項では、LOCA 発生時の時系列データから、LSTM ベースのモデルが配管損傷の位置と程度を予測する能力を評価する。さらに、様々な切断サイズにおけるモデルの予測性能を調査し、最も優れた予測モデルを特定した。

図 3.3.3-4 は、データセットのカットサイズを変えて学習した LSTM リグレッサーの RMSE 値を示している。LSTM リグレッサーは、0~100%の範囲の配管損傷を予測する。LSTM ベースのリグレッサーは、LOCA 時系列データの小さなカットから配管損傷の程度を予測することができる。この解析では、LOCA シナリオのシミュレーションは秒単位の時間スケールであるため、LSTM ベースの回帰器は 48 秒後までに配管損傷の程度を予測できることになる。しかし、実際のアプリケーションを考慮すると、モデルが 48 タイムステップを取得できる時間は計測器の計測速度に依存し、シミュレーションよりも遅くなる可能性が有る。それにもかかわらず、LSTM リグレッサーは、LOCA の初期段階における配管損傷の程度を十分に予測した。また、2%カットから 4%カットにかけての予測性能の顕著な急上昇は、この間に事故の進行に大きな進展が有り、配管損傷の程度を容易に予測できるようになった可能性を示している。




図 3.3.3-4 データセットカット割合を変化させた場合の LSTM 回帰の性能

データセットのカットの中では、8%カットで学習した LSTM 回帰器が RMSE 値 0.57 で最も良い結果を示した。テストセットに対するこのモデルの予測値を図 3.3.3-5 にプロットする。




図 3.3.3-5 LSTM 回帰の予測曲線最適値のまとめ (8%データセット・カット)

表 3.3.3-2 は、データセットのカットを変化させた場合の LSTM 分類器のテスト分類精度を示している。LSTM 分類器は、LOCA 時の配管破断がコールドレグで起こるか、ホットレグで起こるかを予測する。LSTM 回帰器と同様に、LSTM 分類器は、データセットカットが 4%と低い場合、または事故発生から約 48 タイムステップで配管破断の位置を予測することが可能となる。また、2%カットから 4%カットへの予測性能の急激な向上も LSTM 分類器で観察される。20%カットのデータセットで学習した LSTM 分類器のテスト精度は 99.24%で、これは 132 のテスト LOCA シナリオのうち 1 つの誤分類に相当する。最後に、最も優れた予測モデルのハイパーパラメータを以下の表 3.3.3-3 にまとめる。

表 3.3.3-2 データセットカット割合を変化させた場合の LSTM 分類器の性能

Dataset Cut	Classification Accuracy	Dataset Cut	Classification Accuracy
2%	90.91%	12%	97.73%
4%	97.73%	14%	97.73%
6%	93.94%	16%	96.97%
8%	96.97%	18%	98.48%
10%	97.73%	20%	99.24%

表 3.3.3-3 LSTM 予測モデルのハイパーパラメータのまとめ

Task	Best Performing Dataset Cut	LSTM Depth	Number of Hidden Units	Initial Learn Rate
Regression	8%	1	100	0.0018
Classification	20%	3	90	-

このパートでは、LSTM ベースの予測モデルの性能についてまとめた。その結果、LOCA 発生から 4%カットまでの時系列データを小さくカットしたデータから、配管損傷の位置と程度を良好に予測することができた。これは、LSTM ベースのモデルが LOCA の初期段階における配管破損を診断する可能性が有ることを示している。

(2) SGTR 事象に対する AI モデル評価

【R3-R4】

① 目的

令和 3 年度は、AI モデル評価の前提として、事故時プラント解析にかかわる機械学習や AI を適用した事例を調査した。

令和 4 年度は、SGTR 解析について実際の事故時を想定し、運転員の操作によりプラントパラメータが動的に大きく変化することが予想されるケースでの AI モデルの構築、および試評価を行った。これまでは漏洩口径等の静的なデータを推定することはなされていたが、事故対応の観点から有効な、破断口からの流量などの動的挙動を評価することはなされていなかった。そのため、令和 4 年度の研究においては、事故発生時に運転員の操作によってプラントパラメータが変動するような場合を想定することとした。

② AI モデル・学習について

画像解析などの AI 技術では発展が著しく、多くのベンチマークで既存手法を上回る精度を獲得しているが、どのような判断根拠で予測や推定結果を出力したのかを解明するのが非常に困難であることから、最新の研究では説明性を確保するようにモデルを作ることなどが重要視されている。画像解析や自然言語処理などの分野では、認識の際に注視した領域を可視化できる視覚的説明を用いることで、深層学習の判断根拠の理解に取り組んでいる。それら AI 技術の適用によって事故進展にかかわる動的な時系列パラメータの変動や、運転員の操作に伴うパラメータの変動などを捉えた上で、予測に対しての説明性および信頼性の向上に資することができる AI モデルが構築できることが期待される。

そこで、先行研究例を参考に参考文献^[2]に示す MICN (Multi-scale Local and Global Context: 多スケールコンテキスト) という構造のモデルで、画像解析の AI モデルで使われる CNN と、自然言語処理の分野で使われ始めて、近年は多くの分野で用いられることが多い Transformerなどを組み合わせて、時系列データの特徴である局所的な特徴と、大域的な時系列データとの関係を考慮したモデルを構築した。局所的な特徴とは、あるパラメータの短期的な特徴を表し、大域的な時系列データとの関係とは、その後の長期間に亘るパラメータ挙動との間で示される関係性である。例えば、ある瞬間の運転員の操作は、その後のあるパラメータ (プラント内の局所的な圧力や流量値等) の特定の変化に影響するだけでなく、操作後の長期間に亘りプラントの全体的な挙動に影響を与える。

これらの関係を考慮したモデルの構築によって、時系列データの予測だけではなく、以下のような特徴を備えられると考えられる。

- ・ 短期的な変化を測定・検出するための局所的な特徴を抽出する能力

- ・ 長期的な変化を測定するためのグローバルな関係性をモデル化する能力

図 3.3.3-6 に MICN の全体的な構造を、また、図 3.3.3-7 に MICN の内部構造詳細を参照文献^[27]より引用した。MICN の構造では CNN や Transformer の構造を内部に持っているため、LSTM とは異なり、大規模データによる事前学習や推定に利用した箇所を可視化する技術が使えるようになっていることなどが特徴である。

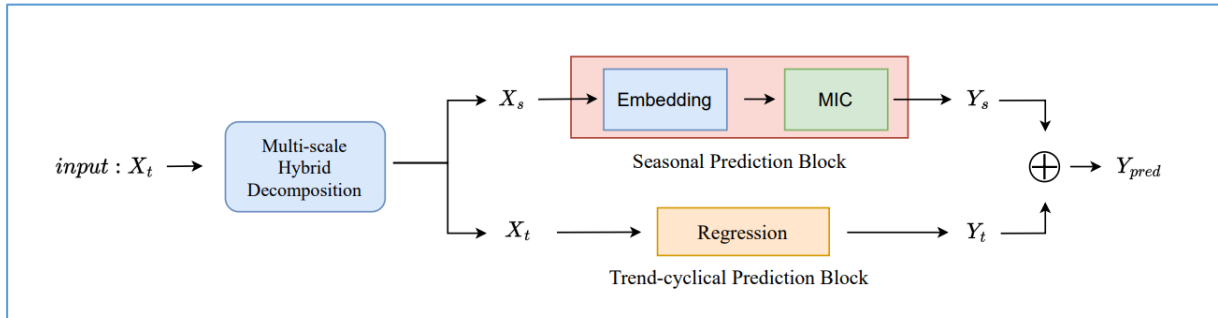


図 3.3.3-6 MICN 全体構造 文献[2]より引用

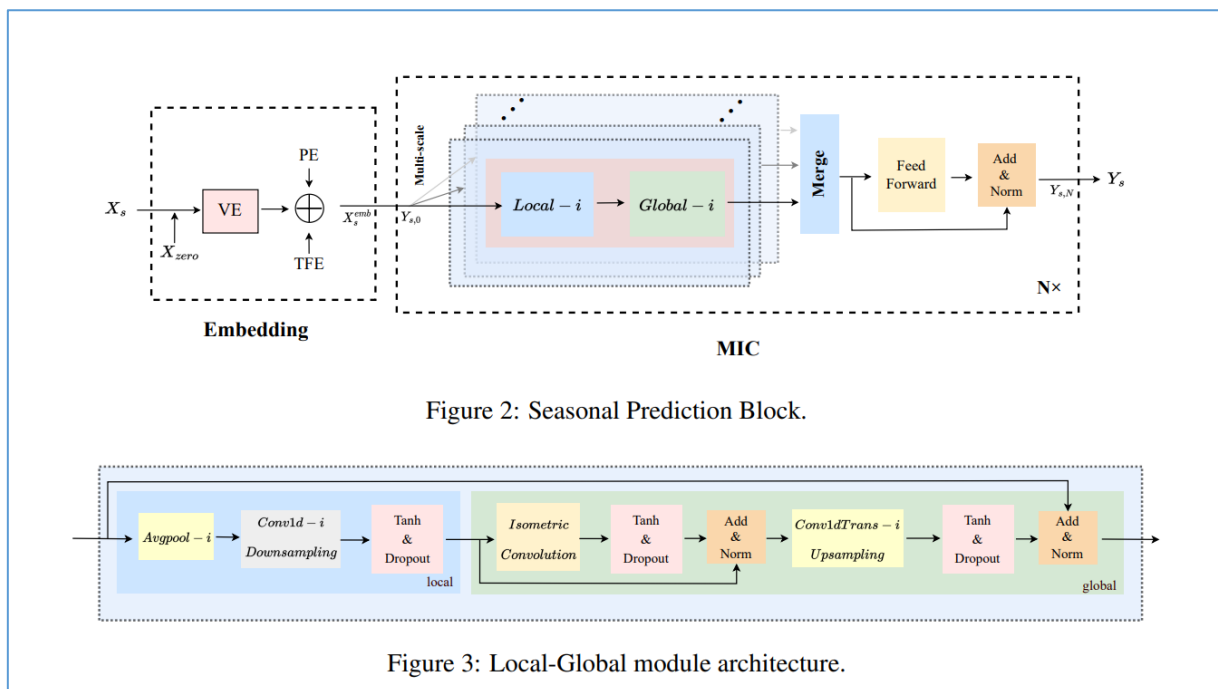


図 3.3.3-7 MICN の内部構造詳細 文献[2]より引用

SGTR 発生後 30 分間のパラメータを下に、事象発生から 30 分後の積算漏洩量を推定した。これらの研究では、従来から時系列データ解析に用いられている LSTM と呼ばれる手法をベースラインとし、MICN と比較して、いずれのモデルでも令和 4 年度に実施した解析ケースにおいて、高精度に推定が行えることを確認した。

【R5】

令和 5 年度においては、令和 4 年度の試評価結果を受けて、学習データ拡充による AI 評価精度への影響について評価を行った。データ拡充の対象となる解析ケースは、前述の通り、運転操作の影響が有る「破断側 SG 隔離のタイミング」、「健全側 MSRVR 開のタイミング」とした。

なお、令和 5 年度は、令和 4 年度の研究において、MICN と呼ばれる手法では、学習時の安定性が高いことが確認できたため、この手法を用いて、モデル作成を行うこととした。

③ 評価

評価データ

モデルの学習および評価をするためのデータとして、令和 4 年度の SGTR の解析データと併せて、令和 5 年度に追加解析を行った SGTR の解析データを用いた。また、GRAPE (RELAP/SCDAPSIM) による解析データには破断口流量のパラメータが有るため、それを用いて破断口からの積算流量を計算し、それを予測するための変数として作成した。

AI 評価に用いる全体のデータは、事故想定とした 150 ケースの学習用データと、3 ケースの評価用データから構成される。事故時プラントパラメータの解析結果を 1 秒ごとに出力するようになっている。実プラントの Safety Parameter Display System (安全パラメータ表示システム：以下、SPDS と略記。) は 60 秒間隔でデータを抽出するようになっているため、SPDS のサンプリングを考慮し、60 秒間隔のデータを抽出するようにしたものを SPDS からのサンプルと見なし、1 つの時系列データのサンプルとして扱うようにした。このようにすることで、150 ケース×60 時点のサンプリングタイミング=9,000 サンプルを学習用データとして扱うこととした。また、それぞれの時系列長は、事故対応操作タイミングを考慮し、30 分間のデータとなるようにした。

評価用のデータについても、サンプリングタイミングを 1 秒ずつ変動させて、60 時点のサンプリングタイミングを用いることとした。

評価詳細

CNN や Transformer の構造を内部に持つ MICN というモデルを用いて評価を行うこととした。SPDS で実測可能なパラメータを用いて、30 分間におけるパラメータの挙動から、その 30 分の期間内における 1 次系から 2 次系への漏洩流量の積算値を時系列データとして学習するようにした。モデルのインプットとしたパラメータは GRAPE の解析データのパラメータのうちで実測可能なパラメータである。これらを用いて GRAPE の解析データのみで用いられる破断口流量データの積算値の時系列推移の再現性を評価した。モデルの学習の際には、50 回の学習を行うようにした。学習したモデルに対して、評価用の 3 ケースのデータによって評価を行った。

評価結果・結論

学習用のデータセットに対して SPDS の実測可能なパラメータの 30 分間の時系列データを用いて、破断口流量の 30 分間の積算値の推移を推定するモデルを学習させた。学習時の損

失関数の推移を図 3.3.3-8 に示す。学習時の損失関数の推移を示したグラフは横軸に学習回数を示しており、縦軸は学習時の損失関数の値を示している。これによって、データ数を増やした場合においても、学習は早期に収束している様子が確認できる。

各評価ケースは評価用データとして作成した添付資料 A の表 A.2-3 における No. 201、202、203 (grape-sgtr-test_01、grape-sgtr-test_02、grape-sgtr-test_03) の 3 つの評価ケースを用いており、学習用データとは異なる解析条件によって得られたケースを用いた。図 3.3.3-9 に示すように、いずれの評価ケースにおいても、破断口流量積算値の推移状態の MICN モデルによる推定結果は、プラント挙動解析結果にほぼ一致しており、学習データの拡充により高精度な推定を行うことができていることが分かる。




図 3.3.3-8 MICN の学習における損失関数の推移

[




図 3.3.3-9 評価用データセットでの積算流量の推移と推定結果

また、令和 4 年度に 54 ケースの解析データを用いて学習したモデルに対して新規に令和年度の 96 ケースの解析データを追加した、全体で 150 ケースの解析データを用いて、追加学習することを行った。追加学習においては、初期段階から、かなり高精度のモデルとなっており、早期に学習が安定して収束していた。追加学習時の損失関数を図 3.3.3-10 に示す。




図 3.3.3-10 追加学習時の損失関数の推移

MICN モデルでは、内部の局所構造部分のパラメータは CNN 部分などで事前学習済みモデルを使用することが可能であり、これらは大規模なデータを用いて事前に学習を行い、タスクごとの再学習やデータの追加では、全体的なモデルの再学習は不要となるなど、効率的な学習を行うことができるようになっている。これらを踏まえて、解析データを学習させながら運転員操作を伴うようなプラントデータから、複雑な時系列データの推定を行う AI のモデル作成が行えるようになったと言える。

(3) まとめ

最後に、本課題(3)により得られた成果をまとめる。LOCA 事象評価においては、GRAPE (RELAP) を用いた小 LOCA を対象とし、異なる破断口径を付与したプラント挙動の解析を実施した。本課題では配管破断口径の予測と、事故進展予測の 2 種類を対象とした。機械学習モデルとしては、文献調査を行った結果、LSTM モデルを選定することとし、配管破断の口径予測並びに事故進展予測を可能とするモデルの構築を実施した。最終年度である令和 5 年度は、事故進展予測性能に照準を絞り、事故初期段階の時系列データの長さを 2~20%に変化させ、精度の検証を行ったところ、すべての条件において 90%以上の精度に到達することが確認できた。本課題で選定した特徴量は、制御室にてモニタリング可能な値

に限定していることから、小 LOCA 時に異常な信号が発生した際、事故進展初期のデータを随時入力させていくことで、事故の進展やプラントの傾向をいち早く予測することが可能なツールとしての応用が期待される。第 2 のテーマとしては SGTR を対象とし、MICN モデルを用いた推定を実施した。本課題において取り上げたケースにおいては、破断口流量積算値の推定結果等、プラント挙動解析結果とほぼ一致していることが分かり、学習データの拡充により高精度な推定を行うことが分かった。ただし、実際のプラントでは、事故対応時の初動、対策等は規定によって定められており、既に細かくマニュアル化されていることから、本ツールをはじめとした AI 技術が、既存の手法を代替するのは時期尚早であると考えられる。しかしながら、現場の事故対応に役立つ補助的なツールとして、有効な情報源の 1 つとして用いられる可能性は高いと考える。

3.4 研究推進【R5】

研究代表者の下で各研究課題従事機関との連携を密にして、研究を進めた。研究実施計画を推進するためのオンライン会議を定期的実施するとともに、slack を用いた情報交換プラットフォームを構築した。

4. 結言

本業務では、画像認識と物体検出を軸とした AI 技術に着目し、データベースに潜んだ関係性を捉える「データ駆動型アプローチ」を検討し、AI 技術と熱流動の融合による安全評価手法の開発を目的としている。以下に、3 ヶ年計画の最終年度である令和 5 年度の業務実績を述べる。

(1) データ駆動型熱流動モデル開発

① 空気-水系円管における流動様式遷移モデルの開発

高速度カメラを使用し、東京大学に設置されている空気-水系二相流実験装置を使用し、二相流画像データベース構築を実施した。

② 沸騰系矩形管における流動様式遷移モデルの開発（再委託先：電気通信大学）

蒸気-水系矩形管実験装置を使用し、沸騰二相流画像データベースを構築した。

③ AI モデル構築・評価（東京大学、再委託先：電気通信大学）

AI モデル構築用の最新情報を収集し、訓練データを用いたモデル構築を実施した。

(2) データ駆動型熱流動解析手法開発（再委託先：原子力機構）

① JUPITER による垂直上昇二相流解析

AI モデル構築用の CFD による計算データベース構築を行った。

② JUPITER による噴流着水解析

AI モデル構築用の CFD による計算データベース構築を行った。

(3) データ駆動型評価モデル開発（東京大学、再委託先：NEL）

① GRAPE による LOCA 事故事象データベース構築+AI モデルの構築と評価

2 ループ PWR の LOCA 事象解析を実施し、事故進展時の時系列データベース構築を行った。

② 運転員操作を有する事故事象パラメータ解析

対象事例を決定し、解析環境を整え、データベース構築を行った。

③ AI モデル評価

モデル構築に向けた情報収集を進めつつ、モデル構築を行った。

(4) 研究推進

研究代表者の下で各研究項目間の連携を密にして、研究を進めた。研究実施計画を推進するための関係者間の打ち合わせを実施した。

(5) 本研究・開発の自己評価と今後の課題

3 年間に亘り、熱流動と人工知能技術の融合を目的に、気液二相流の流動様式、沸騰二相流の流動遷移、噴流による着水、並びに、プラント事故時の挙動といった課題を選定し、実験から解析に至るまで幅広いデータベースを構築した。また、機械学習モデルとしては、画像を対象とした CNN モデルや、物体検出モデル、時系列データを対象とした LSTM、MICN モ

デルを取り扱った。熱流動への応用を検討するにあたり、本事業を通しての気付きと、自己評価を以下に記す。

- 機械学習が得意、不得意とする対象が有ることから、問題設定は重要である。特に、教師有り学習の場合は、人間の眼である程度の判別やラベル付けが可能であることが、信頼性の高いモデルに繋がると考える。ここで問題となるのが、誤った情報（ラベル付け）により機械学習モデルを構築した場合でも、条件によっては、70～80%程度の精度が出てしまうことも有ることから、精度（Accuracy）等に示される結果を鵜呑みにしないよう注意が必要である。
- 二相流に関しては、チャーン流の識別は他の流動様式と比較して精度が若干落ちる結果となったが、本研究・開発で取得したチャーン流のデータが少なかったことも関連するが、チャーン流の定義そのものが曖昧であることも解析を難しくした要因の1つとして挙げられる。前述した通り、教師が確実な情報を提供できなければ、学習者の理解度も曖昧となってしまう。
- 上述した注意点を踏まえ、構築した深層学習モデルの隠れ層を可視化させてみる等して、どのような判断基準、根拠でアウトプットが得られているのかを検証するステップが重要となる。
- 本研究・開発ではデータベースの構築（実験、CFD 計算）に大半の時間が割かれた。現状の教師有り学習は、人間がお膳立てをしてやらねば、精度の良い深層学習モデルが構築できないように映る。このことから、生成 AI に代表されるようなデータ生成の研究が今後重要になると考えられ、熱流動の分野においても、高速度カメラの画像データや、CFD 計算結果を自動的に生成するようなモデル開発は有用性が有るように思う。
- 上記と関連して、教師無し学習によるクラスタリングについても並行して検討する余地が有ると考えられる。AI によるデータ生成と、教師無し学習が完成すれば、ほぼ大半のプロセスのオートメーション化が可能となる。これが理想的な到達点であると考ええる。
- AI モデルの結果をどのように検証するべきか、本研究・開発を通じて色々と考えさせられた。AI モデルを原子力安全に応用する場合には、V&V が必要不可欠である。CFD の V&V スタンドアードが米国機械学会により提案されたのと同様、機械学習モデルの V&V 手法の整備が求められる。

以上、3 ヶ年計画の最終年度である令和 5 年度の業務項目を実施し、所期の目標を達成した。

5. 参考文献

- [1] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- [2] Huiqiang Wang and Jian Peng and Feihu Huang and Jince Wang and Junhui Chen and Yifei Xiao 「MICN: Multi-scale Local and Global Context Modeling for Long-term Series Forecasting」 The Eleventh International Conference on Learning Representations 2023

添付資料： AI モデル学習および評価のための SGTR 解析

(1) 概要

運転員操作を有する事故事象の際に、運転操作タイミング等の変動に伴う事故進展への影響を AI により迅速に評価を行うことを目的として、SGTR 事象^{*}の解析を実施した。本解析結果は AI モデルの学習および評価に使用される。

※今回の解析を実施した「SGTR 事象に対応する操作手順」については、電気事業者の現行の「事故時操作所則」に準拠している。

(2) 解析条件

解析コード・対象プラント

解析コード：RELAP5/SCDAP Mod3.4

対象プラント：国内 4 ループ PWR プラント（GRAPE^{*}内蔵データ）

※Graphical RELAP5-based Analysis Platform for Education & Engineering

解析条件・解析ケース

本解析では、AI モデルの学習のための解析（150 ケース）と AI モデル評価のための解析（3 ケース）の計 153 条件で SGTR 事故シナリオの解析を実施した。

各ケースの解析条件を表 A.1 および表 A.2-1～表 A.2-3 に記す。AI モデルの学習のための解析については、令和 4 年度に実施した 54 ケースおよび令和 5 年度に実施した 96 ケースの区別を行わずに、150 ケースの解析結果として No. を割り当てた。なお、令和 4 年度に実施した解析については表 A.2-1～表 A.2-3 において水色で網掛けしている。

表 A.1 SGTR 解析条件（モデル学習およびモデル評価のための解析）

	項目	実施条件	
起 因 事 象	SGTR 破断箇所 (①)	破断箇所：以下のいずれかの箇所を設定 ・SG 細管入口（高温側） ・SG 細管上端 ・SG 細管出口（低温側）	解析ケースによって異なる破断箇所を設定 (表 A. 2-1～A. 2-3 参照)
	SGTR 破断面積	破断面積： $6.10 \times 10^{-4} [\text{m}^2]$ (SG 細管 1 本の両端破断に相当)	全ケース共通
事 故 条 件	外部電源	あり	全ケース共通
	安全機能の 喪失に対する 仮定	安全系の機器故障は想定しない	全ケース共通
運 転 操 作	破断側 SG 隔離 (②)	原子炉トリップから一定時間経過後に以下の操作を実施 ・主蒸気隔離弁閉止 ・補助給水停止 ・タービン動補助給水ポンプ蒸気抽出ラインの閉止 ・ブローダウンラインの閉止	解析ケースによって異なる操作タイミングを設定 (表 A. 2-1～A. 2-3 参照)
	健全側 SG による 2 次 系強制冷却 (③)	主蒸気逃がし弁全開： 原子炉トリップから一定時間経過後に健全側 SG の主蒸気逃がし弁を全開にする	解析ケースによって異なる操作タイミングを設定 (表 A. 2-1～A. 2-3 参照)
		主蒸気逃がし弁調整開（開度 30%）： 健全側の 1 次冷却材高温側配管温度が 276℃以下になったら健全側 SG の調整開にする	全ケース共通
	1 次系 減圧操作	加圧器逃がし弁開操作： 健全側の 1 次冷却材高温側配管温度が破断側 SG の飽和温度 - 6℃に達した段階で 1 系統の加圧器逃がし弁開操作を実施	全ケース共通
		加圧器逃がし弁閉操作： 加圧器圧力が破断側 SG 圧力以下に達したら実施	全ケース共通
安全注入 停止	高圧注入および低圧注入の停止： 加圧器逃がし弁閉操作と同タイミングで実施	全ケース共通	
そ の 他	減速材 密度係数 (④)	事故時の減速材密度係数として以下の 2 ケースを実施 ・BOC 相当 ・EOC 相当	解析ケースによって異なる減速材密度係数を設定 (表 A. 2-1～A. 2-3 参照)

表 A. 2-3 SGTR 解析ケース（モデル学習のための解析）（3/3）

No.	解析ケース	①破断位置	②破断側 SG 隔離	③健全側 MSRV 開	④減速材密度係数
118	grape-sgtr-o_0209_b	SG 細管出口	原子炉トリップ後 2 分	原子炉トリップ後 9 分	BOC 相当
119	grape-sgtr-o_0210_e	SG 細管出口	原子炉トリップ後 2 分	原子炉トリップ後 10 分	EOC 相当
120	grape-sgtr-o_0210_b	SG 細管出口	原子炉トリップ後 2 分	原子炉トリップ後 10 分	BOC 相当
121	grape-sgtr-o_0306_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	EOC 相当
122	grape-sgtr-o_0306_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 6 分	BOC 相当
123	grape-sgtr-o_0307_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 7 分	EOC 相当
124	grape-sgtr-o_0307_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 7 分	BOC 相当
125	grape-sgtr-o_0308_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	EOC 相当
126	grape-sgtr-o_0308_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 8 分	BOC 相当
127	grape-sgtr-o_0309_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 9 分	EOC 相当
128	grape-sgtr-o_0309_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 9 分	BOC 相当
129	grape-sgtr-o_0310_e	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	EOC 相当
130	grape-sgtr-o_0310_b	SG 細管出口	原子炉トリップ後 3 分	原子炉トリップ後 10 分	BOC 相当
131	grape-sgtr-o_0406_e	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 6 分	EOC 相当
132	grape-sgtr-o_0406_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 6 分	BOC 相当
133	grape-sgtr-o_0407_e	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 7 分	EOC 相当
134	grape-sgtr-o_0407_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 7 分	BOC 相当
135	grape-sgtr-o_0408_e	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 8 分	EOC 相当
136	grape-sgtr-o_0408_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 8 分	BOC 相当
137	grape-sgtr-o_0409_e	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 9 分	EOC 相当
138	grape-sgtr-o_0409_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 9 分	BOC 相当
139	grape-sgtr-o_0410_e	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 10 分	EOC 相当
140	grape-sgtr-o_0410_b	SG 細管出口	原子炉トリップ後 4 分	原子炉トリップ後 10 分	BOC 相当
141	grape-sgtr-o_0506_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	EOC 相当
142	grape-sgtr-o_0506_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 6 分	BOC 相当
143	grape-sgtr-o_0507_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 7 分	EOC 相当
144	grape-sgtr-o_0507_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 7 分	BOC 相当
145	grape-sgtr-o_0508_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	EOC 相当
146	grape-sgtr-o_0508_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 8 分	BOC 相当
147	grape-sgtr-o_0509_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 9 分	EOC 相当
148	grape-sgtr-o_0509_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 9 分	BOC 相当
149	grape-sgtr-o_0510_e	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	EOC 相当
150	grape-sgtr-o_0510_b	SG 細管出口	原子炉トリップ後 5 分	原子炉トリップ後 10 分	BOC 相当
モデル学習のための解析（No. 201～203）					
201	grape-sgtr-test_01	SG 細管入口	原子炉トリップ後 2.5 分	原子炉トリップ後 7.5 分	BOC 相当
202	grape-sgtr-test_02	SG 細管上端	原子炉トリップ後 3.5 分	原子炉トリップ後 7.5 分	EOC 相当
202	grape-sgtr-test_03	SG 細管出口	原子炉トリップ後 4.5 分	原子炉トリップ後 6.5 分	EOC 相当

■ 令和 4 年度実施 □ 令和 5 年度実施

AI モデルに学習させるパラメータ

SGTR 解析の出力のうち、AI モデルに学習させたパラメータのリストを表 A.3 に示す。

表 A.3 AI モデルに学習させたパラメータのリスト

01	原子炉出力 (NIS)
02	原子炉トリップ信号
03	安全注入信号
04	1 冷却材配管高温側温度 (健全側)
05	1 冷却材配管高温側温度 (破断側)
06	1 冷却材配管低温側温度 (健全側)
07	1 冷却材配管低温側温度 (破断側)
08	1 冷却材平均温度温度 (健全側)
09	1 冷却材平均温度温度 (破断側)
10	1 次冷却材圧力 (健全側ループ)
11	加圧器逃がし弁開度
12	加圧器圧力
13	加圧器水位
14	充てん流量
15	抽出流量
16	高圧注入流量
17	主蒸気圧力 (健全側)
18	主蒸気圧力 (破断側)
19	蒸気発生器狭域水位 (健全側)
20	蒸気発生器狭域水位 (破断側)
21	主蒸気隔離弁開度 (健全側)
22	主蒸気隔離弁開度 (破断側)
23	主給水流量 (健全側)
24	主給水流量 (破断側)
25	電動補助給水流量 (健全側)
26	電動補助給水流量 (破断側)
27	タービン動補助給水流量 (健全側)
28	タービン動補助給水流量 (破断側)
29	主蒸気流量 (健全側)
30	主蒸気流量 (破断側)

(3) 解析結果

クロノロジ

SGTR 解析結果のうち、モデル学習のための解析のクロノロジを表 A. 3. 1-1 および表 A. 3. 1-2 に、モデル評価のための解析のクロノロジを表 A. 3. 2 に示す。モデル学習のための解析については150 ケースの中からNo. 005、015、021、023、025、026、027、029、035、045、075、125 の結果のみを記載する。

表 A. 3. 1-1 SGTR 解析結果（モデル学習のための解析）（1/3）

操作・イベント	発生 / 実施時刻					
	005	015	021	023	025	026
	i_0108_e	i_0208_e	i_0306_e	i_0307_e	i_0308_e	i_0308_b
蒸気発生器細管破断	0sec					
原子炉トリップ	195sec	195sec	195sec	195sec	195sec	172sec
SI 信号自動発信	209sec	209sec	209sec	209sec	209sec	189sec
破断側 SG 隔離	255sec	315sec	375sec	375sec	375sec	352sec
健全側 SG による 2 次系強制冷却開始	675sec	675sec	555sec	615sec	675sec	652sec
加圧器逃がし弁開	809sec	804sec	714sec	758sec	802sec	802sec
1 次系減圧操作停止	883sec	895sec	797sec	835sec	876sec	906sec
安全注入停止	883sec	895sec	797sec	835sec	876sec	906sec
主蒸気逃がし弁調整開	1001sec	947sec	891sec	950sec	1001sec	904sec

表 A. 3. 1-2 SGTR 解析結果（モデル学習のための解析）（2/3）

操作・イベント	発生 / 実施時刻					
	027	029	035	045	075	125
	i_0309_e	i_0310_e	i_0408_e	i_0508_e	t_0308_e	o_0308_e
蒸気発生器細管破断	0sec					
原子炉トリップ	195sec	195sec	195sec	195sec	204sec	243sec
SI 信号自動発信	209sec	209sec	209sec	209sec	218sec	257sec
破断側 SG 隔離	375sec	375sec	435sec	495sec	384sec	423sec
健全側 SG による 2 次系強制冷却開始	735sec	795sec	675sec	675sec	684sec	723sec
加圧器逃がし弁開	861sec	896sec	818sec	826sec	795sec	849sec
1 次系減圧操作停止	939sec	990sec	906sec	931sec	847sec	911sec
安全注入停止	939sec	990sec	906sec	931sec	847sec	911sec
主蒸気逃がし弁調整開	995sec	1024sec	923sec	924sec	1011sec	1047sec

表 A. 3. 2 SGTR 解析結果（モデル評価のための解析）（3/3）

操作・イベント	発生 / 実施時刻		
	201	202	203
	test_01	test_02	test_03
蒸気発生器細管破断	0sec		
原子炉トリップ	172sec	204sec	243sec
SI 信号自動発信	189sec	218sec	257sec
破断側 SG 隔離	322sec	414sec	513sec
健全側 SG による 2 次系強制冷却開始	622sec	654sec	633sec
加圧器逃がし弁開	764sec	763sec	806sec
1 次系減圧操作停止	839sec	816sec	902sec
安全注入停止	839sec	816sec	902sec
主蒸気逃がし弁調整開	955sec	987sec	899sec

主要パラメータの解析結果

SGTR 解析結果のうち、モデル学習のための解析の主要パラメータの結果を下記の通り示す。

- 図 A. 3. 1-1 モデル学習のための解析結果(1)：破断側 SG 隔離操作のタイミングの違いによる影響比較 (1/2)
(No. 005、015、025、035、045 の 5 ケースを抜粋)
- 図 A. 3. 1-2 モデル学習のための解析結果(1)：破断側 SG 隔離操作のタイミングの違いによる影響比較 (2/2)
(No. 005、015、025、035、045 の 5 ケースを抜粋)
- 図 A. 3. 2-1 モデル学習のための解析結果(2)：健全側 MSRVR 開操作のタイミングの違いによる影響比較 (1/2)
(No. 021、023、025、027、029 の 5 ケースを抜粋)
- 図 A. 3. 2-2 モデル学習のための解析結果(2)：健全側 MSRVR 開操作のタイミングの違いによる影響比較 (2/2)
(No. 021、023、025、027、029 の 5 ケースを抜粋)
- 図 A. 3. 3-1 モデル学習のための解析結果(3)：破断位置の違いによる影響比較 (1/2)
(No. 25、75、125 の 3 ケースを抜粋)
- 図 A. 3. 3-2 モデル学習のための解析結果(3)：破断位置の違いによる影響比較 (2/2)
(No. 25、75、125 の 3 ケースを抜粋)
- 図 A. 3. 4-1 モデル学習のための解析結果(4)：減速材密度係数の違いによる影響比較 (1/2) (No. 25、26 の 2 ケースを抜粋)
- 図 A. 3. 4-2 モデル学習のための解析結果(4)：減速材密度係数の違いによる影響比較 (1/2) (No. 25、26 の 2 ケースを抜粋)

また、モデル評価のための解析の主要パラメータの結果を下記の通り記載する。

- 図 A. 3. 5-1 モデル評価のための解析結果 (1/2)
(No. 201、202、203 の 3 ケース)
- 図 A. 3. 5-2 モデル評価のための解析結果 (2/2)
(No. 201、202、203 の 3 ケース)

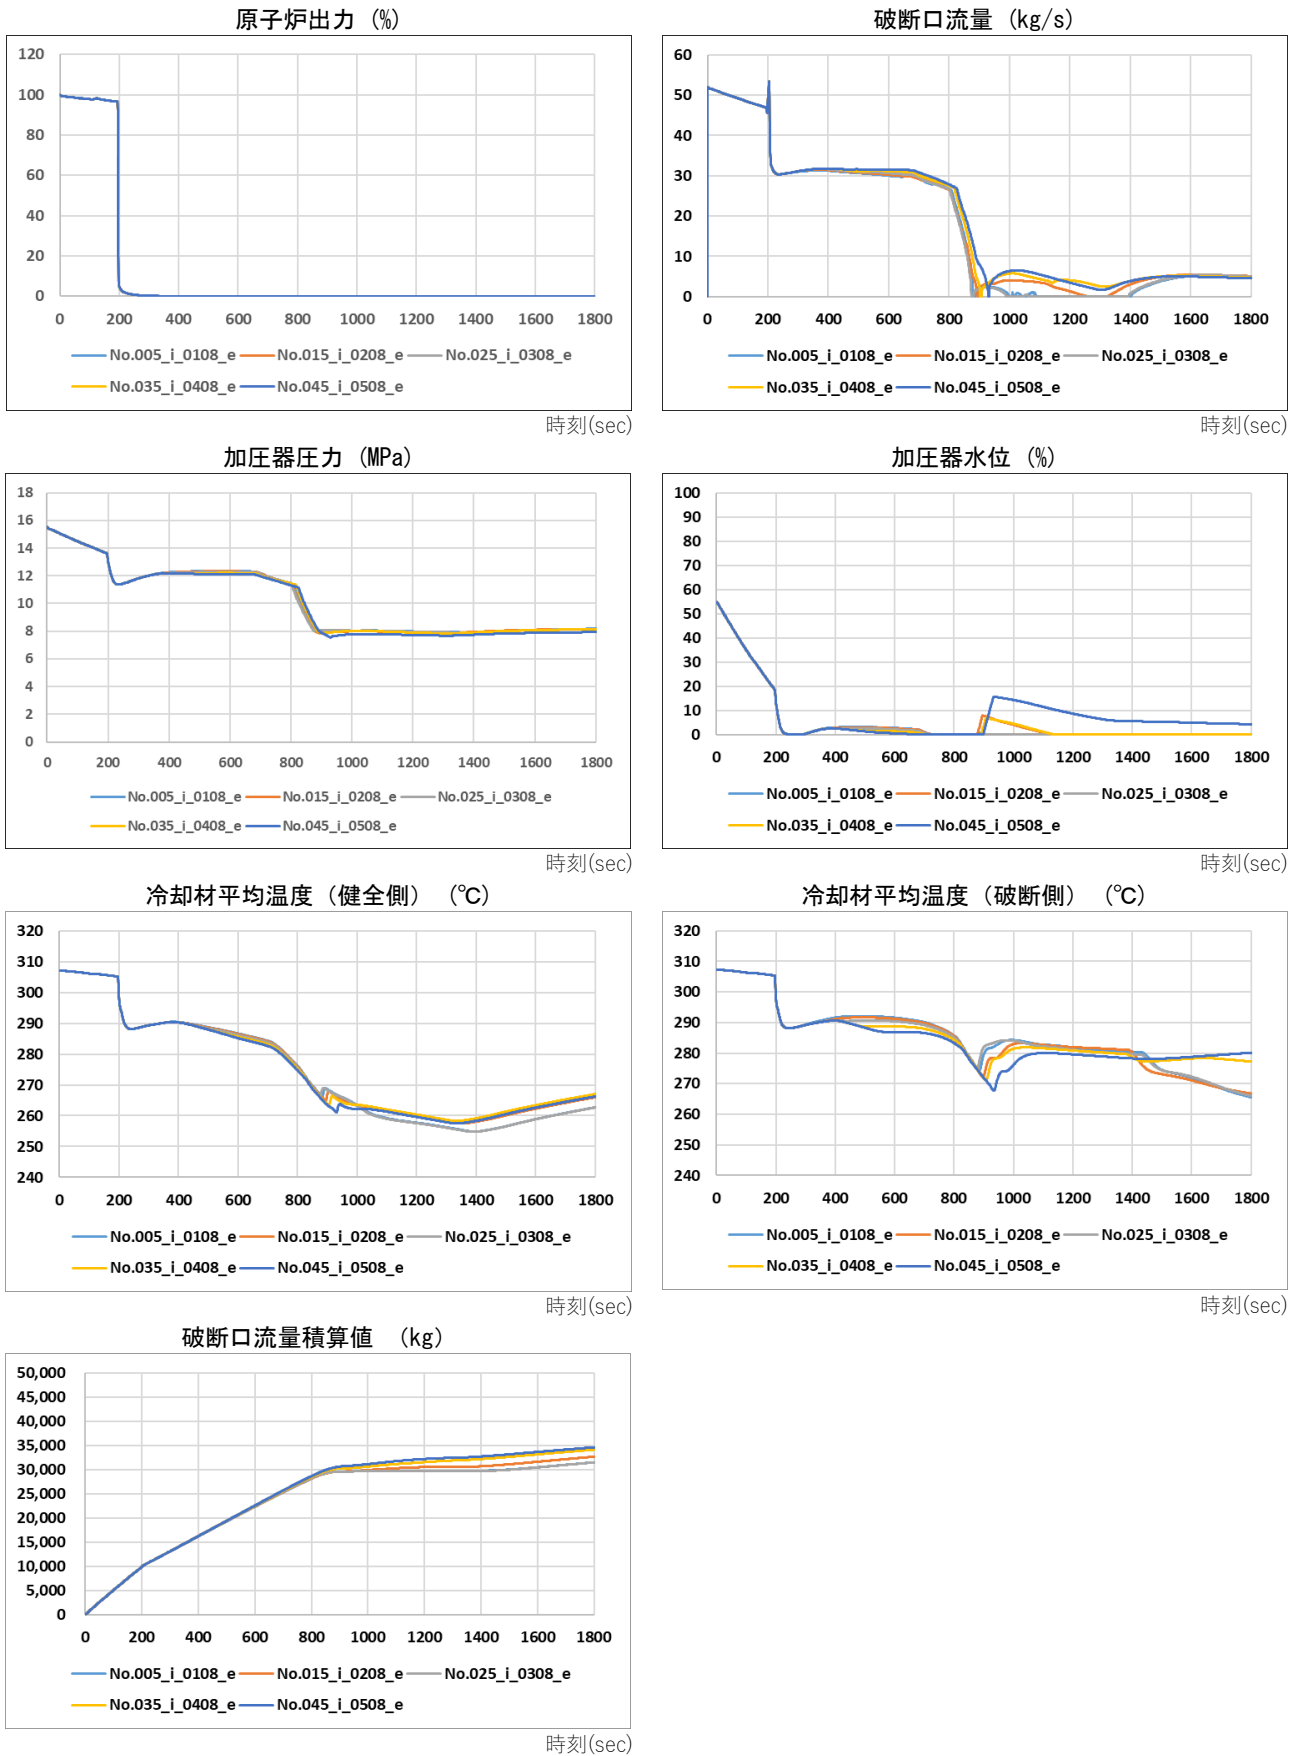


図 A. 3. 1-1 モデル学習のための解析結果(1) :
破断側 SG 隔離操作タイミングの違いによる影響比較 (1/2)

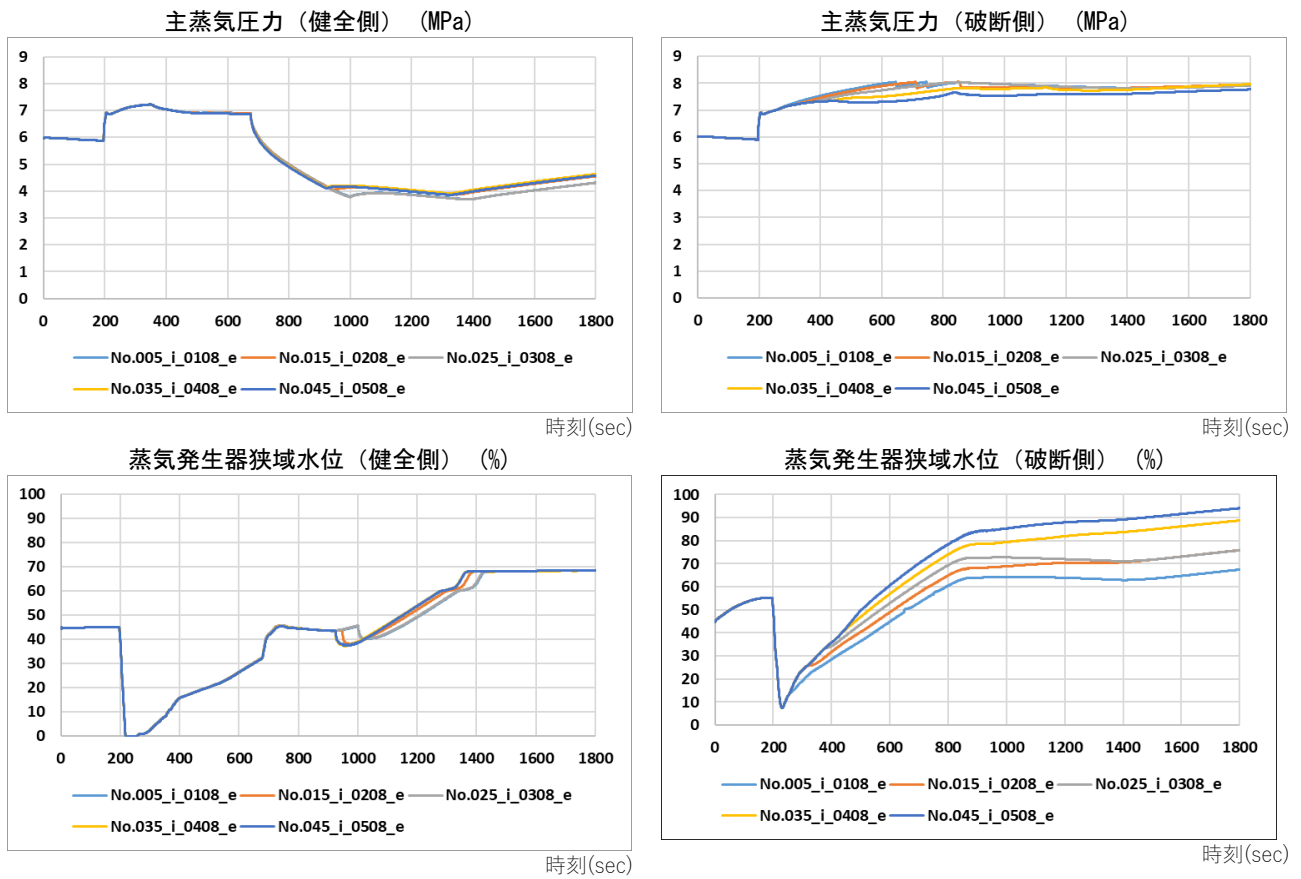


図 A. 3. 1-2 モデル学習のための解析結果 (1) :
破断側 SG 隔離操作タイミングの違いによる影響比較 (2/2)










図 A. 3. 2-1 モデル学習のための解析結果 (2) :
健全側 MSRV 開操作のタイミングの違いによる影響比較 (1/2)







図 A. 3. 2-2 モデル学習のための解析結果 (2) :
健全側 MSR/V 開操作のタイミングの違いによる影響比較 (2/2)



図 A. 3. 3-1 モデル学習のための解析結果(3) : 破断位置の違いによる影響比較 (1/2)







図 A. 3. 3-2 モデル学習のための解析結果(3) : 破断位置の違いによる影響比較 (2/2)



図 A. 3. 4-1 モデル学習のための解析結果 (4) : 減速材密度係数の違いによる影響比較 (1/2)







図 A. 3. 4-2 モデル学習のための解析結果(4) : 減速材密度係数の違いによる影響比較 (2/2)

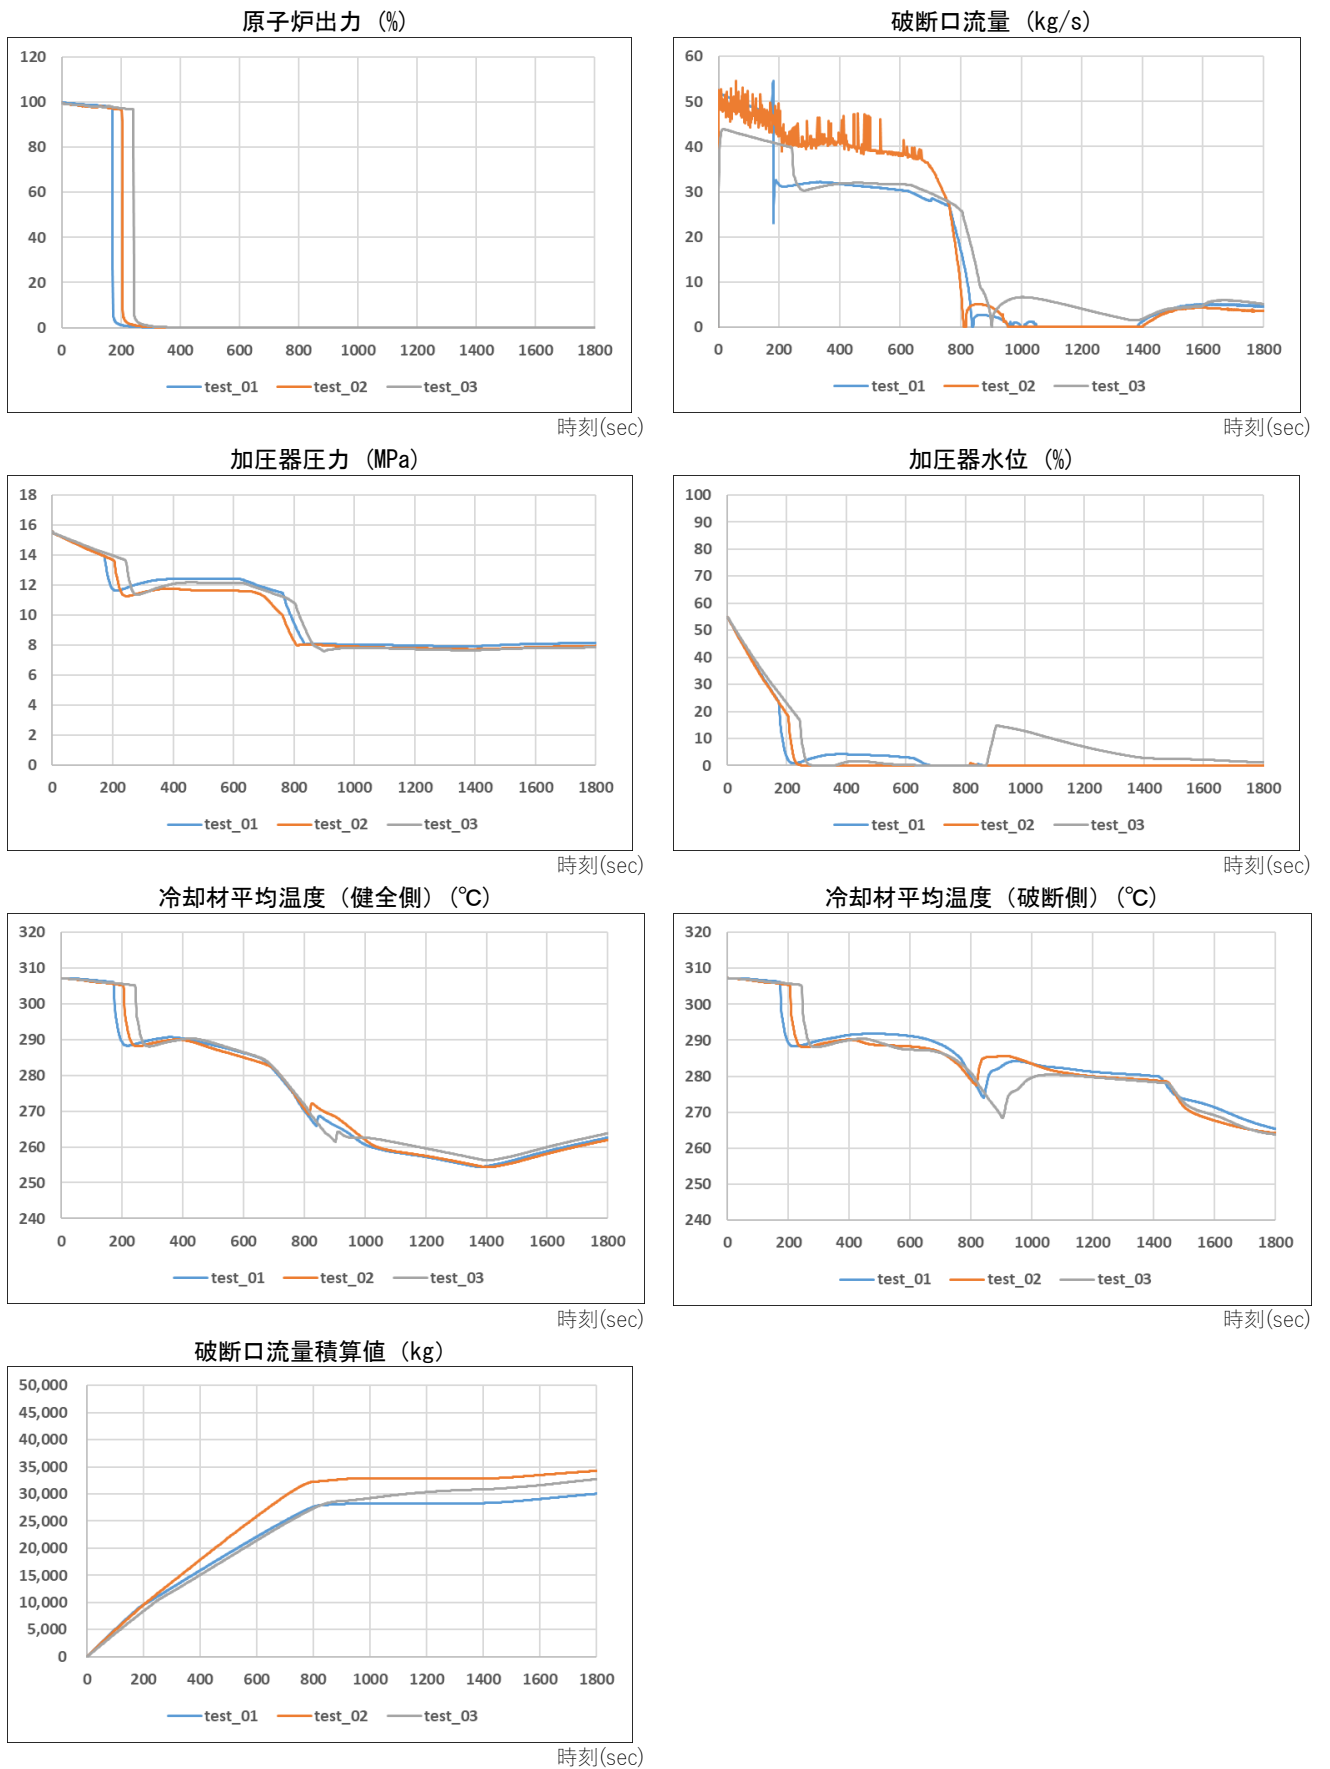


図 A. 3. 5-1 モデル評価のための解析結果 (1/2)







図 A. 3. 5-2 モデル評価のための解析結果（2/2）

(4) 解析結果の考察

解析ケース No. 025 について

SGTR 解析結果 (150 ケース) のうち、代表的なケースとして No. 025 の主要パラメータについて考察を行う。(No. 025 の結果は図 A. 3. 1-1～図 A. 3. 4-2 に記載されている。)

・原子炉出力

SGTR 発生に伴い 1 次冷却材 (減速材) の密度が低下するため、事象開始から原子炉出力は徐々に低下傾向を示す。195 秒で「過大温度 ΔT 高」に達したため原子炉トリップ信号が作動し、制御棒が挿入される。制御棒挿入後、原子炉出力は 0% 付近まで著しく低下する。

・破断口流量

SGTR 発生後は、1 次系と破断側 SG の差圧によって、破断側 SG 細管から 1 次冷却材が流出する。195 秒の原子炉トリップを受けて 1 次系圧力が低下するため破断口流量は 30 kg/s 付近まで低下するが、209 秒に安全注入信号が作動することによって高圧注入が実施されるため、1 次系圧力が維持され、破断口流量も維持される。

675 秒に健全側 SG による 2 次系強制冷却を開始することで、1 次系圧力が低下し、破断口流量は再び低下傾向となる。802 秒に加圧器逃がし弁開操作を実施することで、1 次系圧力は急激に低下し、主蒸気圧力 (破断側) に近付くため、破断口流量はさらに低下する。

・加圧器圧力

SGTR 発生後は、1 次冷却材が流出するため加圧器圧力は徐々に低下していく。195 秒の原子炉トリップを受けて原子炉出力が低下するので、加圧器圧力は急低下する。209 秒に安全注入信号が作動することによって高圧注入が実施されるため、加圧器圧力は回復傾向を示し、その後 12 MPa 付近で安定する。

675 秒に健全側 SG による 2 次系強制冷却を開始することで、加圧器圧力は再び低下傾向となる。802 秒に加圧器逃がし弁開操作を実施することで、加圧器圧力は急激に低下する。876 秒に加圧器圧力が主蒸気圧力 (破断側) 以下となったので、高圧注入を停止し、加圧器逃がし弁を閉止する。その後、加圧器圧力は主蒸気逃がし弁が自動開となる圧力付近でほぼ一定となる。

・加圧器水位

SGTR 発生後は、1 次冷却材が流出するため加圧器水位は徐々に低下していく。安全注入信号が作動するまでは充てん注入が行われるが、破断口流量の方が多いため加圧器水位は目標水位に回復しない。195 秒の原子炉トリップを受けて原子炉出力が低下するので、1 次冷却材の温度が低下し、加圧器水位は 0% 付近まで急低下する。

- ・冷却材平均温度（健全側）

SGTR発生後は、1次冷却材の流出に伴い冷却材平均温度（健全側）は徐々に低下していく。195秒の原子炉トリップを受けて原子炉出力が低下するので、冷却材平均温度（健全側）は急低下する。その後は、崩壊熱とのバランスで一時的に冷却材平均温度（健全側）は上昇するが、その後は低下傾向を示す。

675秒に健全側SGによる2次系強制冷却を開始し、さらに、802秒に加圧器逃がし弁開操作を実施することで冷却材平均温度（健全側）の低下は顕著になる。876秒に高圧注入を停止し、加圧器逃がし弁を閉止して以降も健全側SGによる2次系強制冷却は継続しているため、冷却材平均温度（健全側）は低下傾向を続ける。蒸気発生器水位（健全側）が回復すると、水位を一定に保つために補助給水流量を制限するため、蒸気発生器（健全側）での伝熱量は低下し、冷却材平均温度（健全側）は冷却材平均温度（破断側）に近付いていく。

- ・冷却材平均温度（破断側）

SGTR発生後は、冷却材の流出に伴い冷却材平均温度（破断側）は徐々に低下していく。195秒の原子炉トリップを受けて原子炉出力が低下するので、冷却材平均温度（破断側）は急低下する。その後は、崩壊熱とのバランスで一時的に冷却材平均温度（破断側）は上昇するが、その後は低下傾向を示す。

675秒に健全側SGによる2次系強制冷却を開始し、さらに、802秒に加圧器逃がし弁開操作を実施することで冷却材平均温度（破断側）の低下は顕著になる。876秒に高圧注入を停止し、加圧器逃がし弁を閉止して以降も健全側SGによる2次系強制冷却は継続しているため、冷却材平均温度（破断側）は低下傾向を続ける。蒸気発生器水位（健全側）が60%以上に回復すると、蒸気発生器水位（健全側）を一定に保つために補助給水流量を制限するため、蒸気発生器（健全側）での伝熱量は低下し、冷却材平均温度（破断側）は冷却材平均温度（健全側）に近付いていく。

- ・主蒸気圧力（健全側）

195秒の原子炉トリップを受けて主給水ポンプが停止するので、主蒸気圧力（健全側）は急激に上昇する。主蒸気ダンプ弁を通じて復水器側に蒸気流れるため、主蒸気圧力は7MPa付近で安定する。

675秒に健全側蒸気発生器による2次系強制冷却を開始することで主蒸気圧力（健全側）は急激に低下する。その後、冷却材高温側温度（健全側）が276℃に達すると主蒸気逃がし弁の開度調整を行うため、主蒸気圧力は4MPa付近で安定する。蒸気発生器狭域水位（健全側）が60%以上に回復すると、水位を一定に保つために補助給水流量を制限するため、主蒸気圧力（健全側）は緩やかに上昇する。

- ・主蒸気圧力（破断側）

195秒の原子炉トリップを受けて主給水ポンプが停止するので、主蒸気圧力（破断側）は急激に上昇する。主蒸気ダンプ弁を通じて復水器側に蒸気流れるが、1次系から高

圧の蒸気が流れてくるため、主蒸気圧力（破断側）は上昇を続ける。

675 秒に健全側蒸気発生器による 2 次系強制冷却を開始することで 1 次冷却材圧力が低下し、蒸気発生器（破断側）に流出する蒸気が減少するため、主蒸気圧力（破断側）は主蒸気逃がし弁の設定値以下で安定する。

- ・蒸気発生器狭域水位（健全側）

195 秒の原子炉トリップを受けて主給水ポンプが停止するので、蒸気発生器狭域水位（健全側）は急激に低下する。その後、補助給水系が自動起動するため蒸気発生器狭域水位（健全側）は回復していく。

675 秒に健全側蒸気発生器による 2 次系強制冷却を開始すると、主蒸気逃がし弁（健全側）から放出される蒸気と補助給水流量がバランスし、蒸気発生器狭域水位（健全側）は一定となる。

その後、冷却材高温側温度（健全側）が 276℃に達すると、主蒸気逃がし弁の開度調整を行うため、主蒸気逃がし弁（健全側）から放出される蒸気が減少し蒸気発生器狭域水位（健全側）が上昇する。蒸気発生器狭域水位（健全側）が 60%以上に回復すると、補助給水流量を制限するため、蒸気発生器狭域水位（健全側）は安定する。

- ・蒸気発生器狭域水位（破断側）

SGTR 発生後は、1 次冷却材が破断側 SG に流出するため、蒸気発生器狭域水位（健全側）は徐々に上昇していく。195 秒の原子炉トリップを受けて主給水ポンプが停止するので、蒸気発生器狭域水位（破断側）は急激に低下する。その後、補助給水系が自動起動するため、蒸気発生器狭域水位（破断側）は回復していく。

375 秒に破断側 SG の隔離が行われ、破断側 SG への補助給水が停止するが、1 次系から破断側 SG への漏洩は継続するため、蒸気発生器狭域水位（破断側）は上昇し続ける。その後、1 次冷却材圧力が主蒸気圧力（破断側）付近まで低下すると、1 次冷却材の蒸気発生器（破断側）への流出がほぼなくなるため、蒸気発生器狭域水位は安定する。

破断側 SG 隔離操作のタイミングの違いによる影響比較

図 A. 3. 1-1 および図 A. 3. 1-2 に記載したパラメータ挙動を参照することで、破断側 SG 隔離操作のタイミングの違いによる影響の考察を行う。

No. 005、No. 015、No. 025、No. 035 および No. 045 のケースを比較すると、破断側 SG の隔離のタイミングの違いによって、主蒸気圧力（破断側）と蒸気発生器狭域水位（破断側）の挙動に影響していることが分かる。破断側 SG 隔離は、表 A. 2-1 に記載しているように主蒸気隔離弁閉止、補助給水停止およびブローダウンラインの閉止等を行うため、主蒸気圧力（破断側）が上昇し、蒸気発生器狭域水位（破断側）の上昇が止まる。破断側 SG の隔離が遅い No. 045 では、補助給水が実施されている時間が長いため、破断側 SG の隔離までは冷却材平均温度が他のケースと比較して低い。

No. 005、No. 015、No. 025、No. 035 および No. 045 のケースを比較すると破断口流量へ

の影響はそれほど大きくないことが分かる。

健全側 MSRV 開操作のタイミングの違いによる影響比較

図 A. 3. 2-1 および図 A. 3. 2-2 に記載したパラメータ挙動を参照することで、操作タイミングの違いによる影響の考察を行う。

No. 021、No. 023、No. 025、No. 027 および No. 029 のケースを比較すると、健全側 SG による 2 次系強制冷却開始のタイミングによって、主蒸気圧力や加圧器圧力の低下に影響し、その結果として破断口流量に差異が出る結果となっている。

No. 021、No. 023、No. 025、No. 027 および No. 029 のケースを比較すると、健全側 SG による 2 次系強制冷却開始が早いほど、破断口流量積算値が少ない結果となっている。

破断位置の違いによる影響比較

図 A. 3. 3-1 および図 A. 3. 3-2 に記載したパラメータ挙動を参照することで、破断位置の違いによる影響について考察を行う。

No. 025、No. 075 および No. 125 のケースを比較すると、破断口流量の挙動に差異が有ることが分かる。

No. 075 のような SG 細管上端で破断した場合は、No. 025 と比較して破断口流量の値が上下に振動しており、原子炉トリップ後も比較的高い値で推移しているという特徴が有る。破断口流量に差が生じている原因としては、破断位置の高さによる影響と、破断位置が U チューブの上端であるため、入り口側からも出口側からも冷却材が流れやすい構造であることが考えられる。結果として、No. 075 の破断口流量積算値は No. 025 のケースと比べ多くなっている。

No. 125 のような SG 細管出口側で破断した場合は、No. 025 と比較して破断口流量の値が小さくなっており、その影響で原子炉トリップの時刻も、No. 125 の方がやや遅くなっている。破断口流量に差が生じている原因としては、No. 025 の破断位置に比べ、No. 125 の破断位置では 1 次冷却材のエンタルピーが低下しているためだと考えられる。

減速材密度係数の違いによる影響比較

図 A. 3. 4-1 および図 A. 3. 4-2 に記載したパラメータ挙動を参照することで、減速材密度係数の違いによる影響について考察を行う。

No. 025 および No. 026 のケースを比較すると、SGTR 発生後の原子炉出力の低下傾向に差が有り、その結果として原子炉トリップの時刻に差異が有ることが分かる。

No. 026 では BOC (Beginning of Cycle : サイクル初期) 相当の減速材密度係数を設定しており、SGTR 発生による減速材密度の低下による原子炉出力への影響が比較的小さい。その結果、No. 026 のケースの方が冷却材平均温度は No. 025 のケースに比べやや高い値で推移し、原子炉トリップ信号 (過大温度 ΔT) に早く達する。

上記の考察から、SGTR 解析結果については物理的に矛盾の無い妥当なプラント挙動を示していることが確認できた。なお、解析に用いた RELAP/SCDAPSIM のプラント挙動解析部分は RELAP5 コードであり、その精度は、過去に様々な実験や実炉の検証解析により確認されている。