

## 機械学習を利用した伝熱解析手法の構築

井田, 晴也  
九州大学総合理工学府環境エネルギー工学専攻

<https://hdl.handle.net/2324/4785157>

---

出版情報 : 九州大学, 2021, 修士, 修士  
バージョン :  
権利関係 :

令和3年度

修士論文

機械学習を利用した伝熱解析手法の構築

九州大学大学院総合理工学府  
環境エネルギー工学専攻  
熱エネルギー変換システム学研究室

井田晴也

指導教員 宮崎隆彦

提出年月日 令和4年2月8日

## 目次

第1章 序論.....	1
1.1 はじめに.....	1
1.2 人工知能, 機械学習, 深層学習.....	2
1.2.1 人工知能.....	3
1.2.2 機械学習.....	3
1.2.3 深層学習.....	4
1.3 従来における伝熱解析.....	4
1.3.1 沸騰現象の概要.....	4
1.3.2 熱伝達特性の予測式.....	6
1.4 従来の研究.....	8
1.5 本研究の目的および本論文における構成.....	9
第2章 熱伝達係数測定実験および学習用データセットの準備.....	11
2.1 実験装置.....	11
2.2 測定方法およびデータ収集方法.....	14
2.2.1 温度の測定.....	15
2.2.2 電圧降下量の測定.....	15
2.2.3 測定データの収集方法.....	15
2.2.4 動画の撮影方法.....	15
2.3 白金線抵抗値測定実験.....	15
2.3.1 実験条件.....	16
2.3.2 実験手順.....	16
2.3.3 実験データの整理方法.....	16
2.3.4 結果.....	17
2.4 熱伝達係数測定実験.....	18
2.4.1 実験条件・実験手順.....	18
2.4.2 実験データの整理方法.....	19

2.4.3	熱伝達係数測定の結果.....	20
2.4.4	観測画像および編集.....	23
2.5	機械学習用データセットの作成.....	24
2.6	機械学習の環境構築.....	25
第3章	主成分分析によるデータセットの可視化.....	26
3.1	主成分分析.....	26
3.1.1	主成分分析.....	26
3.1.2	2次元データに対する主成分分析.....	26
3.2	データセットの標準化.....	28
3.3	データセットに対する主成分分析.....	29
3.3.1	主成分ベクトル空間への射影.....	30
3.3.2	第1主成分と第10主成分までの組み合わせによる射影.....	30
3.3.3	固有ベクトルおよび主成分負荷量の可視化.....	32
3.3.4	主成分得点.....	34
3.3.5	寄与率および累積寄与率.....	40
3.3.6	新しいデータセットへの変換.....	41
第4章	.....	43
4.1	線形・非線形回帰による熱伝達係数の予測.....	43
4.1.1	主成分分析による新しいデータセット.....	43
4.1.2	線形回帰分析および非線形回帰分析.....	44
4.1.3	モデルの精度評価指標.....	45
4.1.4	線形回帰分析による熱伝達係数の予測.....	48
4.1.5	非線形(2次)回帰分析による熱伝達係数の予測.....	50
4.1.6	非線形(3次)回帰分析による熱伝達係数の予測.....	53
4.1.7	熱伝達係数の過剰適合モデル.....	56
4.1.8	モデルの次数と予測精度.....	58
4.1.9	平均化による予測誤差の改善.....	58
4.2	畳み込みニューラルネットワーク(CNN)による熱伝達係数の予測.....	63
4.2.1	順伝播型ニューラルネットワーク.....	63
4.2.2	畳み込みニューラルネットワーク.....	66

4.2.3	ニューラルネットワークの最適化アルゴリズム .....	69
4.2.4	熱伝達係数予測モデルの構築 .....	70
4.2.5	畳み込みニューラルネットワークによる熱伝達係数の予測 .....	73
4.2.6	畳み込みフィルタと特徴マップの可視化 .....	76
第5章	.....	86
5.1	物体検出の歴史 .....	86
5.2	YOLO (You Only Look Once) .....	87
5.3	自作データセット .....	87
5.4	評価指標 .....	88
5.4.1	処理速度 .....	88
5.4.2	IoU (Intersection of Union) .....	88
5.4.3	適合率 (Precision) .....	89
5.4.4	再現率 (Recall) .....	89
5.4.5	F 値 .....	90
5.4.6	AP, mAP .....	91
5.5	YOLOv5 による蒸気泡の検出 .....	93
5.5.1	学習 .....	93
5.5.2	蒸気泡の検出 .....	96
5.5.3	推論時間および処理速度 .....	99
第6章	総括 .....	100
謝辞	.....	101
参考文献	.....	102

## 第1章 序論

### 1.1 はじめに

1956年に人工知能という言葉が初めて使用され、推論と探索を中心とした第1次AIブームが始まりを迎えた。1980年代には第2次AIブームを迎え、この時にはエキスパートシステムと呼ばれる専門家のように振る舞う知的システムがブームを牽引した。しかし、この2度のAIブームはどちらも下火になり、その後、低迷も見られた。過去2回のブームが一過性のもので終わった理由の1つにコンピュータの性能がある。当時のコンピュータの性能は、現在に比べると圧倒的に欠如しており、膨大な量の演算を行うには、処理能力も記憶容量も不十分であった。しかし、1990年代にはコンピュータの性能が爆発的に向上し、処理能力や記憶容量だけでなく、情報量も増加した。インターネットが普及したこともこの情報量の増加を大きく助けている。この蓄積された膨大な情報はビッグデータと呼ばれ、第3次AIブームを引き起こした要因にもなった。

第3次AIブームが興った背景には、ビッグデータの普及の他に機械学習やディープラーニングの登場がある。機械学習は膨大なビッグデータの中から機械自らがルールやパターンを発見し、必要な情報を選び学習するアルゴリズムであり、それまでの人工知能とは一線を画したものであった。機械学習における代表的な手法であるディープラーニング(深層学習)はAIブームの火付け役にもなった存在である。2012年に行われた画像認識のコンペティションであるILSVRC 2012において、ディープラーニングを利用したAlexNet<sup>[1]</sup>が高い認識精度で優勝したことで、ディープラーニングはより注目を浴びることとなった。その後、ディープラーニングは次元削減、音声認識、時系列データからの異常検知など多くの場面で実用されている。特に、画像認識などのコンピュータビジョンはディープラーニングの中でも盛んに研究が行われている分野である。既にディープラーニングの活用例は広がりを見せ、機械学習そのものの発展だけでなく、様々な分野への浸透が進んでいる。

既存の学術分野と機械学習の手法を融合される取り組みは、第3次AIブーム以前から成されてはいたが、限定的な分野での話であり、数もさほど多くはなかった。しかし、これらは機械学習の発展とともに解消されつつあり、機械学習を用いた研究は爆発的に数を増やしている。熱工学の分野でも機械学習を活用する動きが活性化してきており、最適化や予測の研究が見られるようになった。その一方で、機械学習、なかでもディープラーニングが持つブラックボックス問題への懸念も大きくなっている。人間が物事を思考する際、

思考プロセスのレベルとしては数次元程度が限界である。それに対し、深層学習は数十から数百次元のレベルで物事を思考できるため、機械が答えを出すまでに至った過程の全てまでは人間は追うことができないとされている。これが深層学習をブラックボックスとさせる所以である。さらに、機械学習は数多くのデータから自律的にデータを取捨選択するため、データに関する専門的な知識なしに高精度の結果を導出することが可能な点もブラックボックス化に拍車をかけている。そのため、機械学習を予測などの目的達成の手段としての道具とするのではなく、既存の学術分野の性質を踏まえたうえで機械学習と融合させることが今後は求められていく。

先述した通り、既に伝熱や熱工学の分野でも機械学習を用いた研究は数多く見られるが、そのほとんどが予測や最適化を目的としており、機械学習の中身に対して、多くは触れられていない。そこで本研究では、沸騰現象の様相とともに熱伝達や熱流束の大きさが変化することに注目し、伝熱分野における機械学習との融合を試みた。また、伝熱解析における機械学習の利用に焦点を当てつつも、機械学習が与えられたデータからどのように伝熱特性を理解しているのかについても考察を行った。

## 1.2 人工知能，機械学習，深層学習

人工知能 (Artificial intelligence), 機械学習 (Machine learning), 深層学習 (Deep learning) はいずれもよく使用される用語であるが、それぞれに関係性があることから混同されがちである。よって、初めにこれらの定義とそれぞれに関係性を簡潔に示す。人工知能, 機械学習, 深層学習の関係を図 1.1 に示す。この中で最も広義に範囲を持つのが人工知能であり、機械学習と深層学習を内包する概念である。機械学習は前節で述べた通り、機械自らが学習するアルゴリズムである。機械学習にはいくつかのカテゴリが存在し、それについては後述する。この機械学習に内包されるのが深層学習である。すなわち、人工知能の一部が機械学習であり、機械学習の一部に深層学習があるということである。

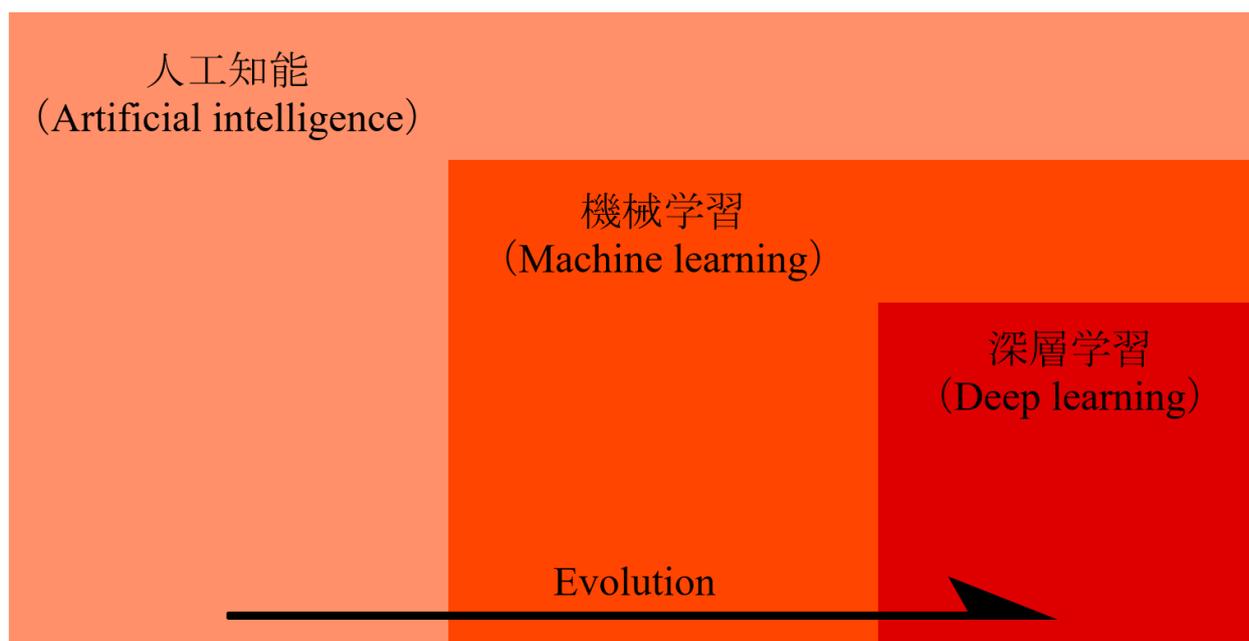


図 1.1 人工知能，機械学習，深層学習の関係

### 1.2.1 人工知能

人工知能という言葉は 1956 年にダートマス大学で開催されたダートマス会議の提案書ではじめて使用されたとされ<sup>[2]</sup>，それ以降，知的な機械，特に知的なコンピュータプログラムを作る科学と技術のことを幅広く指し示す用語として用いられている。

### 1.2.2 機械学習

機械学習には大きく 3 つの学習方法があり，それぞれ，教師あり学習，教師なし学習，強化学習と呼ばれる。それに加え，半教師あり学習も主要なカテゴリの 1 つとなりつつある。

教師あり学習とは名前の通り，学習データに教師となる正解を与える学習方法である。例としては，過去の天候，価格，販促などの要因と売り上げのデータの関係から，今日の売り上げを予測することが挙げられる。

教師なし学習は学習データに正解を与えずに学習させる方法であり，正解を教える教師あり学習とは対をなす手法であると言える。教師なし学習は，入力データからデータの中に隠れたパターンや構造を見つけ出すことを目的とすることが多い。クラスタリングと次元削減は教師なし学習の代表的な例である。

半教師あり学習は文字通り教師あり学習と教師なし学習の間をとったような学習手法で

ある。

強化学習はこれまでに述べた学習手法とは異なり，データを与えることはしない．システム自身が試行錯誤を繰り返すことで精度を高めていく学習手法である．

これらの学習手法はいずれも，変化の要因に対して，結果を正しく予測し成果を最大化することを目的としている．

### 1.2.3 深層学習

機械学習の1つである深層学習は機械学習の手法であるニューラルネットワークという分析手法を拡張したものであり，教師あり学習，教師なし学習，強化学習のすべてに適用できるアルゴリズムである．ニューラルネットワークは人間の神経細胞を模した構造となっており，その基礎となる研究は第1次 AI ブームから行われていた．その人工ニューロンと呼ばれるパーセプトロンは，単層では複雑な問題を解くことはできないことに加え，層を重ねるほど計算量は膨大になり，当時の計算機では処理能力が不足していた．しかし，計算機自体の向上やオートエンコーダー<sup>[3]</sup>などが登場したことで，深い層での学習，つまり深層学習が可能になった．その活用例は多岐にわたり，分野によっては人間の認識精度を上回るものも既に実現されている．

## 1.3 従来における伝熱解析

### 1.3.1 沸騰現象の概要

液体中の物体を加熱したときの伝熱現象は，いくつかの領域に分けられ，対流熱伝達や沸騰熱伝達と呼ばれる．物体を液体温度付近から上げていき，物体と周囲流体の温度差がある一定以上になると物体の周りに液体の運動が生じる．この運動は物体周りの流体の密度差によるもので，対流によって熱が移動するため自由対流熱伝達あるいは自然対流熱伝達と呼ばれる．加熱物体の温度をさらに上げていくと，物体表面から蒸気泡が発生し始め，物体から液体への熱移動が極めて良好となる．このような熱移動に伴い，液体内に液相から気相への相変化が生じる現象を沸騰と呼ぶ．1934年に拔山が発表した沸騰曲線は沸騰現象解明のための先駆的な研究<sup>[4]</sup>としてよく知られ，ここでも沸騰曲線を用いてその概要について説明する<sup>[5]</sup>．

図 1.2 に定性的なプール沸騰の沸騰曲線の形状を示す．静止液体中に加熱面が存在して

いる場合の沸騰をプール沸騰と呼び、液体は自然対流および気泡の成長と離脱によってのみ運動する。図 1.2 に示すように沸騰現象は、多くの場合、両対数グラフ上の縦軸に熱流束  $q$  (heat flux), 横軸に過熱度  $\Delta T_s$  (super-heat) をとって表される。過熱度  $\Delta T_s$  は加熱面温度  $T_w$  とバルク液温度  $T_b$  の差から計算され、バルク液が飽和温度以下の場合の沸騰はサブクール沸騰と呼ばれる。

図 1.2 の AB 部分は非沸騰の液体単相自然対流であり、伝熱面過熱度が飽和温度よりも高いある温度の点 B に達すると、伝熱面上で気泡が発生し始める。この点を沸騰開始点という。

BD の部分は核沸騰と呼ばれる沸騰様式の領域であり、伝熱面上から気泡が発生する。液体温度が飽和温度近くであれば発生した気泡は伝熱面上で成長した後、伝熱面から離脱する。液体温度が飽和温度よりも十分低い場合には、発生した気泡はある大きさまで成長した後、その場で崩壊してしまう。核沸騰では、このような気泡により熱伝達が著しく促進される。伝熱面過熱度の増加とともに発泡点の数は急速に多くなるので、伝熱面過熱度がわずかに増加すると、熱伝達率が劇的に大きくなり、熱流束が大幅に増大するのが、核沸騰熱伝達の特徴である。

このように良好な伝熱特性を持つ核沸騰は、極大熱流束点と呼ばれる D 点で終了する。極大熱流束点はバーンアウト点あるいは限界熱流束点ともいう。点 D を超えて伝熱面過熱度を大きくすると、熱伝達率は小さくなり、熱流束が低下する遷移沸騰と呼ばれる沸騰様式になる。さらに、極小熱流束点またはライデンフロスト点と呼ばれる点 E 以上の伝熱面過熱度では、伝熱面は連続的な蒸気膜で覆われ、液体が伝熱面と直接接触することはなく、気泡は蒸気膜と液体の界面から発生し離脱する膜沸騰と呼ばれる沸騰様式となる。

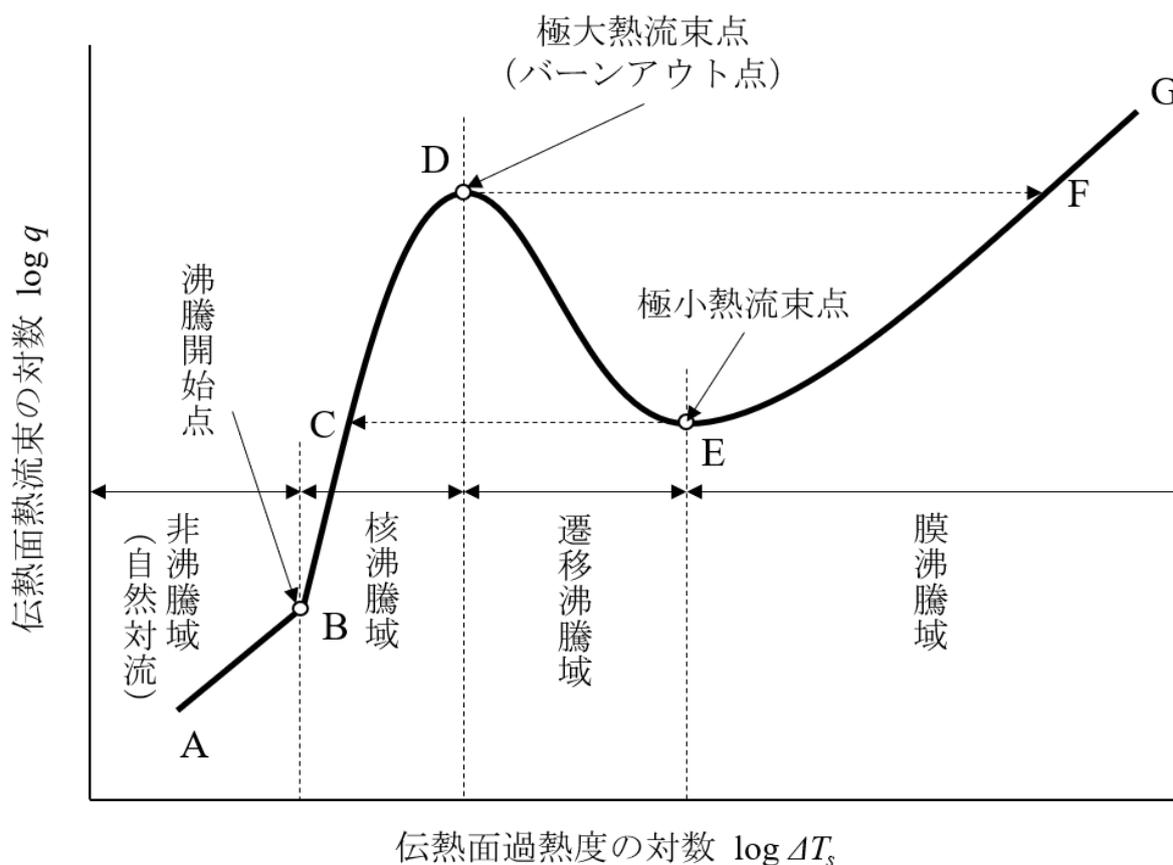


図 1.2 沸騰曲線

### 1.3.2 熱伝達特性の予測式

自由対流および沸騰に関しては、これまで非常に多くの研究がなされており、その熱伝達特性の予測のための熱伝達相関式も数多く提案されている。ここでは代表的なものとして、次の2つの式を示しておく。

#### (1) 水平円柱からの自由対流熱伝達<sup>[6]</sup>

藤井らは、一様伝熱面温度  $T_w$  の、直径  $d$  の加熱水平円柱から温度  $T_b$  への層流自由対流熱伝達に関する理論的および実験的研究を行い、熱伝達特性を予測するための以下のような相関式を提案している。

A.  $10^{-8} \leq Gr_d \cdot Pr \leq 5 \times 10^6$  の場合

$$\frac{2}{Nu_d} = \ln \left\{ 1 + \frac{2.475}{C_1(Gr_d \cdot Pr)^n} \right\} \quad (1.1)$$

B.  $5 \times 10^6 \leq Gr_d \cdot Pr \leq 10^9$  の場合

$$Nu_d = 1.031 \cdot C_1(Gr_d \cdot Pr)^{\frac{1}{4}} \quad (1.2)$$

ここで、式 1.1 および 1.2 中の無次元数、係数および指数は以下のように定義される。

$$\text{ヌセルト数} \quad : \quad Nu_d = \frac{hd}{\lambda_L} \quad (1.3)$$

$$\text{グラスホフ数} \quad : \quad Gr_d = \frac{g\beta(T_w - T_b)d^3}{\nu_L^2} \quad (1.4)$$

$$\text{プラントル数} \quad : \quad Pr = \frac{c_{pL}\mu_L}{\lambda_L} \quad (1.5)$$

$$\text{係 数} \quad : \quad C_1 = \frac{3}{4} \left( \frac{Pr}{2.4 + 4.9\sqrt{Pr} + 5Pr} \right)^{\frac{1}{4}} \quad (1.6)$$

$$\text{指 数} \quad : \quad n = \frac{1}{4} + \frac{1}{10 + 5(Gr_d \cdot Pr)^{0.175}} \quad (1.7)$$

以上の無次元数において、 $h$  は熱伝達係数[W/(m<sup>2</sup>·K)]、 $\lambda_L$ は流体の熱伝達率[W/(m·K)]、 $g$  は重力の加速度[m/s<sup>2</sup>]、 $\beta$ は流体の平均体膨張係数[1/K]、 $\nu_L$ は流体の動粘度[m<sup>2</sup>/s]、 $c_{pL}$ は流体の定圧比熱[J/(kg·K)]、 $\mu_L$ は流体の粘度[Pa·s]である。また、これらの流体の物性値としては代表流体温度（膜温度）

$$T_m = \frac{1}{2}(T_w + T_b) \quad (1.8)$$

での値を用いる。なお、流体の密度[kg/m<sup>3</sup>]を $\rho_L$ とすれば、平均体膨張係数 $\beta$ は式 ( ) で定義される。

$$\beta = \frac{\rho_{Lb} - \rho_{Lm}}{\rho_{Lm}(T_m - T_b)} \quad (1.9)$$

## (2) 水平円柱からの沸騰熱伝達<sup>[7]</sup>

Stephan, K と M. Abdelsalam は、水平円柱、平板等の伝熱面からの様々な液体の核沸騰熱伝達に関する実験データをまとめ、それらの熱伝達特性を予測するための相関式を提案している。その中でも水に対しては次の式を提案している。

$$Nu_d = 0.246 \times 10^7 \left( \frac{qD}{\lambda_L T_{sat}} \right)^{0.673} \left( \frac{c_{pL} T_{sat} D^2}{a_L^2} \right)^{1.36} \left( \frac{h_{fg} D^2}{a_L^2} \right)^{-1.58} \left( \frac{\rho_L - \rho_V}{\rho_L} \right)^{5.22} \quad (1.10)$$

ここに、 $Nu_d$ 、 $q$ 、 $\lambda_L$ 、 $c_{pL}$ および $\rho_L$ は、それぞれ先に示したヌセルト数、熱流束、水の熱伝導率、水の定圧比熱および水の密度である。また、 $D$ は離脱気泡径[m]、 $T_{sat}$ は水の飽和温度[K]、 $a_L$ は水の温度伝導率[m<sup>2</sup>/s]、 $h_{fg}$ は蒸発潜熱[J/kg]、 $\rho_V$ は水蒸気の密度[kg/m<sup>3</sup>]である。さらに離脱気泡径 $D$ は次式で定義される。

$$D = 0.66 \sqrt{\frac{2\sigma}{g(\rho_L - \rho_V)}} \quad (1.11)$$

ここで、 $\sigma$ は水の表面張力[N/m]を表す。

彼らは、水に対して以下のような簡易相関式も提案している。

$$h = C_2 q^{0.673} \quad (1.12)$$

ここに、 $C_2$ は水の圧力によって定まる係数であり、大気圧下では $C_2 = 3.8$ である。

## 1.4 従来の研究

伝熱学ならびに熱工学における機械学習を用いた研究を概説する。

Gustavo M. Hobold および Alexandre K. da Silva<sup>[8][9]</sup>は主成分分析を機械学習の手法であるサポートベクターマシンや人工ニューラルネットワークと組み合わせることで、観測画像

から沸騰領域を分類できることを示した。さらに、畳み込みニューラルネットワークを用いて熱流束を推定し、それが多層パーセプトロンニューラルネットワークよりも、外挿の予測において小さい誤差で予測が行えることを確認した。さらに、それらの推定に要した計算時間を計算機ごとにまとめた。

榎木ら<sup>[10]</sup>は円形微細流路を対象とした様々な冷媒の物性値と沸騰熱伝達係数のデータベースに深層学習を適用し、沸騰熱伝達係数の予測を行った。深層学習による整理式は、既存の整理式と比較しても、ほとんどの冷媒に対して高い精度で予測できていることを示している。

Tim ら<sup>[11]</sup>は物体検出のアルゴリズムである Faster R-CNN と畳み込みニューラルネットワークを用いて、蒸気泡とその形状を検出するモジュールを開発した。彼らの研究は Yucheng Fu ら<sup>[12]</sup>の研究から派生したものである。蒸気泡を検出する研究は、物体検出のアルゴリズムの発展とともに近年活発化してきており、Rafael F.L Cerqueira ら<sup>[13]</sup>は畳み込みニューラルネットワークをベースとした蒸気泡検出モデルを実装している。

## 1.5 本研究の目的および本論文における構成

伝熱分野のみならず、多くの学術分野において、人工知能もとい機械学習を用いた研究はより一層活気を帯びている。先に示したように、伝熱や熱工学の分野においても既に機械学習による最適化や予測のための研究がなされている。しかしながら、伝熱分野における機械学習のブラックボックスの解明、つまり、機械学習がどのように熱伝達特性を理解しているかについての研究は十分に行われているとは言えず、機械学習の中身を配慮せずに用いることに対して危惧する声は多く見られる。

本研究の目的は、伝熱解析における機械学習の利用について、その基礎的な知見を明らかにするとともに、既存の手法の更なる効率化や機械学習による新たな解析手法の提案の可能性を探求することである。そのために本研究では、ビデオカメラによる沸騰現象の観測画像に対して、機械学習の手法を適用し、既存の伝熱解析における知見との比較することで、機械学習の伝熱に対する理解についての考察を行った。

本論文は以下のように構成される。

第1章では、これまでの人工知能の発展と他の学術分野との関わり、ならびに人工知能の定義と沸騰の特性、そして、伝熱分野における機械学習を利用した従来の研究について概説するとともに、本研究の意義および目的を示した。

第2章では、本研究で用いた実験装置、測定方法、計測機器、実験方法および条件、ならびに実験データの整理方法について記述した。そして、実験データから第三章以降で用いる学習用のデータセットを作成するとともに、学習および予測に使用する計算機の構成を示した。

第3章では、統計学上のデータ解析手法である主成分分析を学習用の観測画像に対して適用し、その結果について従来の伝熱解析における観点から熱伝達の特性を捉えられているか検証した。

第4章では、第3章で行った主成分分析の結果をもとに回帰分析から熱伝達係数を推定するとともに、畳み込みニューラルネットワークにより観測画像からダイレクトに熱伝達係数を推定し、沸騰の観測画像が持つ熱伝達特性の把握を行った。

第5章では、物体検出のアルゴリズムによって蒸気泡の検出を行うとともに、処理時間や精度を把握し、伝熱解析における新たな解析手法としての可能性についても検討した。

第6章では、本論文の総括を行った。

## 第2章 熱伝達係数測定実験および学習用データセットの準備

本研究では，沸騰熱伝達係数を測定および観測画像を撮影するため，水中水平加熱円柱まわりの熱伝達係数測定実験装置を作成した．本章では，まず，実験装置および実験方法について述べる．次に，沸騰熱伝達係数測定実験から，機械学習に用いる学習用のデータセットを作成し，それを示す．

### 2.1 実験装置

図 2.1 に実験装置の概略，図 2.2 に実験装置の外装を示す．本実験では水中水平加熱円柱周りの自然対流熱伝達係数の測定およびその様子をビデオカメラで撮影する．水を充填させた恒温槽内にビーカを配置し，供試白金線をビーカ内に沈める．供試白金線は直径 0.5mm，水平部長さ 101mm であり，電気入力により加熱することで温度を制御される．図 2.3 および図 2.4 に実験装置配線と電気回路図を示す．白金線は両端が銅製の電極と接着されており，直流電源と 10m $\Omega$  の標準抵抗に直列でつながれている．測定機器類は，白金線の上部にバルク温度測定用の熱電対が設けられている．また，白金線の繋がれた電極，標準抵抗では電圧降下量を測定する．恒温槽には観察用のガラス窓が正面と背面に設置されている．撮影用のビデオカメラは正面のガラス窓側から白金線周りの熱伝達を撮影する．背面のガラス窓の後方には撮影用の照明を配置しており，背面のガラス窓にはディフューザーを貼付している．

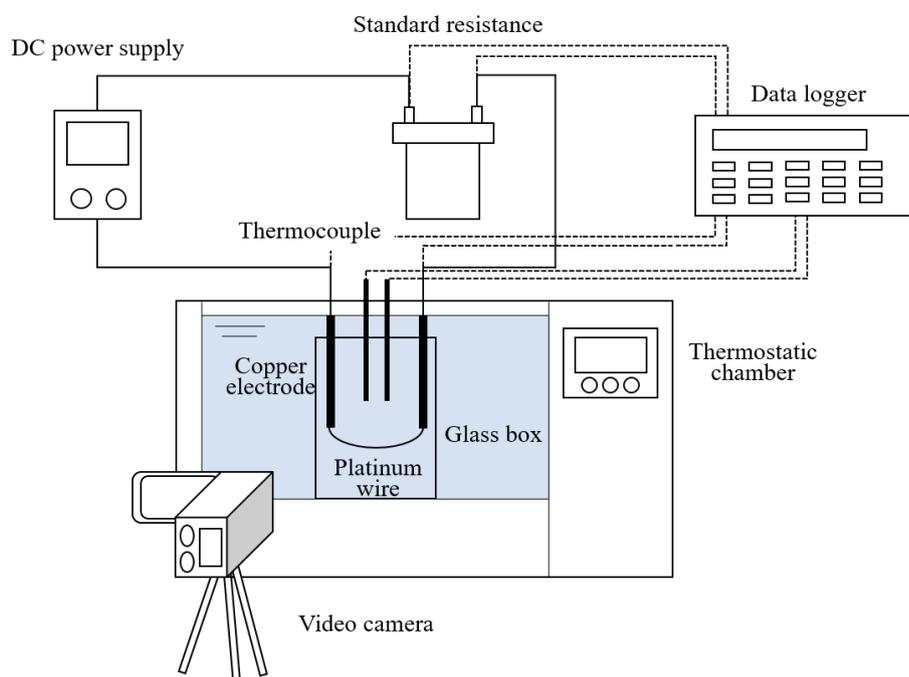
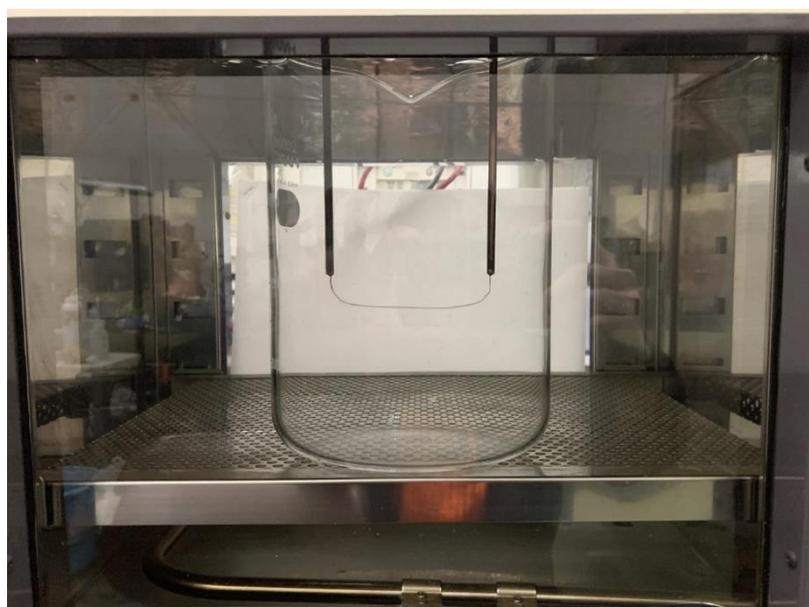


図 2.1 実験装置概略図



(a) 実験装置全体



(b) 恒温槽内

図 2.2 実験装置

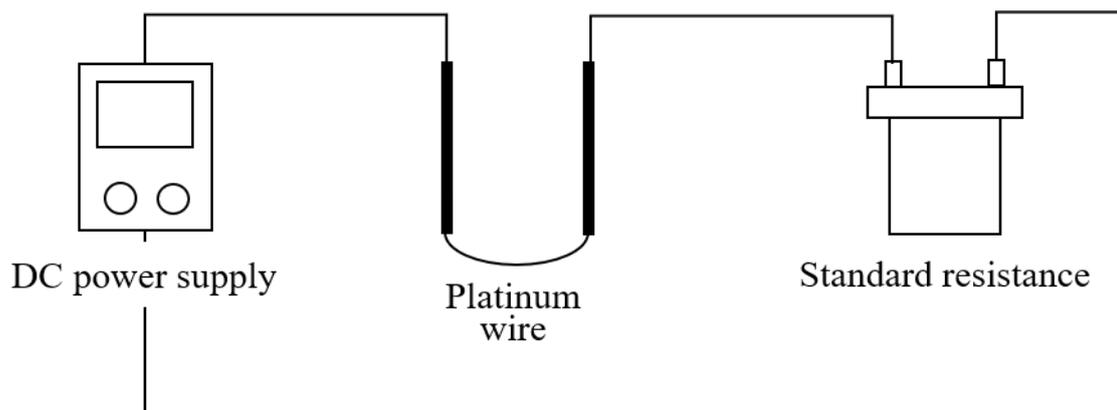


図 2.3 実験装置配線

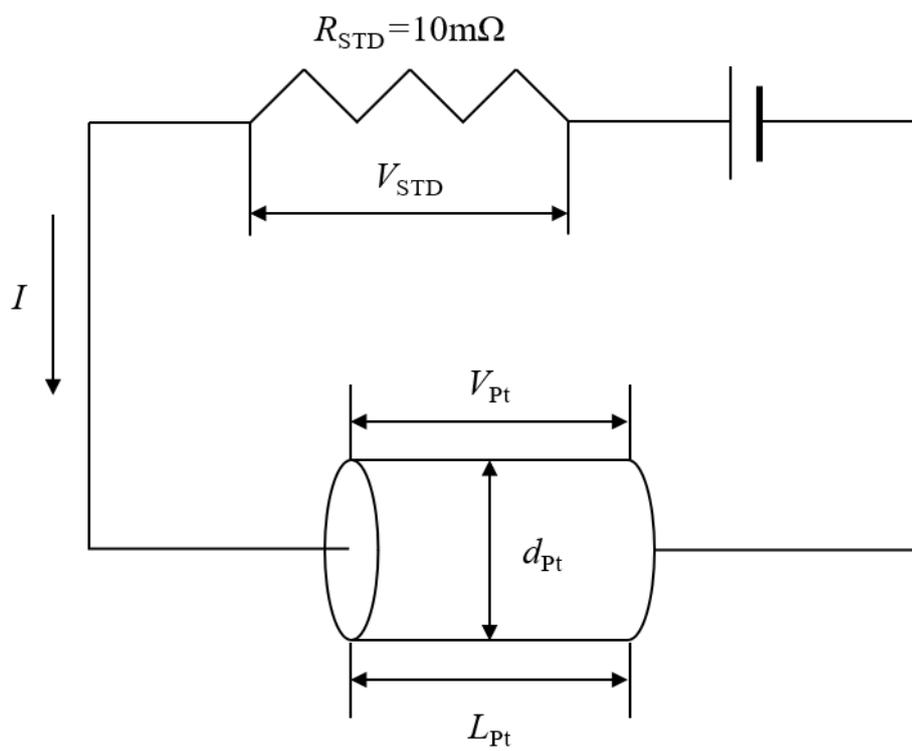


図 2.4 電気回路図

## 2.2 測定方法およびデータ収集方法

### 2.2.1 温度の測定

表 2.1 に熱電対の種類，精度，測定箇所を示す．バルク流体の温度は白金線の上部に設置されたシース径 1mm の K 型熱電対により測定される．熱電対は ITS-90 に準ずる中温白金測温抵抗体を標準温度計として検定が行われており，測定誤差は $\pm 0.05\text{K}$  である．熱電対は白金線の手前側と奥側に 1 本ずつ設けられており，その算術平均を周囲流体温度とする．

表 2.1 温度の測定

センサーの種類	精度	測定箇所
シース K 型熱電対 (1.0mm OD)	$\pm 0.05\text{K}$	バルク温水 (白金線上部)

### 2.2.2 電圧降下量の測定

白金線，標準抵抗の電圧降下量を測定する．回路に流れる電流値は標準抵抗の抵抗値と電圧降下量からオームの法則により算出する．白金線の抵抗値は電流値から計算され，白金線の温度は後述の白金線抵抗値測定の抵抗と温度の整理式から算出する．

### 2.2.3 測定データの収集方法

各センサーから送られた電圧出力値の測定データは，データアキュイジションユニット (MX100, YOKOGAWA) により収集され，イーサネットケーブルを介してコンピュータに取り込まれる．全てのチャンネルは 1 秒間隔で電圧の出力値を計測され，電圧降下量は生データのまま，温度の場合は整理式を入力した MXLOGGER により計算された後，記録される．

### 2.2.4 動画の撮影方法

機械学習の画像データとして白金線周りで生じる伝熱現象をビデオカメラ (HC-VX1M, Panasonic) で撮影する．沸騰現象は非常に高速であるため，シャッタースピードを 1/1000 秒に設定した．ビデオカメラにより撮影された動画は 1 秒間隔で画像に切り出される．

## 2.3 白金線抵抗値測定実験

白金線の抵抗値は白金線の温度に依存する．そのため，白金線の抵抗値を測定し，整理

式を作成することで温度を算出することが可能である。抵抗値検定として、白金線の温度を変化させ、抵抗値を測定することで抵抗値と温度の関係を式に整理した。

### 2.3.1 実験条件

表 2.2 に白金線抵抗値測定の実験条件を記す。恒温槽を用いて白金線の温度を制御し、白金線の温度が変化しないほどの微小の電流を通電させることで、白金線の温度ごとの抵抗値を測定する。

表 2.2 実験条件

白金線温度[°C]	0, 30, 50, 80
電流値[A]	0.05
標準抵抗の抵抗値[Ω]	0.01

### 2.3.2 実験手順

測定手順を以下に示す。

1. 恒温槽の温度を 30°C に設定し、恒温槽内に白金線を沈める。白金線温度条件が 0°C の場合は恒温槽を使用せず氷水に白金線を沈める。
2. 直流電源から白金線に微量の電力を投入し、定常状態を確認後、標準抵抗および白金線の電圧降下量を計測する。
3. 恒温槽の設定を 50°C, 80°C に変更し、手順 1 と 2 を繰り返す。

### 2.3.3 実験データの整理方法

白金線の温度ごとの抵抗値から整理式にフィッティングを行う。白金線の電気抵抗は温度上昇に比例して増大する。抵抗値の温度による変化量は温度係数を  $k_1$ ,  $k_2$  を用いて式 2.1 で表される。

$$R_t = R_0(1 + k_1 t + k_2 t^2) \quad (2.1)$$

ここで  $t$  は温度,  $R_t$  は温度  $t$  における電気抵抗,  $R_0$  は 0°C における電気抵抗である。それぞれ

れの温度における標準抵抗と白金線の電圧降下量から白金線の抵抗値を算出し、最小二乗法により温度係数を決定する。

白金線の抵抗値は以下の手順により算出される。

回路内を流れる電流は標準抵抗の抵抗値と電圧降下量から算出される。

$$I = I_{\text{STD}} = \frac{V_{\text{STD}}}{R_{\text{STD}}} = \frac{V_{\text{STD}}}{0.01} \quad (2.2)$$

ここで  $I$  は回路内に流れる電流であり、 $I_{\text{STD}}$  は標準抵抗に流れる電流である。直列回路であるため、 $I$  と  $I_{\text{STD}}$  は同値である。 $V_{\text{STD}}$  は標準抵抗の電圧降下量であり、 $R_{\text{STD}}$  は標準抵抗の抵抗値で  $10\text{m}\Omega$  である。

白金線の抵抗値は回路に流れる電流  $I$  と白金線の電圧降下量から求められる。

$$R_{\text{Pt}} = \frac{V_{\text{Pt}}}{I} \quad (2.3)$$

ここで  $R_{\text{Pt}}$  は白金線の抵抗値であり、 $V_{\text{Pt}}$  は白金線の電圧降下量である。

#### 2.3.4 結果

図 2.5 に白金線抵抗値測定の結果を示す。横軸は白金線の温度、縦軸は抵抗値を表す。また、式 2.1 に従ってフィッティングし、算出した温度係数を表 2.3 に示す。

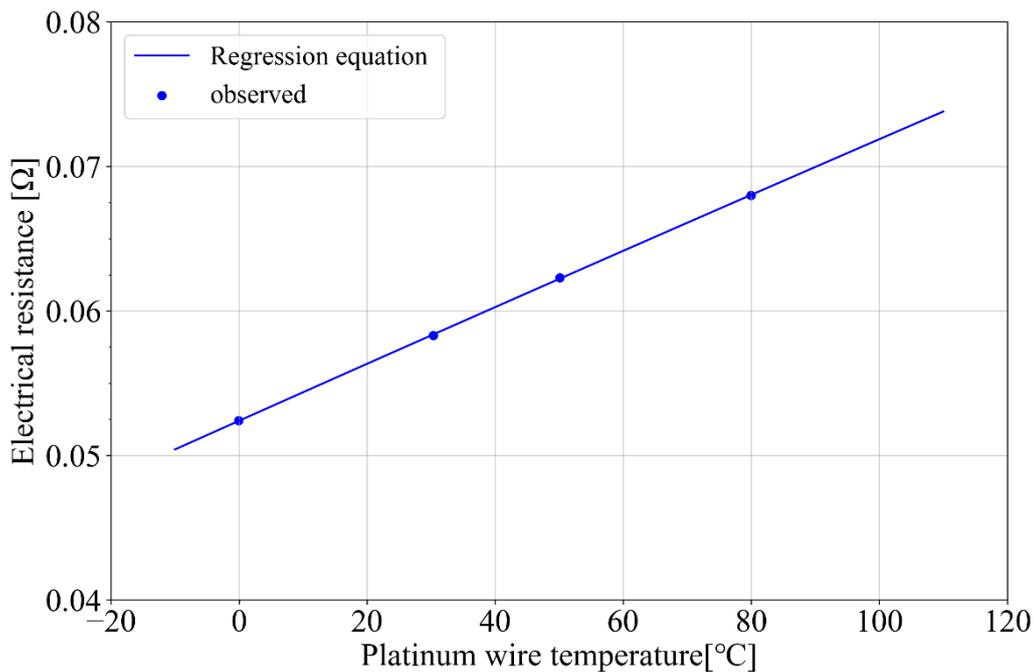


図 2.5 白金線抵抗値

表 2.3 0°Cにおける抵抗値と温度係数

$R_0$	0.052
$k_1$	$3.789 \times 10^{-3}$
$k_2$	$-5.96 \times 10^{-7}$

## 2.4 熱伝達係数測定実験

本実験では直流電源の電流値を変化させ、自然対流熱伝達域と沸騰熱伝達域における熱流束および熱伝達係数を測定する。

### 2.4.1 実験条件・実験手順

表 2.4 に熱伝達係数測定実験の実験条件を示す。

表 2.4 実験条件

周囲流体温度[°C]	90
電流値[A]	12, 13, 14, 16, 18, 20, 22, 24, 26, 28, 30, 32, 34, 36, 38
計測時間[s]	180

測定手順を以下に示す.

1. 恒温槽を 90°C に設定し, 白金線上部に設置した熱電対から周囲流体の温度を測定する. それらの算術平均値を周囲流体の温度とする.
2. 直流電源から白金線に電力を投入し, 加熱する.
3. 電圧降下量が定常になっていることを確認した後, 白金線の電圧降下量および標準抵抗の電圧降下量を測定する. 同時にビデオカメラで白金線回りを撮影する.
4. 投入電力を増加させ, 1~3 の手順を繰り返す.

#### 2.4.2 実験データの整理方法

式 2.4 に示すように周囲流体の温度を 2 カ所の熱電対の平均値から算出する.  $t_{b1}$  は白金線上部手前側の熱電対から計測される温度であり,  $t_{b2}$  は白金線上部奥側の熱電対から計測される温度である.

$$t_b = \frac{t_{b1} + t_{b2}}{2} \quad (2.4)$$

回路に流れる電流値や白金線の抵抗値は白金線抵抗値測定実験と同様の手順で求めることができる. 白金線の温度はここで求める白金線の抵抗値を使って整理式から算出する.

$$t_{Pt} = \frac{-k_1 + \sqrt{k_1^2 - 4k_2 \left(1 - \frac{R_{Pt}}{R_{Pt0}}\right)}}{2k_2} \quad (2.5)$$

ここで  $t_{Pt}$  は白金線の温度である.  $k_1$  および  $k_2$  は前節で求めた温度係数であり,  $R_{Pt}$  は温度

$t_{Pt}$ における白金線の抵抗値， $R_{Pt0}$ は $0^{\circ}\text{C}$ における白金線の抵抗値である．

白金線表面からの熱流束は次のようにして求めることができる．

白金線の単位時間当たりの熱流量は白金線の電力と同じとして扱うことができ，熱流束はこれを白金線の表面積で割ったものである．すなわち，熱流束は式 2.6 で表される． $q$

(heat flux) は白金線表面の熱流束を表す． $A_{Pt}$ は白金線の表面積を表し， $d_{Pt}$ は白金線の直径， $L_{Pt}$ は白金線の長さである．

$$q = \frac{IV_{Pt}}{A_{Pt}} = \frac{IV_{Pt}}{\pi d_{Pt}L_{Pt}} \quad (2.6)$$

また，式 2.7 で定義される  $h$  を熱伝達係数や熱伝達率 (heat transfer coefficient) といい， $[\text{W}/(\text{m}^2 \cdot \text{K})]$ を単位に持つ．式 2.7 中の過熱度  $\Delta T_s$  は伝熱面と周囲流体との温度差であり，単位は $[\text{K}]$ である．ここでは，白金線の温度と周囲流体である水との温度差を指す．

$$h = \frac{q}{\Delta T_s} = \frac{q}{t_{Pt} - t_b} \quad (2.7)$$

### 2.4.3 熱伝達係数測定の結果

図 2.6 に熱伝達係数測定実験の結果を示す．横軸は熱流束を，縦軸は熱伝達係数を示す．青色のドットは測定した実測値であり，それぞれの実験条件の平均値をプロットしている．緑色のドットは藤井らによって提案された自由対流の熱伝達相関式<sup>[6]</sup>を示す．赤色のドットは Stephan-Abdelsalam の簡易熱伝達相関式<sup>[7]</sup>であり，藤井らによるものが自由対流に関するものだったのに対し，こちらは核沸騰熱伝達に関するものである．相関式の計算に必要な物性値は NIST の物性値計算プログラム REFPROP Ver.10.0<sup>[14]</sup>を用いた．

まず，自由対流熱伝達における実測値と相関式の比較を行う．同じ熱流束における比較はできないが，熱流束に対する熱伝達係数の傾きや熱伝達係数は 2 つの間に深刻な違いは見受けられない．

次に，核沸騰熱伝達における比較を行う．同じ熱流束における実測値と相関式の値との間に大きな差がある．これは本実験の周囲流体温度が  $90^{\circ}\text{C}$  となっており，厳密には飽和状態でないことが一因であることが考えられる．また，熱伝達係数は実験装置に依存するこ

とが多い。しかし、熱流束に対する熱伝達係数の傾きは実測値と相関式で酷似しており、沸騰熱伝達の特徴をよく表していると言える。

表 2.5 と表 2.6 に実験条件ごとの熱流束と熱伝達係数の誤差範囲を示す。それぞれの条件ごとの平均値、最小値、最大値、標準偏差をまとめる。最小値、最大値には括弧内に平均値との差を記している。これを見ると、どの条件においても大きな測定誤差はなく、定常状態での測定であったことが分かる。

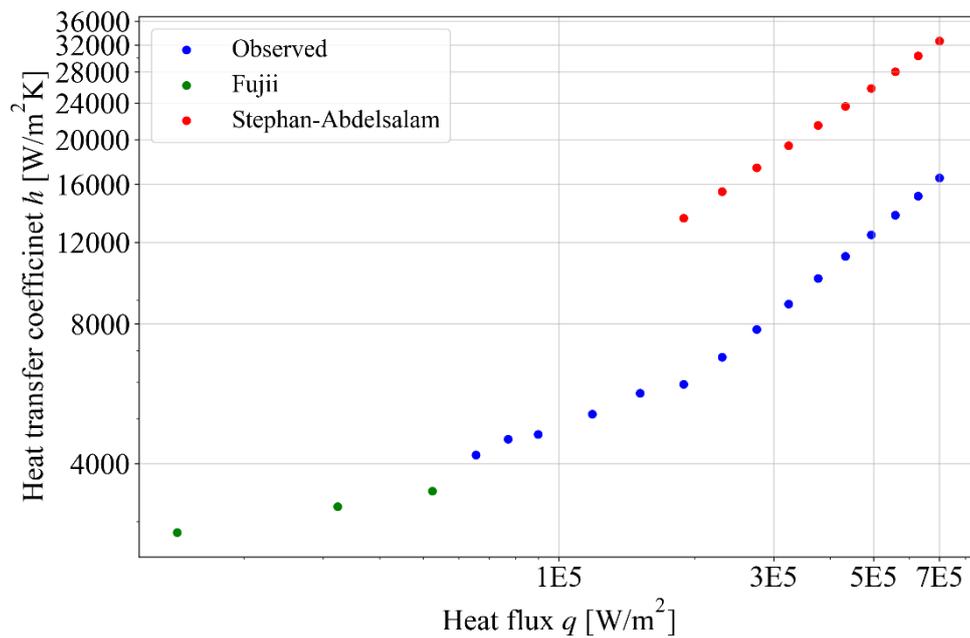


図 2.6 熱伝達係数測定値と整理式による推定値

表 2.5 熱流束測定値のまとめ

電流値[A]	平均値[W/m <sup>2</sup> ]	最小値[W/m <sup>2</sup> ]	最大値[W/m <sup>2</sup> ]	標準偏差 [W/m <sup>2</sup> ]
12	65469	65211(-258)	65747(+278)	102
13	77135	76667(-468)	77573(+438)	137
14	90005	89573(-432)	90623(+618)	163
16	118605	118062(-543)	119289(+684)	255
18	151453	150700(-753)	152711(+1258)	346
20	189423	188318(-1105)	190510(+1087)	433
22	230294	229498(-796)	231728(+1434)	416
24	274918	274163(-755)	276034(+1116)	396
26	323786	323103(-683)	324664(+878)	286
28	376171	375741(-430)	376585(+414)	169
30	432898	432534(-364)	433437(+539)	152
32	493823	493347(-476)	494230(+407)	161
34	558730	558216(-514)	559357(+627)	196
36	627545	626977(-568)	628286(+741)	259
38	700353	699857(-496)	701045(+692)	215

表 2.6 熱伝達係数測定値のまとめ

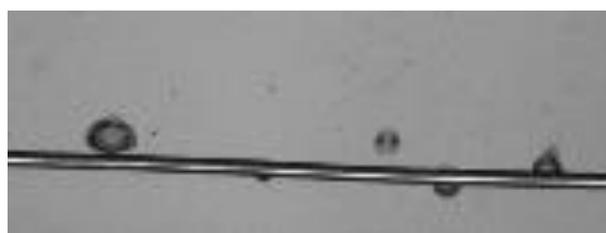
電流値[A]	平均値[W/m <sup>2</sup> K]	最小値[W/m <sup>2</sup> K]	最大値[W/m <sup>2</sup> K]	標準偏差 [W/m <sup>2</sup> K]
12	4173	3804(-369)	4508(+335)	145
13	4514	4016(-498)	5193(+679)	173
14	4624	4109(-515)	5037(+413)	155
16	5113	4686(-427)	5499(+386)	172
18	5672	5118(-554)	6139(+467)	179
20	5932	5580(-352)	6417(+485)	161
22	6789	6391(-398)	7088(+299)	132
24	7784	7475(-309)	7993(+209)	111
26	8832	8614(-218)	9027(+195)	77
28	10032	9870(-162)	10153(+121)	50
30	11199	11099(-100)	11312(+113)	42
32	12465	12365(-100)	12621(+156)	44
34	13750	13631(-119)	13857(+107)	43
36	15116	14976(-140)	15258(+142)	54
38	16528	16398(-130)	16658(+130)	50

#### 2.4.4 観測画像および編集

熱伝達係数測定実験で撮影された白金線回りの動画は 1 秒間隔で画像に切り出される。さらに、画像から不要な背景部分を取り除かれ、図 2.7 に示す白金線を中心とした画像にトリミングされる。画像はグレースケールに変換されており、チャンネル数は 1 である。観測画像の大きさは縦 60 ピクセル、横 160 ピクセルであり、熱伝達係数の測定点と同じく 2700 枚の画像が用意されている。また、白金線に通電していないときの画像も 180 枚用意している。図 2.7 の観測画像から沸騰熱伝達で観測される蒸気泡も鮮明に捉えることができ、その大きさや数も肉眼で確認することができる。



(a) 14A



(b) 24A



(c) 38A

図 2.7 沸騰様相の観測画像

## 2.5 機械学習用データセットの作成

機械学習は大きく分けて教師あり学習，教師なし学習，強化学習の3つに分けられる．教師あり学習とは，その中でも最も一般的な機械学習のアルゴリズムである．本研究でも教師あり学習を主に取り扱う．教師あり学習は，用意されたデータセットを使用し，既知の入力と既知の応答によってモデルの学習をさせ，予測を行う．この既知の入力は特徴量とも呼ばれる．学習用のデータセットには入力データとその応答値のペアが用意されている必要がある．応答値は出力または目的変数と呼ばれる．教師あり学習アルゴリズムではこのデータセットを用いて，入力データと応答値を結び付け，未知の入力データに対する応答値を予測する．

教師あり学習のデータセットには先ほどでも述べた通り，入力となる特徴量と出力となる応答値が含まれる．ここでは第3章や第4章で用いるデータセットを作成することでデータセットの例を示す．入力となる特徴量は図2.7で示した白金線周りの観測画像である．特徴量の次元数は画像をベクトル変換したときの要素数で表すことが一般的であり， $60 \times$

160 の 1 チャンネルの場合，9600 次元となる．1 つの次元には 1 つの画素数が含まれており，その値は 0 から 255 までである．出力となる応答値はここでは熱伝達係数とした．データセット全体の構造を表 2.7 にまとめる．1 つの列には 9600 個の特徴量と 1 つの応答値が格納されており，これは 1 枚の画像と 1 つの熱伝達係数が含まれているということである．

表 2.7 学習用データセット

	特徴量 1	特徴量 2	...	特徴量 9599	特徴量 9600	応答値 (目的変数)
1	100	100	...	107	107	4150
2	100	100	...	108	107	4205
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2879	93	93	...	94	94	16551
2880	92	92	...	96	96	16467

## 2.6 機械学習の環境構築

機械学習とりわけ深層学習には膨大な計算処理が必要なため，計算機であるコンピュータのスペックに計算時間や処理時間が大きく左右される．本研究ではパーソナルコンピュータを計算機として使用し，表 2.8 に機械学習に関わるハードウェアの構成をまとめる．

表 2.8 計算機の構成

OS	Windows 10 Home
CPU	Intel Core i7-9700K 3.60GHz
RAM	DDR4-2400 32.0GB
GPU	NVIDIA Quadro P2000 5GB

### 第3章 主成分分析によるデータセットの可視化

本章では、統計学上のデータ解析手法である主成分分析を学習用の観測画像に対して適用し、その結果について従来の伝熱解析における観点から熱伝達の特徴を捉えられているか検証する。

#### 3.1 主成分分析

##### 3.1.1 主成分分析

主成分分析 (Principal Component Analysis : PCA) <sup>[15]</sup>は次元削減や特徴量抽出、データの可視化のために用いられる多変量解析である。多変量解析には主成分分析のほかに因子分析やクラスターなどがある。そのほとんどが教師なし学習であるが、それぞれが持つ特徴に合わせて手法を選択することが望ましい。主成分分析はデータの分散を最も保持する主成分を見つけ、主成分ベクトル空間へデータを射影する。情報の損失を最小限に抑え、多次元データを低次元データに縮約することができ、データの解釈もしやすくなる。データの分散を最も保持する主成分は第1主成分と呼ばれ、順に第2主成分、第3主成分と続き、保持する分散の大きさもその通りである。

##### 3.1.2 2次元データに対する主成分分析

ここでは、主成分分析を2次元データ行列 $X$ に対して適用し、分散を最大限にする主成分を見つける。式3.1にその2次元データ行列 $X$ を示す。

$$X = \begin{bmatrix} x_1 & y_1 \\ \vdots & \vdots \\ x_n & y_n \end{bmatrix} \quad (3.1)$$

データ行列 $X$ に対し、2次元ベクトル $a$  (式3.2) を用いてデータの変換を行うと、変換後の新たなデータ行列 $Z$ は式3.3で表せる。また、 $a$ は単位ベクトルである。

$$a = (a_1, a_2) \quad (3.2)$$

$$Z = a_1 \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} + a_2 \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \quad (3.3)$$

この変換後のデータ行列 $Z$ の分散 $V_Z$ が最大の時、変換のためのベクトル $\mathbf{a}$ は第1主成分ベクトルに対応する。式3.4に分散 $V_Z$ を示す。

$$\begin{aligned}
V_Z &= \frac{1}{n} \sum_{i=1}^n (Z_i - \bar{Z})^2 \\
&= \frac{1}{n} \sum_{i=1}^n \{(a_1 x_i + a_2 y_i) - (a_1 \bar{x} + a_2 \bar{y})\}^2 \\
&= \frac{1}{n} \sum_{i=1}^n \{a_1(x_i - \bar{x}) + a_2(y_i - \bar{y})\}^2 \\
&= \frac{1}{n} \sum_{i=1}^n \{a_1^2(x_i - \bar{x})^2 + 2a_1 a_2(x_i - \bar{x})(y_i - \bar{y}) \\
&\quad + a_2^2(y_i - \bar{y})^2\} \\
&= a_1^2 V_x + 2a_1 a_2 S_{xy} + a_2^2 V_y
\end{aligned} \tag{3.4}$$

ここで、 $V_x$ はデータ行列 $X$ の第1列の分散、 $V_y$ は第2列の分散、 $S_{xy}$ は共分散である。式3.4と2次元ベクトル $\mathbf{a}$ が単位ベクトルであることからラグランジュの未定乗数法を用いると、

$$\begin{aligned}
F(a_1, a_2, \lambda) &= V_Z - \lambda(a_1^2 + a_2^2 - 1) \\
&= a_1^2 V_x + 2a_1 a_2 S_{xy} + a_2^2 V_y - \lambda(a_1^2 + a_2^2 - 1)
\end{aligned} \tag{3.5}$$

となり、式3.5において、 $a_1, a_2, \lambda$ の偏微分が0となる時、データ行列 $Z$ の分散 $V_Z$ は最大となる。それぞれの偏微分方程式を式3.6で表す。

$$\begin{cases} \frac{\partial F(a_1, a_2, \lambda)}{\partial a_1} = 2a_1 V_x + 2a_2 S_{xy} - 2a_1 \lambda = 0 \\ \frac{\partial F(a_1, a_2, \lambda)}{\partial a_2} = 2a_1 S_{xy} + 2a_2 V_y - 2a_2 \lambda = 0 \\ \frac{\partial F(a_1, a_2, \lambda)}{\partial \lambda} = -a_1^2 - a_2^2 + 1 = 0 \end{cases} \tag{3.6}$$

さらに、式 3.6 より、式 3.7 が成り立つ。

$$\begin{bmatrix} V_x & S_{xy} \\ S_{xy} & V_y \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \lambda \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} \quad (3.7)$$

これは分散共分散行列の固有方程式であり、この固有方程式を解くことにより主成分が決定する。固有値のうち、大きいものが第 1 主成分である。固有値から決定される  $a_1, a_2$  は固有ベクトルである。つまり、分散を最大化する軸を見つけることは元行列の分散共分散行列の固有値を求めることに帰着する。

ここで  $a_1, a_2$  を第 1 主成分の固有ベクトルとすると、固有ベクトルと元データ行列の内積  $Z_i$  は第 1 主成分得点と呼ばれる。また、第  $i$  主成分が保持する分散を元データ行列の総分散で除したものを寄与率といい、第  $i$  主成分までの主成分が保持する分散の合計を総分散で除したものを累積寄与率という。

### 3.2 データセットの標準化

主成分分析を実行するデータセットに対し、標準化を行った。標準化の目的はセンタリングとスケーリングを行うことであり、式 3.8 で表せられる。

$$X_{\text{std},ij} = \frac{X_{ij} - \mu_j}{\sigma_j} \quad (3.8)$$

$\mu_j$  は第  $j$  列の平均、 $\sigma_j$  は第  $j$  列の標準偏差である。標準化を行うことで主成分分析の結果が単位系の違いによる影響やデータセットの特徴量が持つ分散の大きさの違いによる影響を受けなくなる。

データセットに標準化を行い、標準化された後のデータ値に従ってカラーマップの変更を行った。図 3.1 に標準化を行う前の観測画像と標準化後の可視化画像を示す。図 3.1(a) および (b) は白金線に電流を供給していないときのペアである。元の画像のピクセル値が 0 に近い、つまり黒に近いピクセルは標準化後には青で表現されていることが確認できる。一方、元の観測画像のピクセル値が 255 に近いピクセルは赤で表現されてる。ここで青はネガティブ値、赤はポジティブ値、白は 0 を表している。また、図 3.1(b) の標準化後の可視

化画像には蒸気泡のようなものが確認されるが，これは標準化の影響によるものであることに加え，あくまでも可視化画像であるということに注意が必要である．



(a) 標準化前データ (0A)



(b) 標準化後データ (0A)



(c) 標準化前データ (38A)



(d) 標準化後データ (38A)

図 3.1 標準化データセット

### 3.3 データセットに対する主成分分析

データの可視化のためにすべてのデータセットに対し主成分分析を行った．主成分分析には `scikit-learn` の `decomposition.PCA` を用いた．データセットには前節で述べた標準化を行っている．

### 3.3.1 主成分ベクトル空間への射影

第1主成分と第2主成分の組み合わせにおいて、ベクトル空間にすべてのデータセットを射影した。射影したデータセットには沸騰領域ごとのラベル付けを行っている。主成分ベクトル空間上でのデータセットの座標を主成分得点といい、第1主成分に対する座標を第1主成分得点と呼ぶ。図3.2の射影より、主成分ベクトル空間に射影されたデータセットが沸騰領域ごとにまとまっていることが確認される。第1主成分得点が大きくなるにつれ、沸騰領域は自然対流域から核沸騰領域に遷移している。さらに、電流を供給していない、つまり、熱伝達が生じていないデータは第1主成分得点がデータセットの中でも最も小さくされるように射影されている。第2主成分に注目すると、沸騰領域ごとのまとまりは確認できないが自然対流域や核沸騰域内での違いを捉えているように見える。これらは主成分負荷量や主成分得点を可視化することでより詳しい解析が可能である。

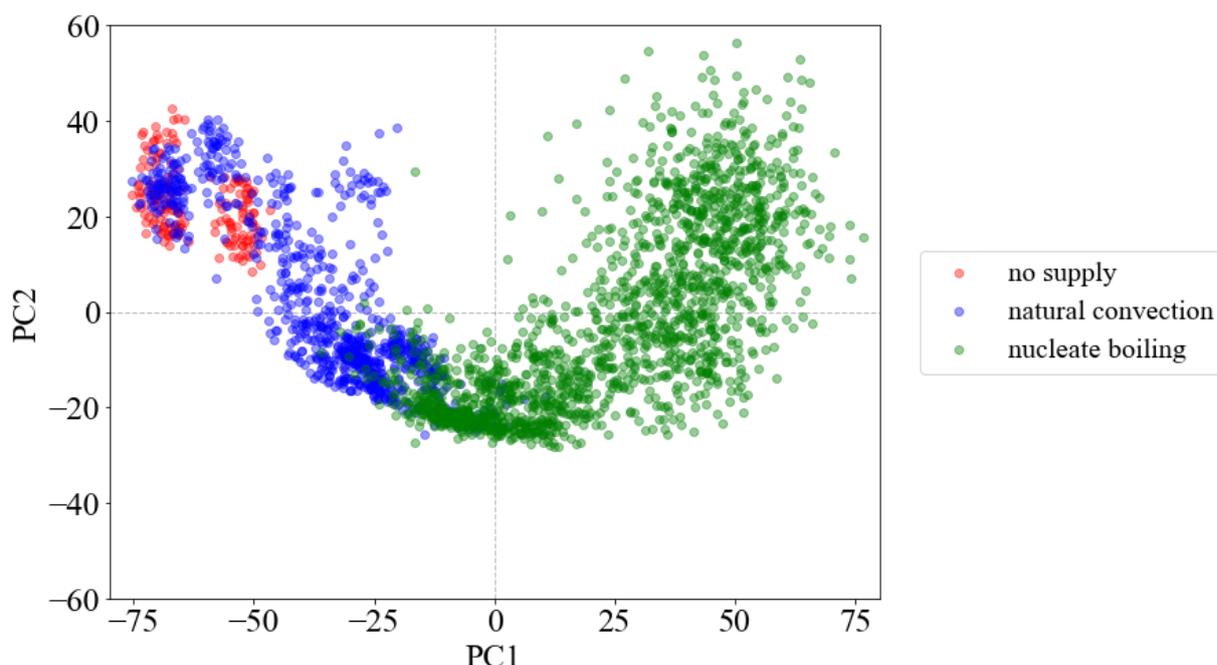


図 3.2 第1・第2主成分への射影

### 3.3.2 第1主成分と第10主成分までの組み合わせによる射影

前節により、第1主成分は沸騰領域ごとの特徴をかなり捉えられていることが期待できる。そこで第1主成分と他の主成分の組み合わせや、第1主成分以外の主成分同士の組み合わせで2次元空間への射影を行った。実際に次元削減を行う際に、特定の2次元を選ん

で削減を行うことは滅多にないが、ここでは後に、主成分負荷量や主成分得点の可視化を行うため、選定を行っている。第1主成分から第10主成分までの組み合わせにおける2次元空間への射影を図3.3に示す。

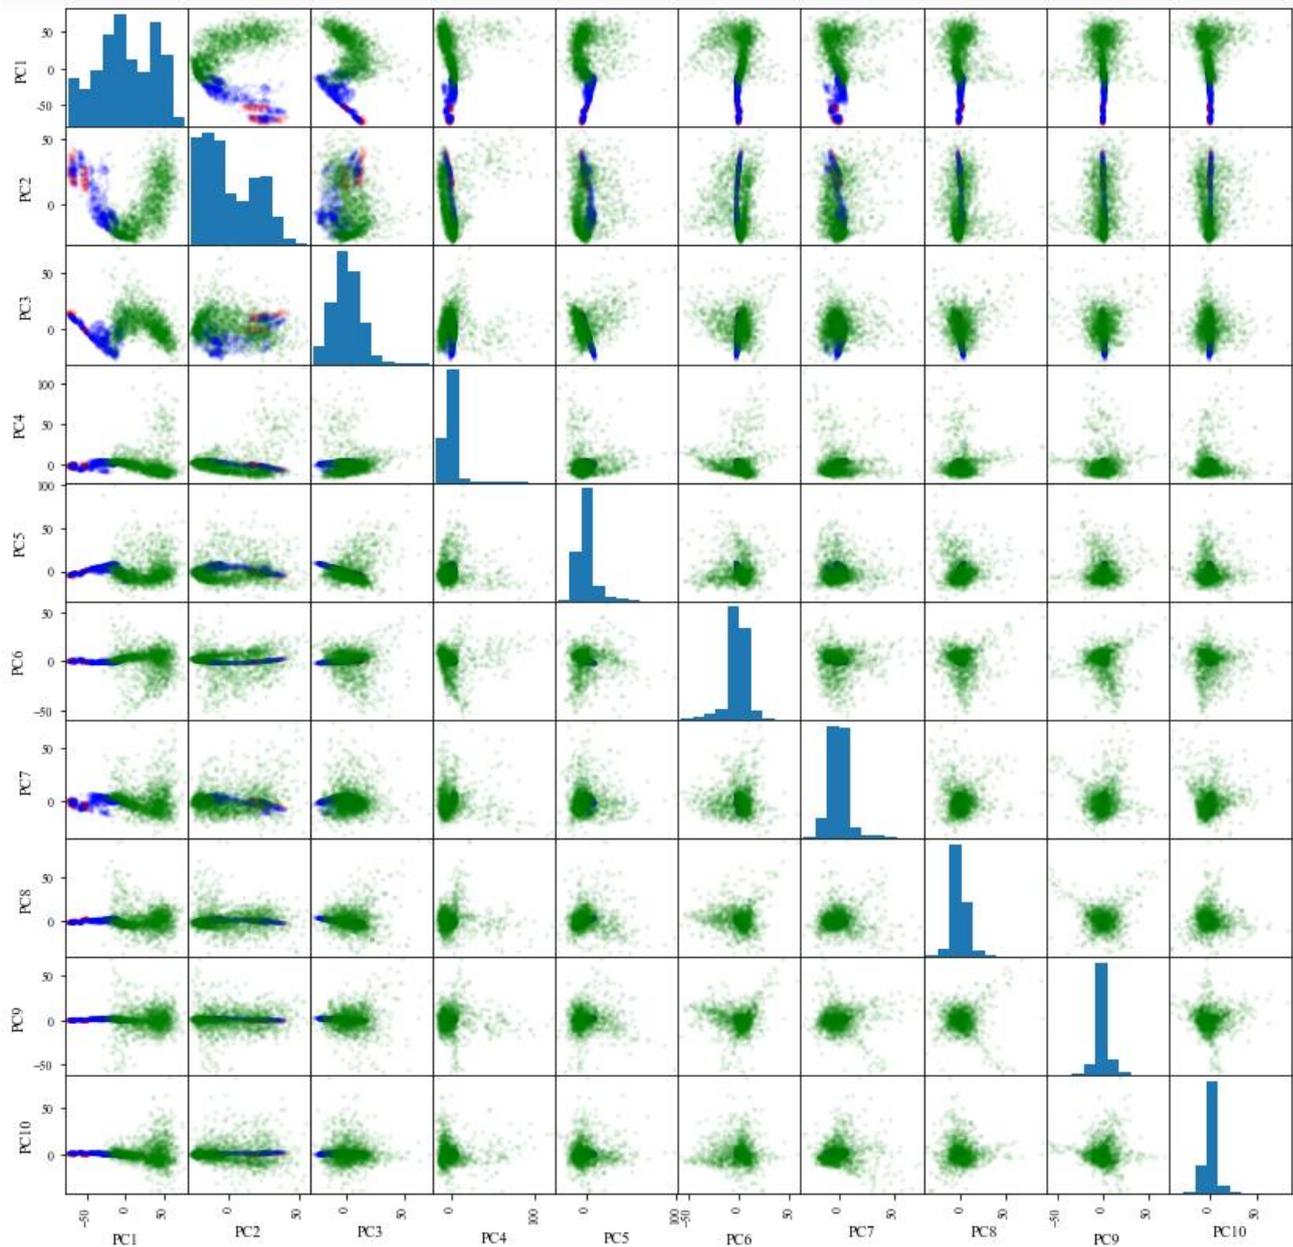


図3.3 第1主成分から第10主成分までの組み合わせによる射影

図3.3を見ると、第1、第2、第3主成分以外の主成分を用いた射影には沸騰領域ごとの特徴を捉えるようなものは見受けられなかった。主成分分析は特定の目的変数が存在しない教師なし学習であるので、必ずしもすべての主成分が沸騰領域を判別するような基底を

取るというわけではない。しかし、第 1, 第 2, 第 3 主成分に関しては、沸騰領域ごと、もしくは沸騰領域内の違いを捉えているように見える。そこで、次節以降ではこれらの主成分負荷量や主成分得点を可視化することで更なる考察を行っていく。

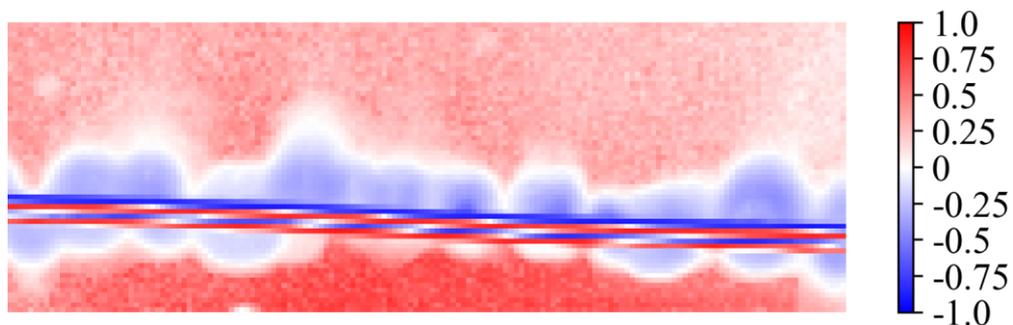
### 3.3.3 固有ベクトルおよび主成分負荷量の可視化

固有ベクトルは主成分分析において、元データ行列と主成分の直交交換を行うための結合係数の役割を果たしている。つまり、元データの特徴量に対する重みとしてみることができる。このことから固有ベクトルを可視化し、考察を行うのも有効な手段であるが、ここでは主成分負荷量を可視化することで考察を行う。

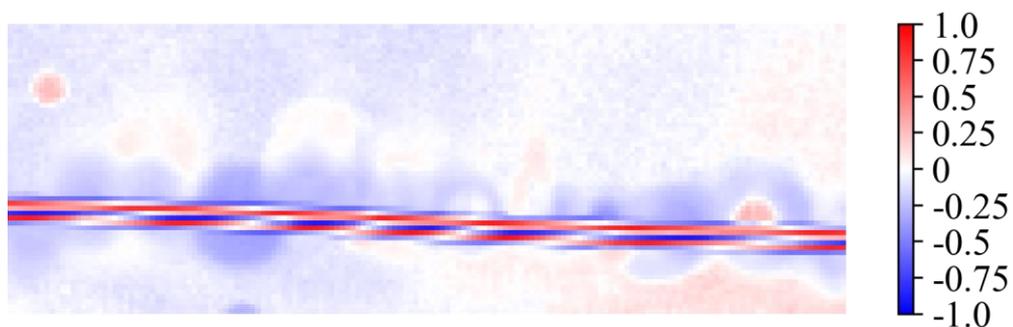
主成分負荷量は式 3.9 で表され、主成分と元データの各変数（特徴量）の相関係数である。ここで、 $r_{z_mx_i}$  は第  $m$  主成分  $z_m$  と  $i$  番目の変数  $x_i$  との間の因子負荷量であり、 $\sigma_{z_mx_i}^2$  は共分散、 $\sigma_{z_m}$ 、 $\sigma_{x_i}$  はそれぞれ  $z_m$ 、 $x_i$  の標準偏差である。もしくは固有値の正の平方根と固有ベクトルの積を元行列の分散で除したもので表される。 $\lambda_m$  は第  $m$  主成分の分散、 $a_{im}$  は変数  $x_i$  に対応する第  $m$  主成分の固有ベクトルである。固有ベクトルとの相違は特徴量ごとの単位や変動範囲を考慮している点である。また、最大 1、最小 -1 にスケーリングされるため、比較も容易になる。

$$r_{z_mx_i} = \frac{\sigma_{z_mx_i}^2}{\sigma_{z_m} \sigma_{x_i}} = \frac{\sqrt{\lambda_m} a_{im}}{\sigma_{x_i}} \quad (3.9)$$

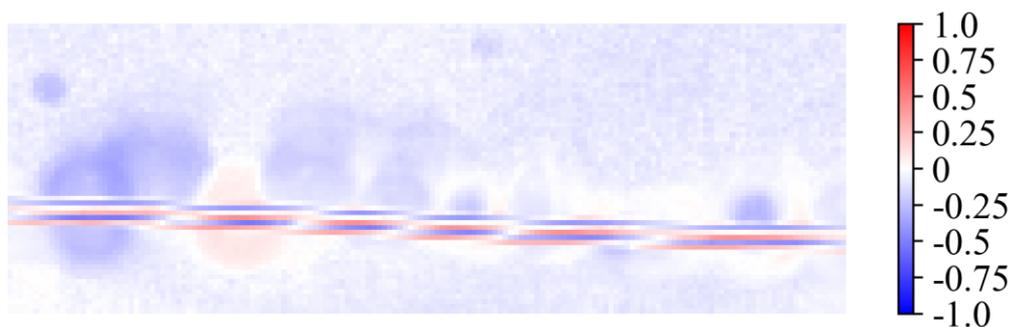
第 1 主成分から第 3 主成分までの主成分負荷量を可視化したものを図 3.4 に示す。



(a) 第 1 主成分負荷量



(b) 第 2 主成分負荷量



(c) 第 3 主成分負荷量

図 3.4 主成分負荷量

図 3.4(a)の第 1 主成分負荷量に着目すると、白金線の周囲とそれ以外で主成分負荷量に大きく違いがある。白金線の周囲は丸のような形状をしていることから蒸気泡に対して強い重みを置いていることが推察できる。それ以外の部分ではほぼ一様に正の重みがつけられており、これは周囲流体への重みであると解釈できる。白金線の周囲とそれ以外で重み

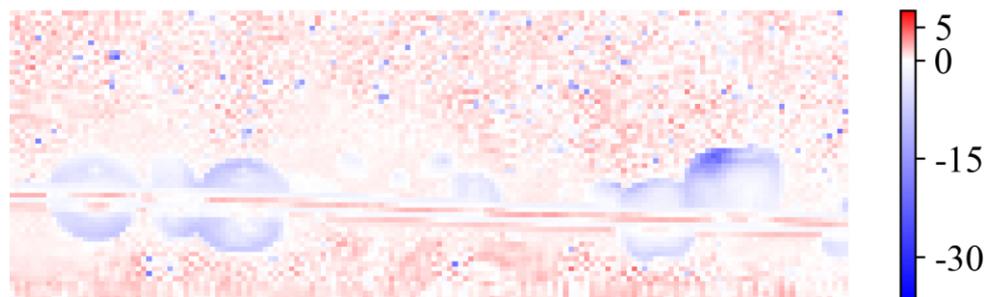
の正負が異なるが、これはその領域同士が対の性質を示しているというわけではない。実際、元データの正負によって主成分得点は正にも負にも取り得るからである。主成分負荷量においては、正負のどちらであるのかということより 1 もしくは -1 に近い主成分負荷量に着目するのが一般的である。なぜなら、1 もしくは -1 に近い値を持つ主成分負荷量は主成分と強い相関を持つからである。第 1 主成分負荷量から第 3 主成分負荷量までを総じて見ると、蒸気泡と見られる部分に負荷がかかっていることが確認でき、統計学上からも蒸気泡がプール沸騰現象の中で強い影響を持っていることが予想される。しかし、図 3.4(b)(c) の第 2・第 3 主成分負荷量は沸騰現象に完全に則っているとは言えない。第 2 主成分負荷量ではバルク流体の負荷量が一様でなく、さらに正負どちらも有している。第 3 主成分負荷量でもポジティブの蒸気泡とネガティブの蒸気泡が確認できることから同様のことがいえる。第 2・第 3 主成分負荷量はかなり局所的な評価をしていることが考えられ、このことは主成分を沸騰領域の判別やその他の熱伝達要素の予測に用いるときには留意しなければならない。

### 3.3.4 主成分得点

主成分負荷量の可視化に加え、主成分得点を可視化することもデータセットの解釈の大きい役立つ。ここでは熱伝達が生じていないデータ、自然対流域、核沸騰域の 2 つ、計 4 つデータに対する第 1 主成分得点の可視化を行う。

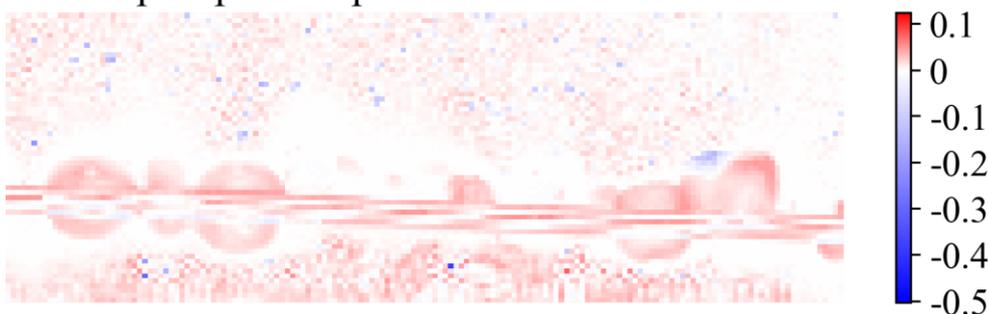
図 3.5 は核沸騰域 (38A) に属するデータに標準化を行った後の可視化画像とその標準化されたデータと第 1 主成分固有ベクトルの積(第 1 主成分得点)を可視化したものである。

このデータに対する主成分得点は 50.28 であった。図 3.2 を見ても分かるように第 1 主成分の中でも大きい得点である。図 3.5(b)中には全体的にポジティブの成分が確認されるが、中でも蒸気泡が強い要素となっているのが特徴的である。蒸気泡が主成分分析の中で強い影響を持っていることは主成分負荷量の可視化でも触れたが、主成分得点の可視化でも同様のことが確認された。特に、主成分得点の可視化では蒸気泡による得点が周囲流体より大きい値となっているため、周囲流体より重要な要素となっていることが分かる。このことから、主成分分析は観測画像から熱伝達の特徴となる蒸気泡を抽出していることが確認できる。



(a) 標準化データ

pricipal component score = 50.28



(b) 第1主成分得点

図 3.5 核沸騰域 (38A) の標準化データと第1主成分得点

図 3.6 には、核沸騰域 (28A) の結果を示す．図 3.5 と比べ蒸気泡の数や径が小さいことから主成分得点も 22.12 と小さくなっている．このように核沸騰域内でも蒸気泡の数や径の違いが主成分得点に反映されていることから，第1主成分によって変換される新しいデータセットは熱伝達係数や熱流束の予測に活用できることが期待される．



(a) 標準化データ

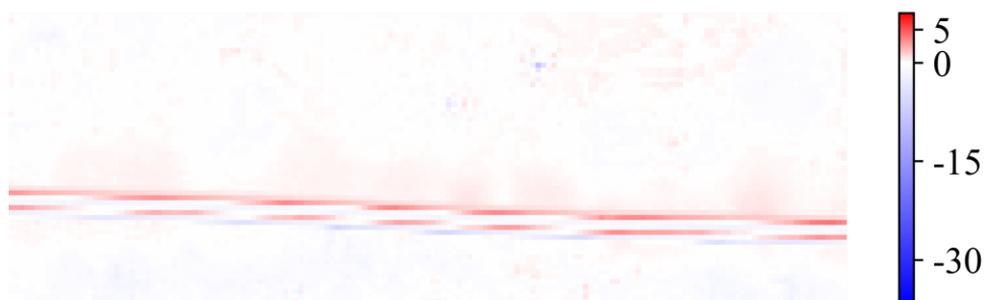
pricipal component score = 22.12



(b) 第1主成分得点

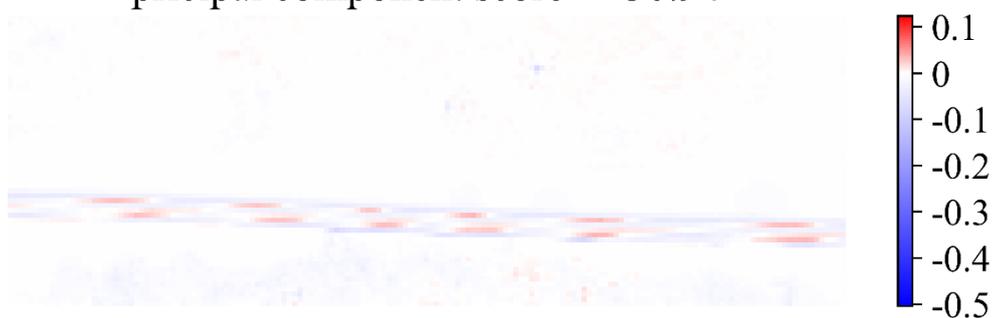
図 3.6 核沸騰域 (28A) の標準化データと第1主成分得点

図 3.7 は自然対流域における主成分得点の可視化である。標準化された可視化画像には蒸気泡のようなものが確認されるが、蒸気泡ではなく標準化によるものであることに注意が必要である。主成分得点は-30.94であった。主成分得点の可視化に注目すると、核沸騰域と比べて全体的にネガティブを示す部分が増加しており、それが主成分得点にも表れている。また、後述の熱伝達なしの周囲流体と比べると0付近もしくはポジティブな成分が多く確認され、対流による流体移動が主成分得点に影響を与えていることが分かる。



(a) 標準化データ

principal component score = -30.94



(b) 第1主成分得点

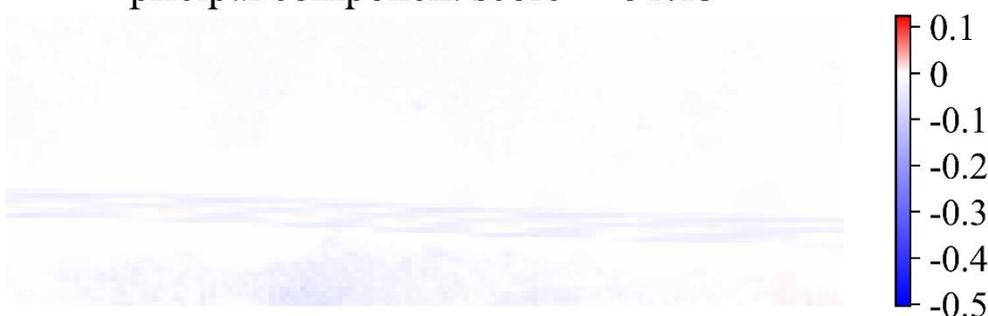
図 3.7 自然対流域 (13A) の標準化データと第1主成分得点

図 3.8 には熱伝達なしの標準化データ可視化画像とその主成分得点可視化画像を示す。主成分得点は4つの中で最小の-50.12であった。主成分得点の可視化画像も全体的に青みがかっている。



(a) 標準化データ

principal component score = -51.13



(b) 第1主成分得点

図 3.8 熱伝達なしの標準化データと第1主成分得点

それぞれの沸騰域における第1主成分得点の可視化から、第1主成分の解釈ができる。熱伝達なしと自然対流域において周囲流体部分の主成分得点に差があることから、対流による熱伝達の大きさや熱流束の情報を含んでいると考えることができる。核沸騰域においては蒸気泡が主成分得点に大きな影響を及ぼしている。蒸気泡の数や径の大きさによって主成分得点に変化しており、核沸騰域内での細かな特徴まで捉えている。第1主成分得点の分布は単に沸騰領域を分けているだけでなく、熱伝達係数や熱流束の大きさに沿って分布していることが考えられる。図 3.9 に第1主成分に射影したデータセットのラベルを沸騰領域から白金線に流れる電流値に変更し、50点ずつに減算したものを示す。また、図 3.10 は各電流値の第1主成分得点平均値を第1主成分軸上にプロットしたものである。円の大きさは分散の大きさに比例している。

図 3.9 および図 3.10 から第1主成分得点の平均値はほとんどが電流値の大きさの順に並んでおり、第1主成分得点の大きさと熱伝達の大きさが結びついていることが推測される。さらに、平均値は等間隔ではなく、熱伝達領域ごとにまとまっていることが見て取れる。

例えば、対流がほとんど見られない 0A と 12A と対流が確認できる 13,14,16A で 2 グループに分かれている。蒸気泡が確認できる 18A 以降の平均値はそれ以前のグループとは離れた場所に位置し、18~24A のグループ、30~38A のグループ、それらの中間に位置する 26,28A となっている。このことから主成分分析によって変換された新たなデータセットは、機械学習を用いた推定器によって熱伝達を予測するための入力情報として非常に有効であることが期待される。

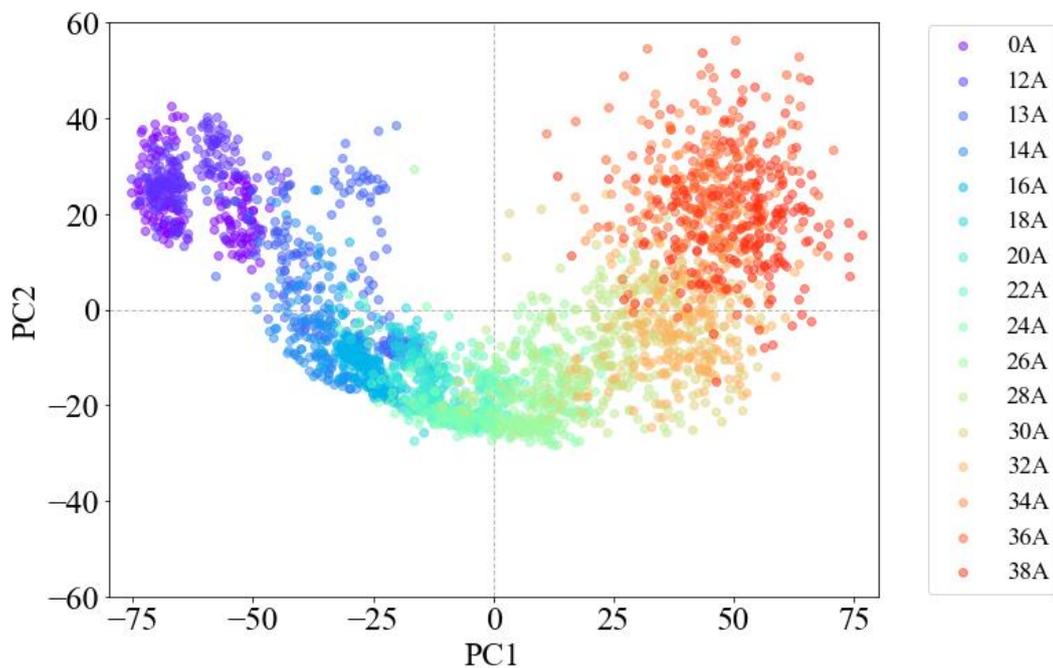


図 3.9 電流値ごとの第 1・第 2 主成分への射影

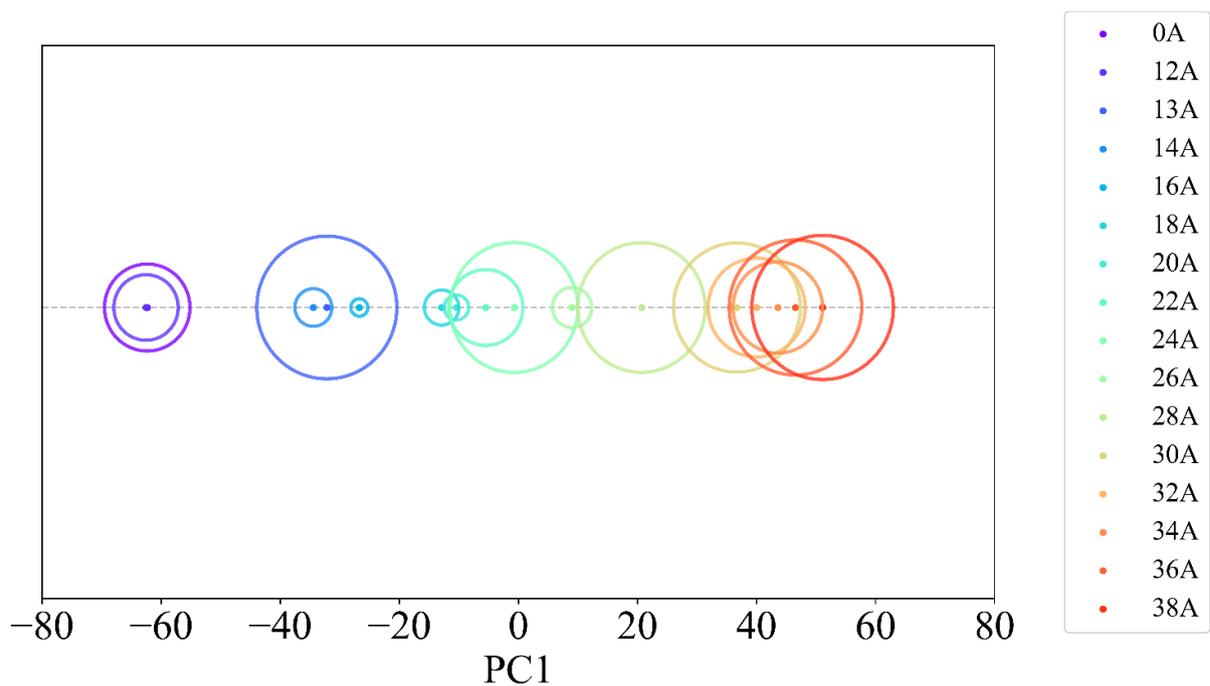


図 3.10 電流値ごとの第 1 主成分得点平均と分散の関係

### 3.3.5 寄与率および累積寄与率

主成分分析は元のデータからそれぞれの主成分に変換するが、それらの主成分が元のデータの情報をどの程度保持しているかを表す指標として寄与率が与えられる。寄与率はその主成分が持つ分散を元のデータの総分散を除いたもので表され、式 3.10 の通りである。

$$C_m = \frac{\lambda_m}{\sum \lambda_x} \quad (3.10)$$

$C_m$ は第 $m$ 主成分の寄与率であり、 $\lambda_m$ は第 $m$ 主成分の分散、 $\sum \lambda_x$ は元データの総分散である。また、すべての主成分の総和は元のデータの総分散と等しい。

また、第 $m$ 主成分までの分散の和を総分散で除いたもの、すなわち寄与率の和を累積寄与率という。累積寄与率は式 3.11 で表される。

$$P_m = \sum_{i=1}^m C_i = \frac{\sum_{i=1}^m \lambda_i}{\sum \lambda_x} \quad (3.11)$$

図 3.11 に主成分分析を行ったデータセットの累積寄与率を示す。

第 1 主成分の寄与率は 14.53% であり, 第 2 主成分, 第 3 主成分の寄与率はそれぞれ 3.85%, 1.51% であった. 第 1 主成分がその他の主成分に比べ, 元のデータの情報をかなり保持していることが分かる. さらに, 累積寄与率が 80%, つまり, 元のデータの分散の 80% を 644 主成分までで保持している. 次元削減を行う場合, 累積寄与率が 80% などと条件を設定し, 主成分の数を決定することが多く見受けられる. このデータセットでは累積寄与率を 80% として次元削減を行う場合, 9600 次元から 644 次元まで次元を削減することができる. ただし, これまでの主成分軸への射影や主成分負荷量の可視化でも分かるように第 2 主成分以降の主成分が沸騰現象の解釈をしているとは言うのは難しい. 第 2 主成分以降の寄与率は第 1 主成分の寄与率に比べ小さいことから, 第 2 主成分以降の主成分を用いるときには注意が必要である. また, 標準化により元データの分散を 1 にしている場合, 分散が 1 以上の主成分をすべて用いるという方法もある. これは元の変数が持つ分散よりも大きな分散を持つ主成分のみを採用するという考え方に従っている.

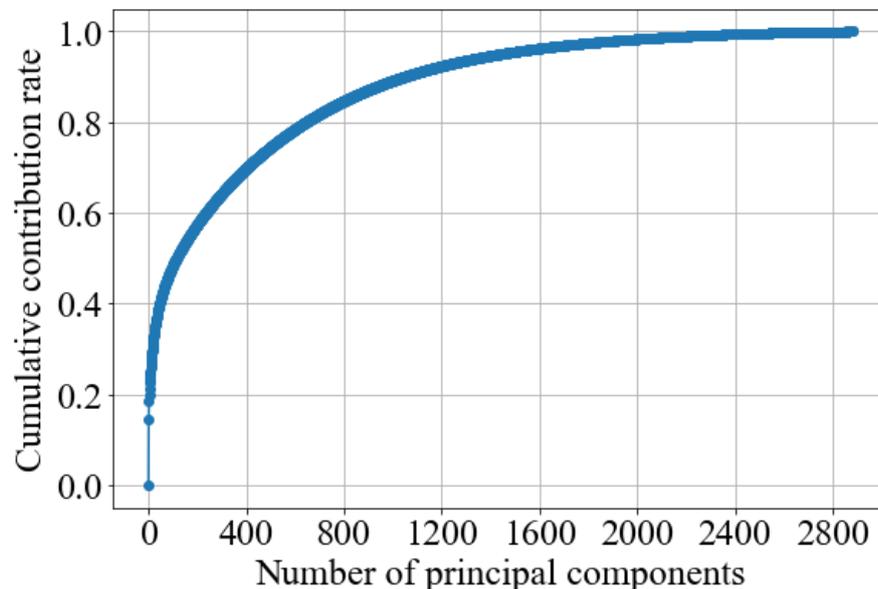


図 3.11 累積寄与率

### 3.3.6 新しいデータセットへの変換

主成分得点は縮約された新しい特徴量として機械学習のデータセットに用いられる. 次元削減の面ではコンピュータの処理能力への負担を軽減することができる. 本研究でも,

第4章の熱伝達係数の予測において、第1主成分を新たな特徴量として用いる。また、特徴量抽出の面でも分散の小さい情報に左右されない点やニューラルネットワークなどの学習回数を少なくできる点が有益であり、主成分分析はよく用いられる手法である。

## 第4章

本章では、第2章で得られたデータセットや第3章の主成分分析で縮約されたデータセットを用いて、線形・非線形回帰やニューラルネットワークによる熱伝達係数の予測を行う。また、それぞれの推定器の特徴について考察を行う。

### 4.1 線形・非線形回帰による熱伝達係数の予測

#### 4.1.1 主成分分析による新しいデータセット

第3章の主成分分析で得られた結果のうち、第1主成分のみを新しい特徴量として用いる。第3章で述べたように第2主成分以降はデータセットの分散を保持しているが、熱伝達の推定に適した特徴量ではないため本章では用いない。データセットは12Aから38Aの15条件、総2700点であり、白金線に通電していないときの観測画像は用いていない。特徴量(説明変数)は第1主成分得点のみ、目的変数を熱伝達係数とした構造となっている。表4.1に特徴量である第1主成分得点と目的変数である熱伝達係数の組み合わせを一部示す。また、横軸を第1主成分得点、縦軸を熱伝達係数とし、全データをプロットしたものを図4.1に示す。図4.1より、第1主成分得点と熱伝達係数には正の関係があることが見受けられる。このことから第1主成分得点を用いることで回帰分析による熱伝達係数の予測が期待できる。

表 4.1 主成分分析による変換データセット

	1	2	...	2699	2700
第1主成分得点	-51.12	-52.30	...	50.27	33.96
熱伝達係数	4180	4200	...	16551	16467

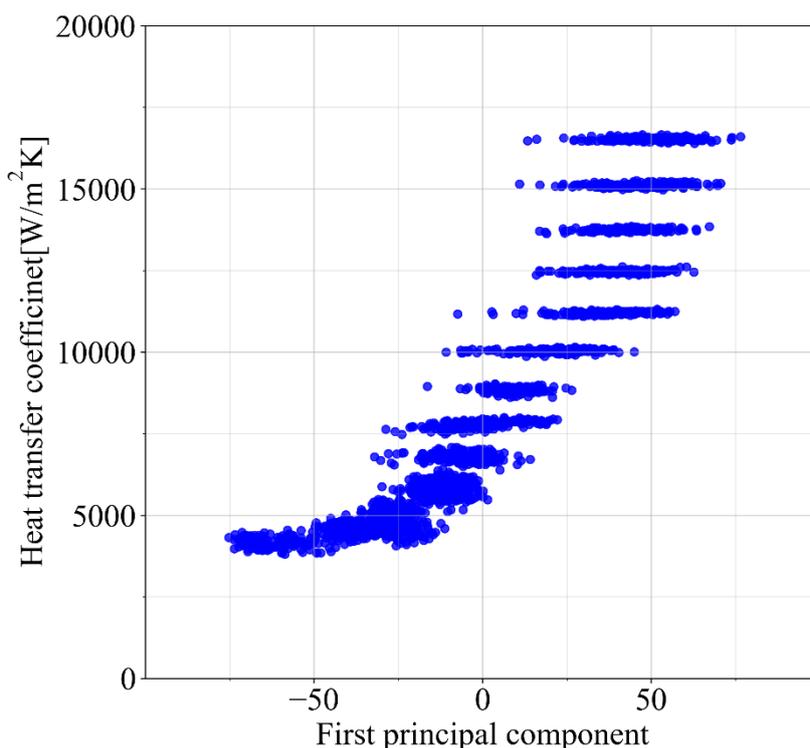


図 4.1 説明変数と目的変数のプロット

#### 4.1.2 線形回帰分析および非線形回帰分析

線形予測関数を用いて既知の説明変数から目的変数を予測することを線形回帰分析という。特に、説明変数が 1 つの場合には単回帰分析と呼ばれる。単回帰分析の予測関数を式 4.1 に示す。

$$y = w_0 + w_1 x \quad (4.1)$$

ここで、 $y$ は予測値、 $x$ は説明変数であり、 $w_0$ は定数項（切片）、 $w_1$ は説明変数の係数である。定数項 $w_0$ および説明変数の係数 $w_1$ の決定には最小二乗法を採用することが多い。最小二乗法は目的変数と予測値の二乗誤差を最小化するようにパラメータを決定する手法であり、誤差の分布に正規分布を仮定した場合の最尤推定である、線形回帰分析における二乗誤差を式 4.2 に示す。

$$E = \sum_i (Y_i - y_i) \quad (4.2)$$

$E$ は二乗誤差,  $Y_i$ は目的変数の真値,  $y$ は単回帰による推定値である.

非線形回帰分析は説明変数の非線形モデルを用いて目的変数を予測する回帰分析である. 非線形モデルは様々な関数形式を使用できることから説明変数と目的変数の関係を柔軟に表現することができる. その一方で, 適切な関数形式を選択することは容易でなく, 説明変数が増大するほど多くの労力を要することになる. 本章では図 4.1 で示した説明変数と目的関数の関係から式 4.3 と式 4.4 の多項式回帰モデルを用いる.

$$y = w_0 + w_1x_1 + w_2x_1^2 \quad (4.3)$$

$$y = w_0 + \sum_i w_ix_1^i \quad (4.4)$$

式 4.3 は $x_1$ についての 2 次関数モデル, 式 4.4 は $x_1$ についての  $n$  次関数モデルである. 線形回帰モデルと同じく  $w_0$ は定数項 (切片),  $w_1, w_2, w_3$ は説明変数の係数である. パラメータの決定には線形回帰モデルと同じく最小二乗法を用いる. 一般的に次数を大きくするほど高度な結果が得られるが, 複雑なモデルが常に優秀なモデルであるとは限らない. 高次元モデルが訓練データに過剰に適合してしまった結果, 汎化性を失ってしまう過学習と呼ばれる現象が代表的な例である. 適切なモデルの決定には次項で説明する評価指標や説明変数と目的変数の関係を理解することが必要である.

#### 4.1.3 モデルの精度評価指標

モデルの精度評価には平均絶対誤差 (MAE : Mean Absolute Error), 二乗平均平方根誤差 (RMSE : Root Mean Squared Error), 平均絶対パーセント誤差 (MAPE : Mean Absolute Percentage Error) や決定係数 ( $R^2$ ) を用いる. また, 二乗平均平方根誤差と平均絶対誤差の比 (RMSE/MAE) も評価指標の 1 つである.

平均絶対誤差を式 4.5 に示す.

$$\text{MAE} = \frac{\sum_i |Y_i - y_i|}{n} \quad (4.5)$$

平均絶対誤差が 0 に近いほど予測精度が高いことを表している。

式 4.6 に二乗平均平方根誤差を示す。

$$\text{RMSE} = \sqrt{\frac{\sum_i (Y_i - y_i)^2}{n}} \quad (4.6)$$

二乗平均平方根誤差が 0 に近いほど予測精度が高いことを表している。二乗平均平方根誤差は平均絶対誤差と比べ、外れ値に敏感である。全データの誤差が一定の場合のみ、平均絶対誤差と等しくなる。

平均絶対パーセント誤差を式 4.7 に示す。

$$\text{MAPE} = \frac{100}{n} \sum_i \left| \frac{Y_i - y_i}{Y_i} \right| \quad (4.7)$$

平均絶対誤差が 0% に近いほど高い予測精度であるといえる。二乗平均平方根誤差や平均絶対誤差が誤差の大きさを予測精度を評価するのに比べ、平均絶対パーセント誤差は比率で予測精度を評価するためスケールが異なるデータの誤差を比較できることが特徴である。

決定係数  $R^2$  は式 4.8 で表される。

$$R^2 = 1 - \frac{\sum_i (Y_i - y_i)^2}{\sum_i (Y_i - \bar{Y})^2} \quad (4.8)$$

決定係数は説明変数と目的変数の相関を表す。決定係数が 1 に近いほど回帰式が実際のデータに当てはまっていることを示す。しかし、決定係数がほとんど 1 であるときには、回帰式の汎化性能は失われることになるため範囲外のデータに対応できない可能性がある。

また、二乗平均平方根誤差と平均絶対誤差の比も評価指標の 1 つである。式 4.9 と 4.10 に二乗平均平方根誤差と平均絶対誤差、それぞれの二乗を示す。

$$\text{RMSE}^2 = \frac{\sum_i (Y_i - y_i)^2}{n} = \frac{\sum_i e_i^2}{n} \quad (4.9)$$

$$\text{MAE}^2 = \frac{(\sum_i |Y_i - y_i|)^2}{n^2} = \frac{(\sum_i e_i)^2}{n^2} \quad (4.10)$$

ここで式 4.9 と式 4.10 の差を取ると、

$$\text{RMSE}^2 - \text{MAE}^2 = \frac{1}{n} \sum_i e_i^2 - \left( \frac{1}{n} \sum_i e_i \right)^2 = \text{VAR}(e_i) \quad (4.11)$$

式 4.11 となり、二乗平均平方根誤差と平均絶対誤差の差は誤差の絶対値  $e_i$  の分散と等しいことが分かる。

また、 $e_i$  の平均  $\text{MEAN}(e_i)$  が平均絶対誤差  $\text{MAE}$  と等しいことから、二乗平均平方根誤差と平均絶対誤差の比は式 4.12 によって表される。

$$\frac{\text{RSME}}{\text{MAE}} = \sqrt{1 + \frac{\text{VAR}(e_i)}{\text{MEAN}(e_i)^2}} \quad (4.12)$$

誤差が正規分布に従う場合、 $\text{MEAN}(e)$  (式 4.13) と  $\text{VAR}(e)$  (式 4.14) は以下の式のように計算される。

$$\text{MEAN}(e) = \int_0^{\infty} e \times \frac{2}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e^2}{2\sigma^2}\right) de = \sqrt{\frac{2}{\pi}}\sigma \quad (4.13)$$

$$\text{VAR}(e) = \int_0^{\infty} (e - \text{MEAN}(e))^2 \times \frac{2}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e^2}{2\sigma^2}\right) de = \left(1 - \frac{2}{\pi}\right)\sigma^2 \quad (4.14)$$

以上から、二乗平均平方根誤差と平均絶対誤差の比は、

$$\frac{\text{RMSE}}{\text{MAE}} = \sqrt{1 + \frac{\left(1 - \frac{2}{\pi}\sigma^2\right)}{\left(\frac{2}{\pi}\sigma\right)^2}} = \sqrt{\frac{\pi}{2}} \doteq 1.253 \quad (4.15)$$

式 4.15 となる．RMSEとMAEの比が $\sqrt{\frac{\pi}{2}}$ 付近であり，誤差が正規分布に従っている場合，高い予測精度が期待される．逆に，比が $\sqrt{\frac{\pi}{2}}$ から大きく外れている時には，ハイパーパラメータの変更や誤差関数の変更，データクレンジングの実行が要求される． $\sqrt{\frac{\pi}{2}}$ 付近であっても，誤差の絶対値が大きいときや誤差が正規分布に従わない場合にはモデルの変更が必要である．また，誤差が正規分布よりも多くの外れ値が観測される分散 $2\phi^2$ のラプラス分布に従う場合，RMSEとMAEの比は $\sqrt{2}$ 付近となる．

#### 4.1.4 線形回帰分析による熱伝達係数の予測

本項では線形回帰分析を用いて熱伝達係数の予測とその考察を行う．データセットには第 4.1.1 項で述べた主成分分析による変換データセットを用いている．データセットのうち 1800 点を訓練用データに，残りの 900 点を評価用データに振り分けた．

図 4.2 は，単回帰分析による熱伝達係数の推論である．図の横軸に特徴量である第 1 主成分得点，横軸に目的変数である熱伝達係数を示し，青色のプロットが実測値，赤色のプロットが回帰式を示す．また，図 4.3 に実測値と予測値のプロットを示す．横軸は熱伝達係数の実測値，縦軸は予測値である．実測値と予測値の絶対誤差率が 0%に近いドットほど赤色で表され，誤差率が増大するほど青色で表される．なお，20%以上の誤差率はすべて 20%の誤差率と同じ色で表している．平均絶対誤差MAE，二乗平均平方根誤差RMSE，平均絶対パーセント誤差MAPE，決定係数 $R^2$ ，RMSEとMAEの比をそれぞれ表 4.2 にまとめる．また，表 4.3 に線形回帰モデル式と各パラメータを示す．

表 4.2 より，平均絶対誤差や二乗平均平方根誤差が大きく，平均絶対パーセント誤差は 17.31%であった．決定係数やRMSE/MAE比はまざまざの結果であるが，予測精度が低く，モデルの改善が求められる．これは図 4.2 から同様のことが言える．図 4.2 中の熱伝達係数の実測値は第 1 主成分得点が増大するにつれ，指数的に増大しているが，線形回帰で

はこの特徴を表現することができない。その結果、回帰直線と実測値の間に大きな誤差が生じている。図 4.3 中のプロットの色も大部分が青色で占められており、誤差が大きいことが確認できる。

以上のことより、線形単回帰分析では説明変数である第 1 主成分得点から熱伝達係数を予測することは困難であり、モデルの改善が必要であることが分かった。次項では線形単回帰分析から得られた改善点から、非線形回帰分析によって熱伝達係数を予測するモデルを構築し、そのモデルの評価と考察を行う。

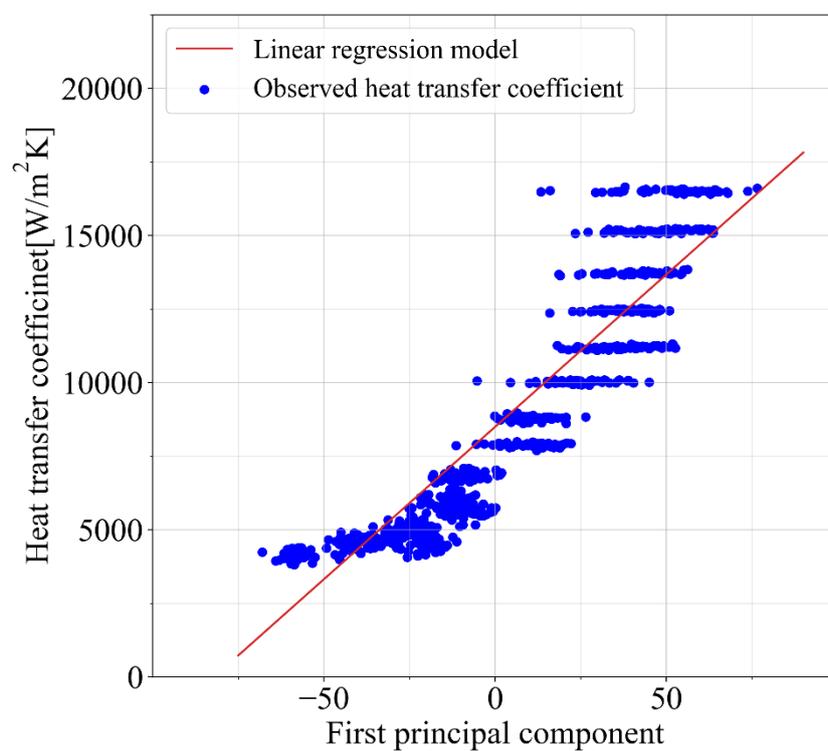


図 4.2 単回帰による熱伝達係数の推論

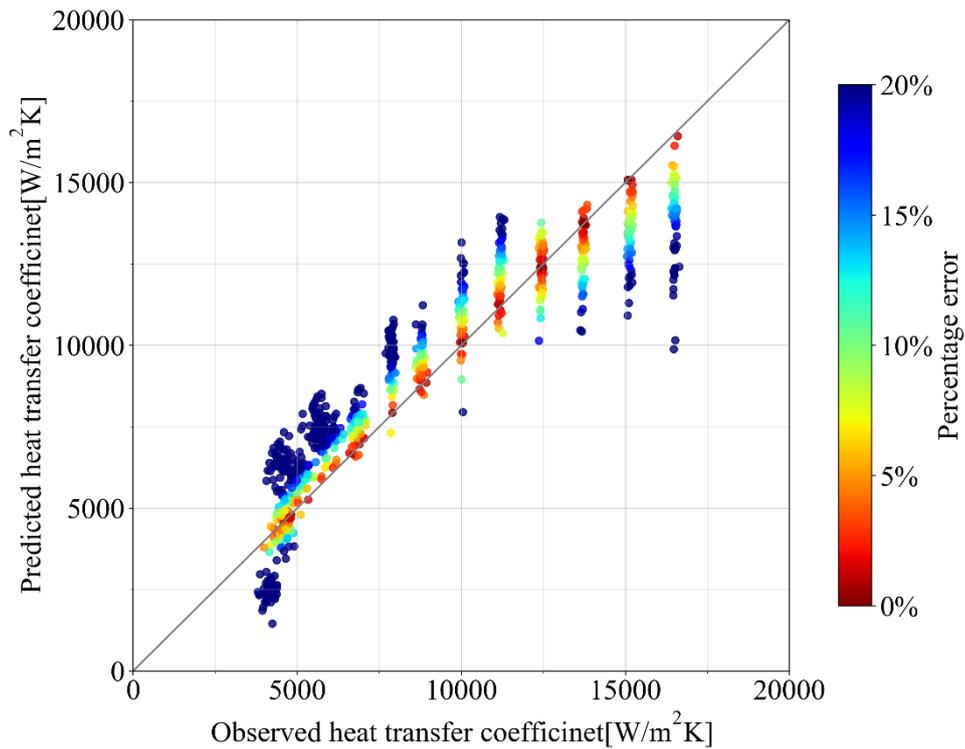


図 4.3 単回帰分析の実測値－予測値プロット

表 4.2 単回帰分析の予測精度評価

平均絶対誤差MAE [W/(m²K)]	1287
二乗平均平方根誤差RMSE[W/(m²K)]	1555
平均絶対パーセント誤差MAPE[%]	17.31
決定係数R <sup>2</sup>	0.847
RMSE/MAE	1.208

表 4.3 単回帰モデルパラメータ

回帰モデル : $y = w_0 + w_1x_1$	
$w_0$	8493
$w_1$	103.5

#### 4.1.5 非線形（2次）回帰分析による熱伝達係数の予測

本項では非線形回帰モデルの1つである2次の多項式回帰を用いて熱伝達係数の予測を

行い、その結果を考察する。第 4.1.4 項と同じデータセットを用いている。

図 4.4 は 2 次の多項式回帰分析による熱伝達係数の推論である。図の横軸に第 1 主成分得点、横軸に熱伝達係数を示し、青色のドットが実測値、赤色のプロットが回帰式を示す。

図 4.5 に実測値と予測値のプロットを示す。横軸は熱伝達係数の実測値、縦軸は予測値である。ドットの色と誤差率の関係については前項と同様である。表 4.4 に平均絶対誤差 MAE, 二乗平均平方根誤差 RMSE, 平均絶対パーセント誤差 MAPE, 決定係数  $R^2$ , RMSE と MAE の比をそれぞれ示す。また、表 4.5 に回帰モデル式と各パラメータをまとめる。

表 4.4 より、単回帰分析と比べて予測精度が大幅に改善していることが分かる。平均絶対誤差は 367 減少し、平均絶対誤差は 6.43% 改善した。決定係数も 0.049 増加している。その一方で RMSE/MAE 比は増加しており、外れ値の存在が予測される。これは二乗平均平方根誤差からも同様のことが言える。二乗平均平方根誤差は線形回帰モデルに比べて減少しているが、平均絶対誤差ほどの減少ではなく、外れ値の影響を受けていることが分かる。

図 4.4 より、回帰式が熱伝達係数の実測値にどれだけフィッティングできているか確認することができる。単回帰分析では第 1 主成分得点の小さい領域や熱伝達係数が急激に増大する領域に対してフィッティングができていないのに対し、多項式回帰では曲線を用いることで上手くフィッティングできていることが分かる。図 4.5 から単回帰分析に比べ、2 次の多項式回帰モデルが熱伝達係数をより予測できていることが確認できる。図 4.3 との比較では、誤差率の小さい赤色のプロットが増え、誤差率の大きい青色のプロットが減少している。特に、第 1 主成分得点が小さい領域においては大幅な誤差率の改善が見られる。一方、熱伝達係数の大きい領域では、改善されないままである。これについては第 4.1.9 項にて後述する。

2 次の多項式回帰モデルを用いて熱伝達係数の予測を行った。単回帰分析に比べ、予測精度は大幅に改善されており、説明変数から目的変数を適切に表現できることが確認できた。

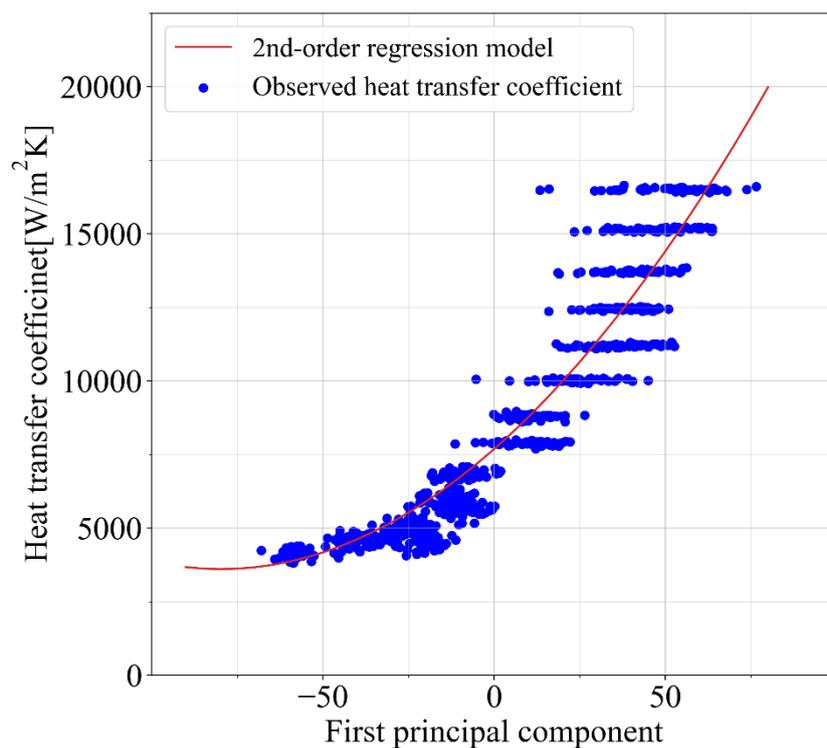


図 4.4 2 次の多項式回帰による熱伝達係数の推論

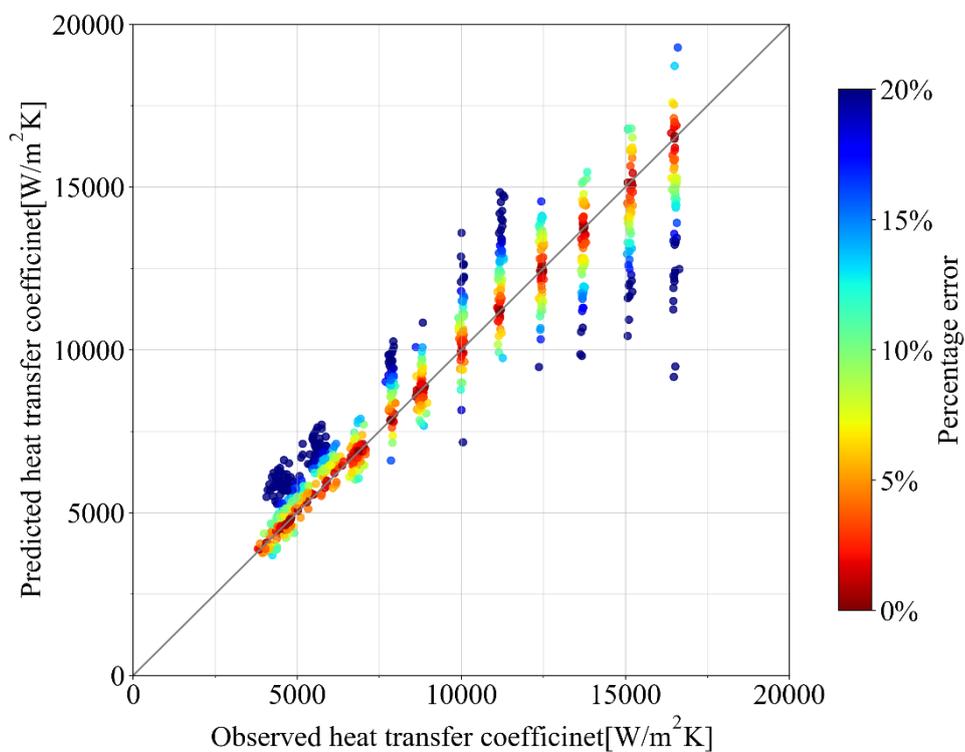


図 4.5 2 次の多項式回帰分析の実測値ー予測値プロット

表 4.4 2 次の多項式回帰分析の予測精度評価

平均絶対誤差MAE [W/(m <sup>2</sup> K)]	920
二乗平均平方根誤差RMSE[W/(m <sup>2</sup> K)]	1281
平均絶対パーセント誤差MAPE[%]	10.88
決定係数R <sup>2</sup>	0.896
RMSE/MAE	1.392

表 4.5 2 次の多項式回帰モデルパラメータ

回帰モデル： $y = w_0 + w_1x_1 + w_2x_1^2$	
$w_0$	7682
$w_1$	102.3
$w_2$	0.642

#### 4.1.6 非線形（3次）回帰分析による熱伝達係数の予測

本項では3次の多項式回帰を用いて熱伝達係数の予測を行う。

図 4.6 は3次の多項式回帰分析による熱伝達係数の推論である。図の横軸に第1主成分得点、横軸に熱伝達係数を示し、青色のプロットが実測値、赤色のプロットが回帰式を示す。図 4.7 に実測値と予測値のプロットを示す。横軸は熱伝達係数の実測値、縦軸は予測値である。プロットの色と誤差率の関係については前項と同様である。表 4.6 に平均絶対誤差MAE、二乗平均平方根誤差RMSE、平均絶対パーセント誤差MAPE、決定係数R<sup>2</sup>、RMSEとMAEの比をそれぞれまとめる。また、表 4.7 に回帰モデル式と各パラメータを示す。

表 4.6 より、2次の回帰モデルに比べて予測精度が改善されたことが分かる。しかし、前項で回帰モデルを線形回帰から多項式回帰に変更したほどの改善は得られなかった。さらに、図 4.6 の回帰式に着目し、この回帰モデルが熱伝達係数の予測に適したモデルであるか考察する。一般に機械学習の予測には内挿と外挿に分類される。内挿とは、機械学習のモデルにおいて、訓練データの数値の範囲内で出力を求めることであり、外挿とは範囲外の数値の出力を求めることを指す。内挿に対する予測精度は表 4.6 の評価指標の通りである。外挿に関しては、訓練データの範囲外の検証データが得られていないため、熱伝達係数の特性から考えられるケースについて検討する。外挿のうち主成分得点が-80 以降につ

いては、熱伝達係数が主成分得点の減少とともに減少することが予想される。それに対し、回帰式は主成分得点の減少とともに熱伝達係数が増加している。これは、データの範囲外では回帰モデルが熱伝達係数の予測モデルとして正常に機能しないことが予想される。主成分得点が高い方向の外挿については次のことが考えられる。過熱度が増加していくと核沸騰域では主成分得点とともに熱伝達係数は増加していく。その後、熱流束が極大値に達すると、熱伝達係数が低下する遷移沸騰領域に遷移する。蒸気泡の数や径が増大するほど主成分得点も増加することから、遷移沸騰領域や膜沸騰領域でも主成分得点が増大することが予想される。そのため、遷移沸騰領域の熱伝達係数を予測するには、遷移点の情報を含むデータ点が必要となる。しかし、データセットには遷移点の情報は含まれておらず、自然対流域と核沸騰域のみである。従って、本論文の回帰モデルを外挿となる遷移沸騰域や膜沸騰域の熱伝達係数の予測に用いることはできないことに注意しなければならない。

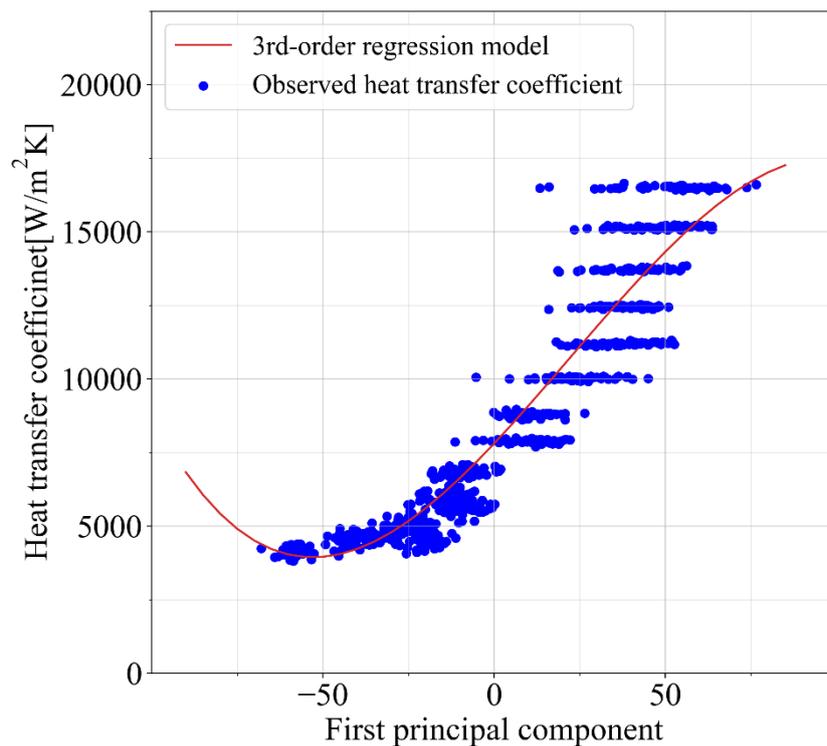


図 4.6 3 次の多項式回帰による熱伝達係数の推論

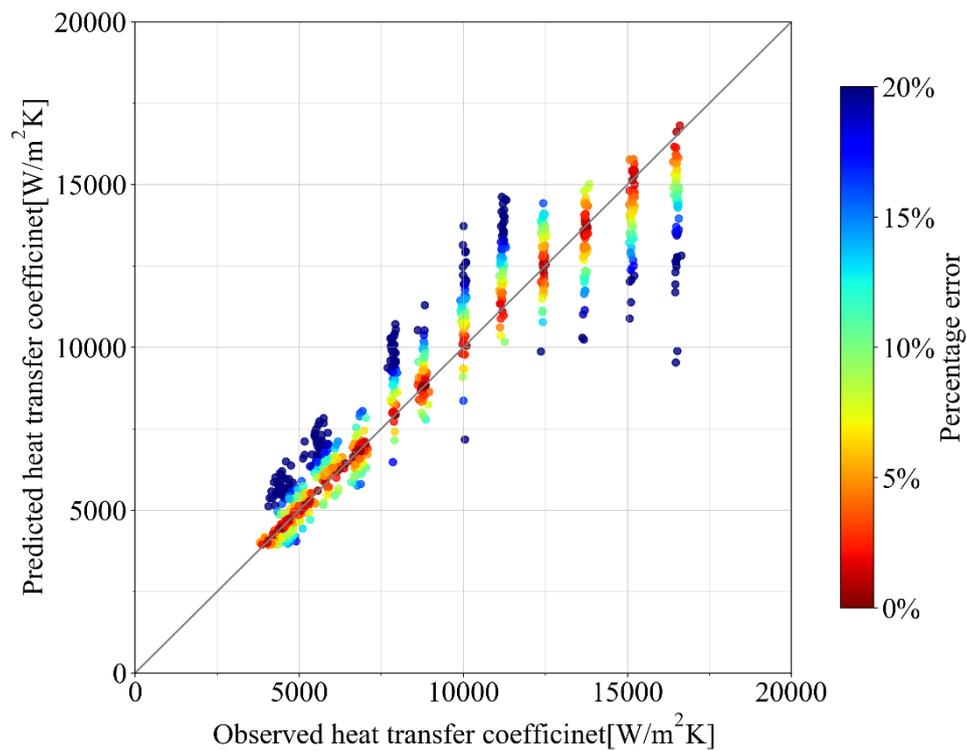


図 4.7 3 次の多項式回帰分析の実測値－予測値プロット

表 4.6 3 次の多項式回帰分析の予測精度評価

平均絶対誤差MAE [ $W/(m^2K)$ ]	910
二乗平均平方根誤差RMSE [ $W/(m^2K)$ ]	1255
平均絶対パーセント誤差MAPE[%]	10.47
決定係数 $R^2$	0.900
RMSE/MAE	1.379

表 4.7 3 次の多項式回帰モデルパラメータ

回帰モデル： $y = w_0 + w_1x_1 + w_2x_1^2 + w_3x_1^3$	
$w_0$	7801
$w_1$	123.6
$w_2$	0.534
$w_3$	$-7.996 \times 10^{-3}$

#### 4.1.7 熱伝達係数の過剰適合モデル

多項式回帰において次数を増やすことは予測精度の向上に繋がることが多い。その一方で、過度に複雑なモデルや訓練データの不足は過少適合や過剰適合の原因となる。本項では 10 次の多項式回帰を用いて予測精度と過剰適合について考察する。

図 4.8 は 10 次の多項式回帰分析による熱伝達係数の推論である。図の横軸に特徴量である第 1 主成分得点、横軸に熱伝達係数を示し、青色のプロットが実測値、赤色のプロットが回帰式を示す。図 4.9 に実測値と予測値のプロットを示す。横軸は熱伝達係数の実測値、縦軸は予測値である。プロットの色と誤差率の関係については前項と同様である。表 4.8 に平均絶対誤差 MAE, 二乗平均平方根誤差 RMSE, 平均絶対パーセント誤差 MAPE, 決定係数  $R^2$ , RMSE と MAE の比をそれぞれ示す。

表 4.8 から、10 次の多項式モデルの予測精度はすべての評価指標において、2 次・3 次の多項式モデルの予測精度を下回っていることが確認できる。これは 10 次の多項式モデルが説明変数と目的関数の関係を表すモデルとして適していないことを示している。データセットの個数や特徴量の個数に対し、モデルのパラメータの個数が過多であるとき、つまり、モデルの自由度が高すぎるときにデータに対する予測精度が低下する場合がある。回帰では学習データに共通する特徴から推論を行い、テストデータに対しても共通の特徴に基づいて予測を行う。しかし、モデルの自由度が高いときには全てのデータには共通しないような特徴に基づいて推論を行うことにより、学習データに対しての性能は向上するが、テストデータに対しては上手く予測ができなくなることがしばしばである。これが過学習や過剰適合と呼ばれる現象であり、図 4.8 から過剰適合が見て取れる。さらに、外挿については熱伝達係数の予測に全く適していないことも分かる。

本項では、10 次の多項式回帰モデルを用いて過剰適合や過学習について考察を行った。特徴量が第 1 主成分のみである本データセットに対しては 10 次の多項式モデルは過剰であり、予測精度と汎化性の保持のためには適切な次数の選択が必要であることが改めて確認された。

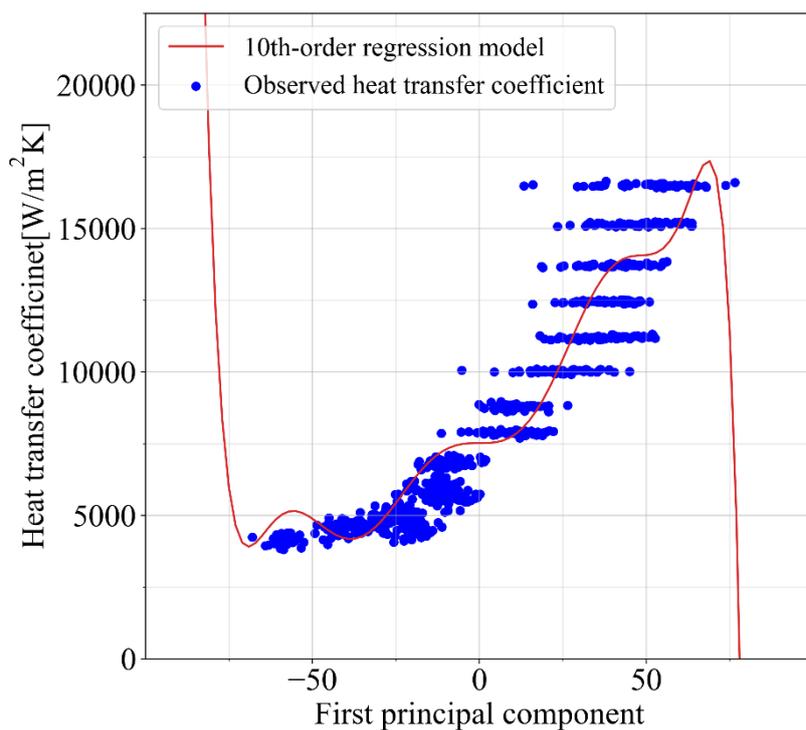


図 4.8 10 次の多項式回帰による熱伝達係数の推論

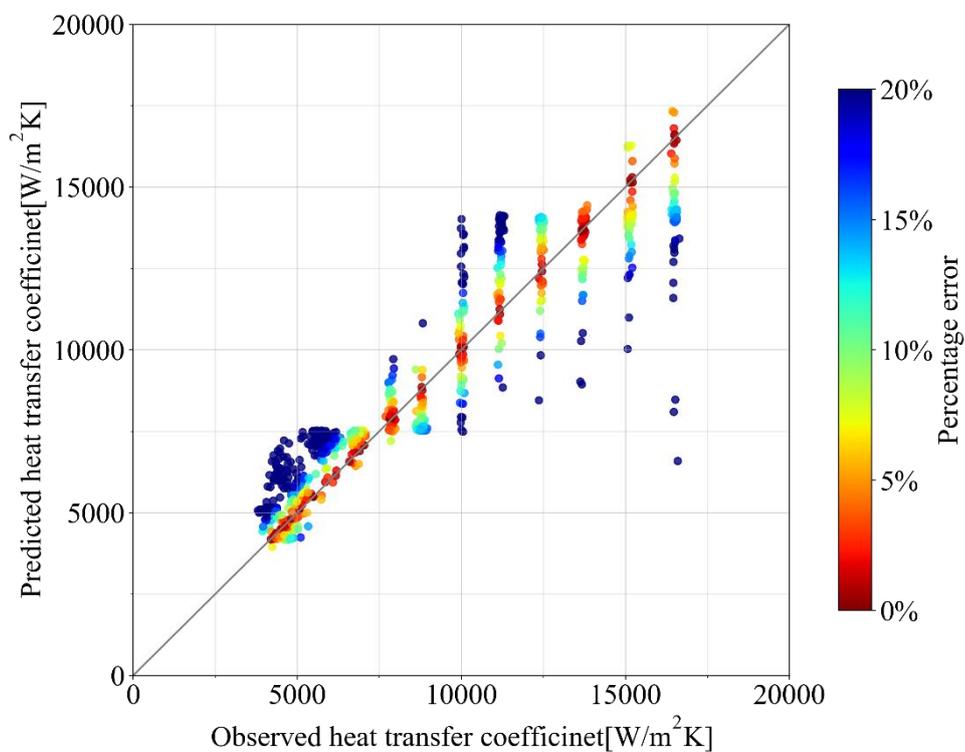


図 4.9 10 次の多項式回帰分析の実測値ー予測値プロット

表 4.8 10 次の多項式回帰分析の予測精度評価

平均絶対誤差MAE [W/(m <sup>2</sup> K)]	1099
二乗平均平方根誤差RMSE[W/(m <sup>2</sup> K)]	1453
平均絶対パーセント誤差MAPE[%]	13.80
決定係数R <sup>2</sup>	0.867
RMSE/MAE	1.322

#### 4.1.8 モデルの次数と予測精度

単回帰モデルと 2 次から 10 次までの多項式回帰モデルの平均絶対誤差と決定係数の比較を図 4.10 に示す。線形回帰から多項式回帰にかけて平均絶対誤差と決定係数ともに大きく改善しているが、それ以降はほぼ横ばい状態であり、前項で述べた通り 10 次の回帰モデルでは過剰適合が確認された。このことから、次数を増やすことだけで予測精度のこれ以上の向上を見込むことは難しいことが分かる。

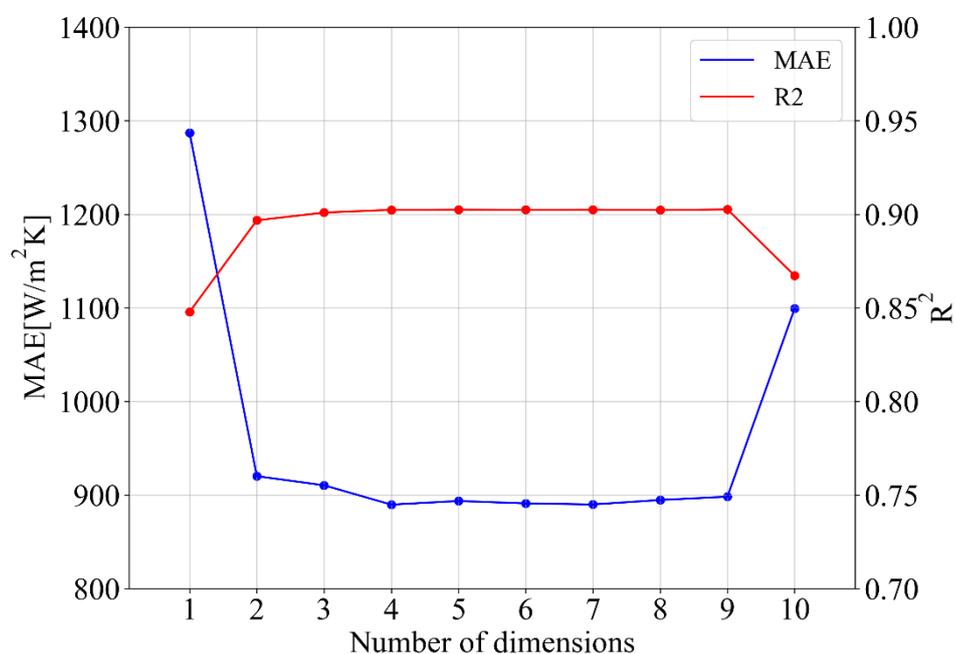


図 4.10 次数の異なる回帰モデルの平均絶対誤差と決定係数の比較

#### 4.1.9 平均化による予測誤差の改善

本項では熱伝達係数の大きい領域における誤差の改善を行う。第 4.1.5 項でも述べたよ

うに、熱伝達係数の大きい領域においては次数の大きさに関係なく誤差が大きくなっている。これに関しては、説明変数と目的変数の不一致に原因があると考えられる。図 4.1 のうち、熱伝達係数が 17000 付近のデータに着目する。熱伝達係数はほぼ一定であるのに対し、説明変数である第一主成分得点は 25 から 75 付近まで幅広いデータセットであることが確認できる。これは他の核沸騰域のデータにも当てはまっており、誤差を減らすためには改善が不可欠である。図 4.11 に電流値 38A の主成分データセットを主成分得点の大きさごとにまとめたヒストグラムを示す。横軸は 5 ごとの主成分得点の階級であり、縦軸はその度数である。図 4.11 より主成分得点の分布は対称的であり、50~60 の主成分得点を中心としていることが分かる。また、誤差の原因である外れ値の度数は小さい。この外れ値が現れる箇所を確認するため、この主成分得点データを時系列順に並べたものを図 4.12 に表す。横軸は時間であり、縦軸は主成分得点である。これを見ると外れ値は連続的に現れているのではなく瞬時的であることが確認できる。さらに、これらの主成分得点が小さいデータは蒸気泡の径や数が小さいことが図 4.13 の観測画像から分かる。蒸気泡の発生と発散は非常に高速であり、瞬間的にキャプチャ内の蒸気泡が極端に少なくなったことがこの外れ値の原因であると推測ができる。

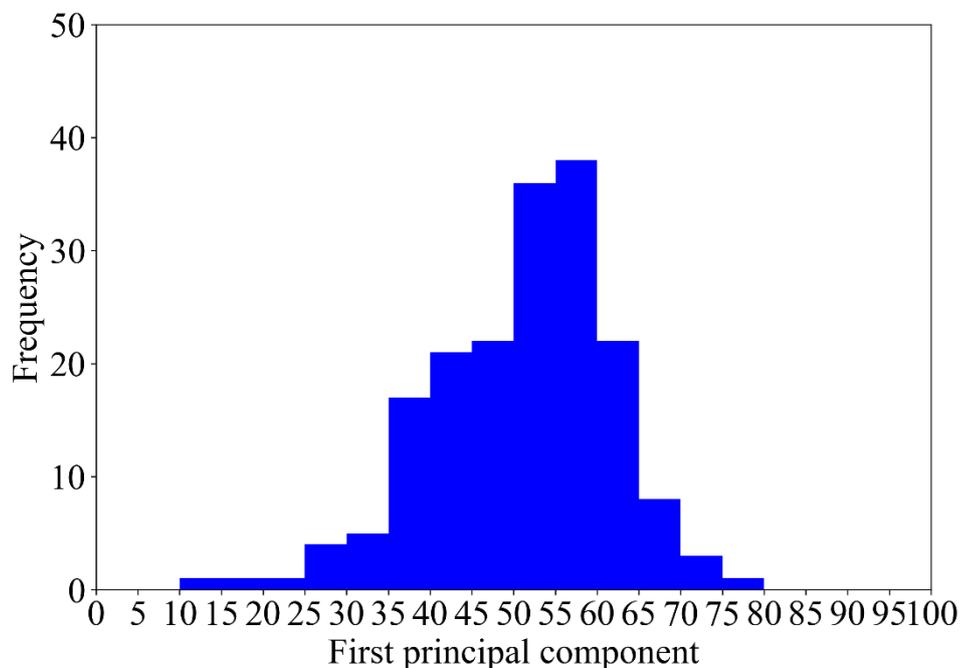


図 4.11 主成分得点のヒストグラム

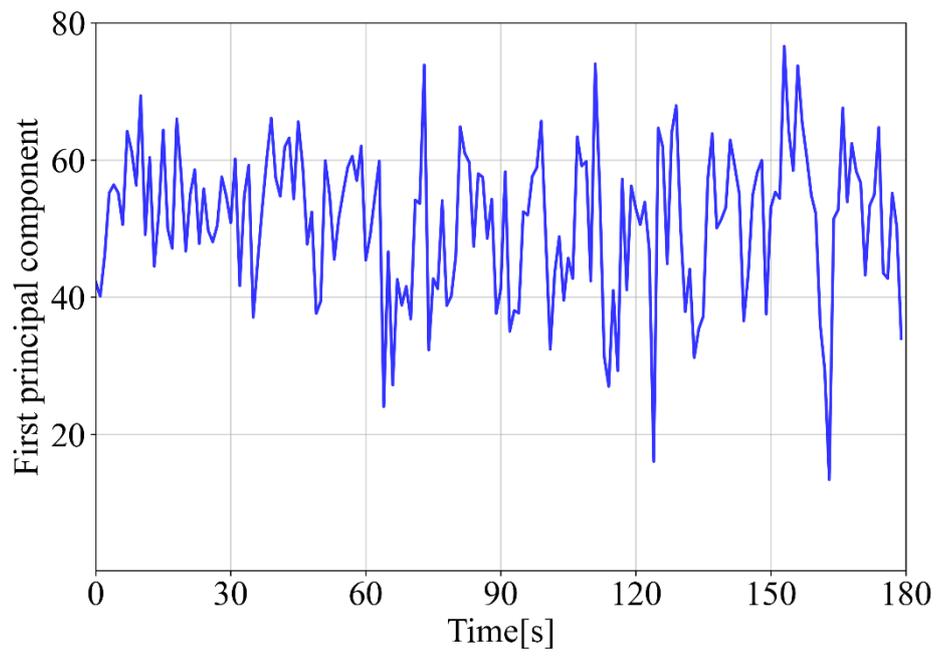
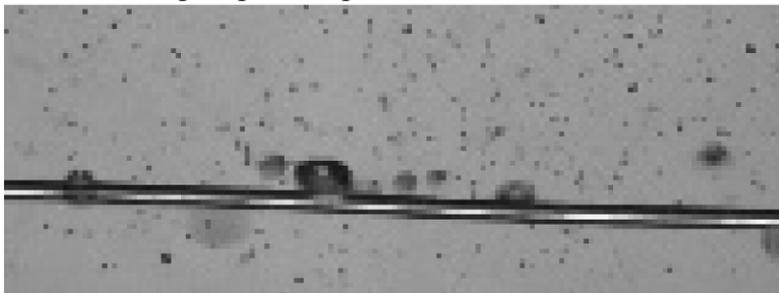


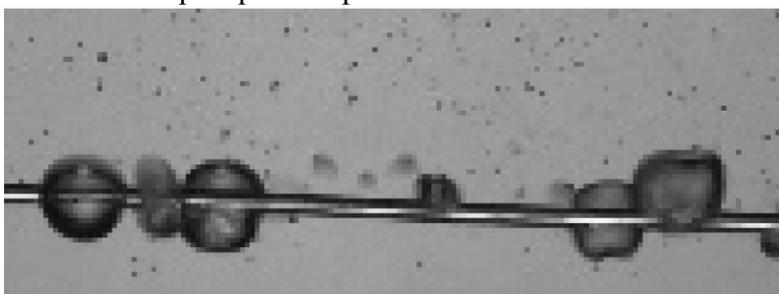
図 4.12 主成分得点の時系列プロット

pricipal component score = 13.39



(a) 主成分得点=13.39

pricipal component score = 50.28



(b) 主成分得点=50.28

図 4.13 主成分得点比較

蒸気泡を制御することで主成分得点を一定に保つことは難しい。しかし、外れ値の主成分得点が現れるのは離散的であるので、熱伝達係数の推定値に平均値を用いることで予測精度の改善を図ることが可能であると考えられる。ここでは時系列順に並んだ $t-4$ 番目から $t$ 番目までの5秒間のテストデータとその熱伝達係数の実測値を1つのテストデータとする。それに伴い、学習データにも同様の処理を施し、回帰式の推定を行った。回帰モデルは第4.1.5項の2次の多項式回帰モデルを用いる。

図4.14は平均化を施したデータセットを用いた2次の多項式回帰分析による熱伝達係数の推論である。図の横軸に特徴量である第1主成分得点、横軸に熱伝達係数を示し、青色のプロットが実測値、赤色のプロットが回帰式を示す。図4.15に実測値と予測値のプロットを示す。横軸は熱伝達係数の実測値、縦軸は予測値である。表4.9に平均絶対誤差MAE、二乗平均平方根誤差RMSE、平均絶対パーセント誤差MAPE、決定係数 $R^2$ 、RMSEとMAEの比をそれぞれ示す。

表 4.9 より，平均化を行っていない予測結果に比べて，予測精度がすべての指標において格段に向上していることが分かる．図 4.14 から，テストデータの外れ値の個数が減少しており，予測精度の向上が平均化によるものであることが確認できる．さらに，学習データにも同様の処理を行っているため，学習データの外れ値が減少していることが予想でき，回帰式の推論の際にも外れ値の影響が少なくなっていることが推測できる．また，図 4.5 と図 4.15 の比較から熱伝達係数の誤差率が小さくなっていることが分かる．平均化を施していないデータセットを用いた 2 次の多項式回帰分析において誤差率が 20% を超える予測結果は全テストデータの 15% であったのに対し，平均化を施したデータセットを用いた 2 次の多項式回帰分析において誤差率が 20% を超える予測結果は 10% であった．

熱伝達係数の予測誤差を改善するために原因の考察とデータセットの平均化を行った．データセットの平均化を行うことで大きい誤差率を持つ予測結果を大幅に削減できることが確認でき，予測精度を格段に向上させることができた．

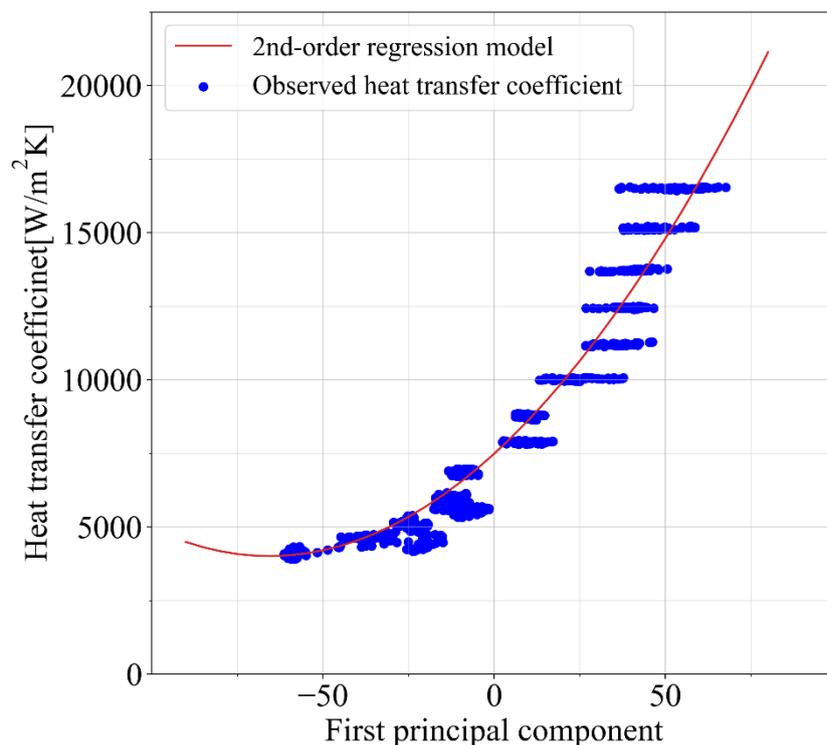


図 4.14 平均熱伝達係数データセットを用いた多項式回帰による熱伝達係数の推論

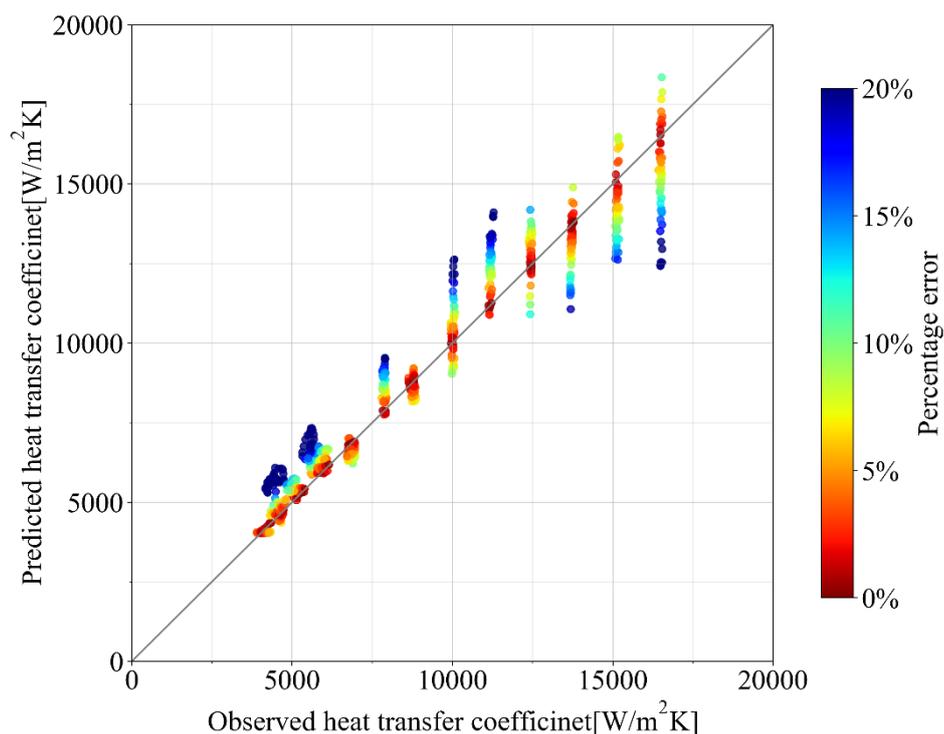


図 4.15 平均熱伝達係数データセットを用いた多項式回帰分析の実測値—予測値プロット

表 4.8 平均熱伝達係数データセットを用いた多項式回帰分析の予測精度評価

平均絶対誤差MAE [W/(m²K)]	689
二乗平均平方根誤差RMSE[W/(m²K)]	956
平均絶対パーセント誤差MAPE[%]	8.15
決定係数R <sup>2</sup>	0.942
RMSE/MAE	1.387

## 4.2 畳み込みニューラルネットワーク (CNN) による熱伝達係数の予測

### 4.2.1 順伝播型ニューラルネットワーク

ニューラルネットワークとは生物の神経回路網を模した人工ニューロンであり、Warren S. McCulloch と Walter Pitts によって提唱された<sup>[16]</sup>。人工ニューロンは1つ以上のバイナリ入力と1つのバイナリ出力を持つ。これらが隣接層間でのみ結合した構造を持ち、情報が入力側から出力側へ一方向に伝播するニューラルネットワークのことを順伝播型ニューラ

ルネットワーク (Feedforward neural network) と呼ぶ。順伝播型ニューラルネットワークは最も基本的かつ最も使われているニューラルネットワークである。ネットワークを構成するユニットは図 4.16 の構造で表され、先に述べたように複数の入力を受け取り、1 つの出力を出力する。図 4.16 の場合、3 つの入力  $x_1$ ,  $x_2$ ,  $x_3$  を受け取り、総入力  $u$  は式 4.16 で表される。

$$u = w_1x_1 + w_2x_2 + w_3x_3 + b \quad (4.16)$$

$w_1$ ,  $w_2$ ,  $w_3$  は各入力に掛けられる重みであり、 $b$  はバイアス (重み) である。この総入力  $u$  に対する活性化関数を  $f$  とすると、ユニットの出力  $z$  は式 4.17 のように表される。

$$z = f(u) \quad (4.17)$$

順伝播型ネットワークでは図 4.17 のようにユニットが層状に並べられ、層間で結合を持つ。左の層の三つのユニットは右の層のそれぞれのユニットの入力となり、右のユニットが受け取る入力 は式 4.18, 4.19, 4.20 となる。

$$u_1 = w_{11}x_1 + w_{12}x_2 + w_{13}x_3 + b_1 \quad (4.18)$$

$$u_2 = w_{21}x_1 + w_{22}x_2 + w_{23}x_3 + b_2 \quad (4.19)$$

$$u_3 = w_{31}x_1 + w_{32}x_2 + w_{33}x_3 + b_3 \quad (4.20)$$

ユニットの出力は活性化関数を適用したものとなる。

図 4.18 のように複数の層で構成されるネットワークのことを多層ネットワークと呼ぶ。最も左の層を入力層、最も右の層を出力層と呼ぶ。その間の層は中間層、あるいは隠れ層と呼ばれる。順伝播型を含むニューラルネットワークは層の数を増やすことで表現の柔軟性を高めることができる。

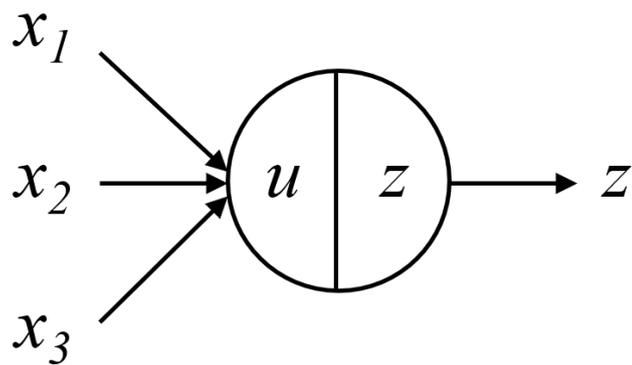


図 4.16 ユニット構造

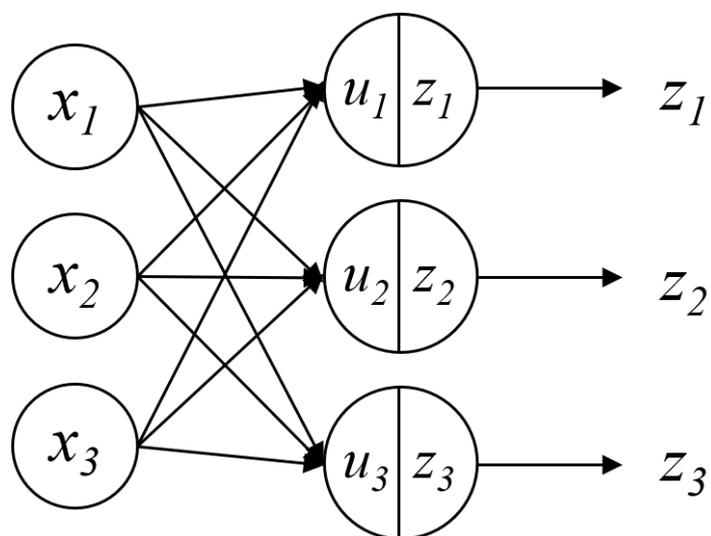


図 4.17 層状ネットワーク

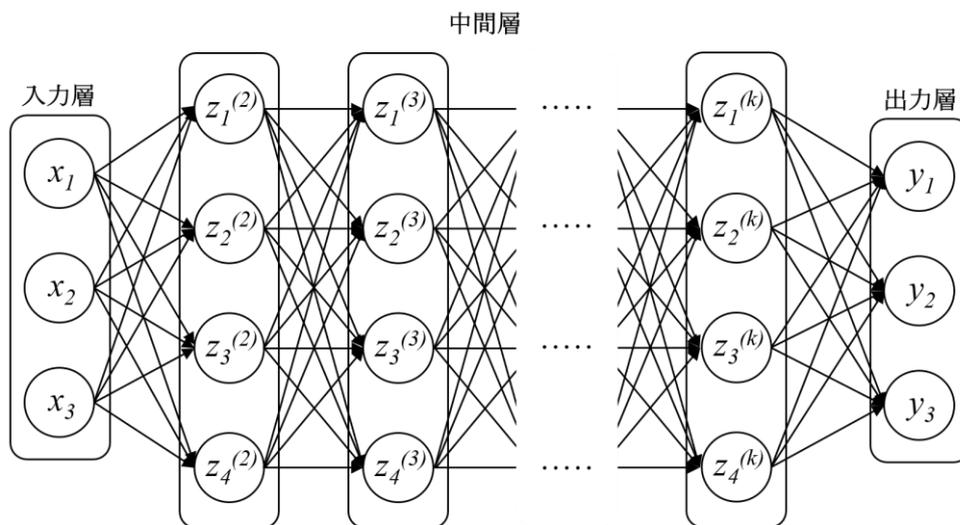


図 4.18 隠れ層を含む多層ネットワーク

#### 4.2.2 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional neural network) は、畳み込み層とプーリング層という特別な二種類の層を持つ順伝播型ネットワークのことであり、画像認識の分野で活用されている。図 4.19 に畳み込みニューラルネットワークの構造の例を示す。一般の順伝播型ネットワークの持つ全結合層に加え、畳み込み層とプーリング層を持つ。プーリング層は畳み込み層の後に続くことが多く、このペアが複数回繰り返される。また、畳み込み層は続けて配置されることもある。

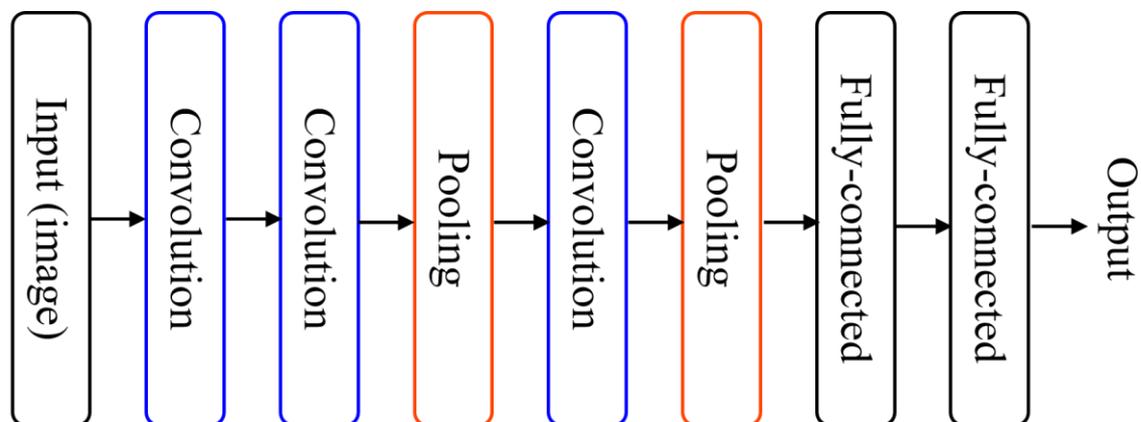


図 4.19 畳み込みニューラルネットワーク

畳み込み層は画像に含まれる特徴を抽出するための層である．ここでは例として画像サイズ  $W \times W$  のグレイ画像への畳み込み演算を示す． $i$  行  $j$  列目の画素は  $x_{ij}$  で表される．画像の畳み込みでは， $H \times H$  のフィルタを用いて畳み込み演算を行う．フィルタの画素も画像の画素と同じく  $h_{pq}$  のように表される．

畳み込み層で行われる畳み込み演算は式 4.21 で定義される積和演算である．

$$u_{ij} = \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} x_{i+p, j+q} h_{pq} \quad (4.21)$$

畳み込みニューラルネットワーク内の畳み込み演算は実際には相互相関関数であるが，実質的な違いはない．畳み込み演算は前述の通り，フィルタの濃淡パターンと類似した入力画像の濃淡パターンを抽出する働きをする．

ここで  $W = 8$ ,  $H = 3$  のときの畳み込み演算を実際に行う．図 4.20 は入力画像とフィルタの例であり，画素数は正規化されたものである．入力画像は丸印であり，フィルタは右上から左下への斜め線のパターンとした．積和演算は式 4.21 の通りであり，入力画像の左上から右下へとフィルタをずらしながら内積を計算する．この例ではストライドの大きさは 1 であるが，入力画像やフィルタの大きさによって調節されることが多い．畳み込み演算の結果を図 4.21 に示す．積和計算によって新しく出力された画像はマップとも呼ばれ，この例では  $6 \times 6$  のマップが生成されている．また，フィルタの濃淡パターンと一致しているほどマップの値が大きくなる．この場合，フィルタと入力画像の濃淡パターンが一致する場所は入力画像の左上と右下であると分かるが，マップの値の大きさもそれに準じた結果となっており，フィルタが濃淡パターンを抽出していることが確認できる．

入力画像とフィルタによって生成されたマップは重みがつけられた後，活性化関数に適用され，その値が最終的な出力となる．この活性化関数には **Relu** 関数が用いられることが多い．さらに，畳み込み層はバイアスが全ユニットで共有される重み共有などの特徴を持つ．

0	0	0	0	0	0	0	0
0	0	0.5	1	1	0.5	0	0
0	0.5	1	0	0	1	0.5	0
0	1	0	0	0	0	1	0
0	1	0	0	0	0	1	0
0	0.5	1	0	0	1	0.5	0
0	0	0.5	1	1	0.5	0	0
0	0	0	0	0	0	0	0

0	0.5	1
0.5	1	0
1	0	0

図 4.20 入力画像とフィルタ

0	0	0	0	0	0	0	0
0	0	0.5	1	1	0.5	0	0
0	0.5	1	0	0	1	0.5	0
0	1	0	0	0	0	1	0
0	1	0	0	0	0	1	0
0	0.5	1	0	0	1	0.5	0
0	0	0.5	1	1	0.5	0	0
0	0	0	0	0	0	0	0

 $\otimes$ 

0	0.5	1
0.5	1	0
1	0	0

 $=$ 

0	1	2.25	1.5	1	1.25
1	3.5	1.5	1	1.25	1
2.25	2	0	1	1	1.25
1.5	1	1	0	1	2.5
1	1.25	1	1	3	2
1.25	1	1.25	2.5	2	0.5

図 4.21 特徴マップ

次に、プーリング層について述べる。プーリング層は入力画像におけるフィルタの形状の位置ずれを吸収するような機能を持つ。プーリング層では入力画像または入力マップ上で画素 $(i, j)$ を中心とする $H \times H$ の正方領域をとり、その領域に含まれる画素数の最大値や平均値を出力とする計算が行われる。

図 4.22 の出力マップを用いて最大プーリングの例を示す。プーリングサイズ $2 \times 2$ 、ストライドは2である。図 4.22 に計算結果を示す。プーリングによる位置ずれの吸収は確認することができないが、入力マップの特徴は保持されている。プーリング層のユニットには活性化関数を適応することは少なく、プーリングの結果がそのままプーリング層の出力となることがほとんどである。

0	1	2.25	1.5	1	1.25
1	3.5	1.5	1	1.25	1
2.25	2	0	1	1	1.25
1.5	1	1	0	1	2.5
1	1.25	1	1	3	2
1.25	1	1.25	2.5	2	0.5

→

3.5	2.25	1.25
2.25	1	2.5
1.25	2.5	3

図 4.22 最大プーリング

これらの畳み込み層やプーリング層を組み合わせた畳み込みネットワークは、画像認識のコンペティションで数多くの優秀な成績を修め、画像認識の分野において高い精度を実現している。

#### 4.2.3 ニューラルネットワークの最適化アルゴリズム

回帰分析では最小二乗法を用いてパラメータの最適化を行った。ニューラルネットワークでも二乗誤差が小さくなるようにパラメータの最適化を行うが、回帰分析に比べてパラメータの数は膨大であり、局所最適解に陥ることがしばしばである。また、計算量も莫大になる。この局所解問題を解決するために、確率的勾配降下法 (SGD) や Momentum SGD, RMSprop など様々な探索アルゴリズムが提案されている。その中でも、Adam (Adaptive moment estimation) は最適化アルゴリズムとして採用されることが多く、本節でもこのアルゴリズムを用いてパラメータの最適化を行う。Adam とは RMSprop と Momentum SGD の手法を組み合わせることで、それぞれのデメリットを改善したアルゴリズムである。その改善点としては、勾配の二乗平均と平均を 1 次モーメント、2 次モーメントとすることで次元量の問題に対処している点が挙げられる。また、ハイパーパラメータのデフォルト値は表 4.9 の通りである。

表 4.9 ハイパーパラメータ

$\eta$	0.001
$\beta_1$	0.9
$\beta_2$	0.999
$\varepsilon$	$1 \times 10^{-7}$

Adam は適応学習率アルゴリズムであるため、学習率 $\eta$ を調整する必要は少なく、デフォルトの値を使えることが多い。  $\beta_1$ は運動量減衰のハイパーパラメータ、  $\beta_2$ はスケールリング減衰ハイパーパラメータであり、ともに移動平均の減衰に関するハイパーパラメータである。これらのハイパーパラメータは1に近いほど減衰率は小さい。  $\varepsilon$ はゼロ除算を避けるために設けられる極めて小さい値であり、計算結果にも影響を及ぼさない程度の値を設定する。

#### 4.2.4 熱伝達係数予測モデルの構築

畳み込みニューラルネットワークを用いて、熱伝達係数を予測するためのモデルを構築する。熱伝達係数予測モデルの構造を図 4.23 に示す。入力層では $160 \times 160$ の画像データを、形状を保ったまま直接入力する。前節の回帰モデルでは入力画像を主成分分析により変換したデータを説明変数としていたが、畳み込みニューラルネットワークモデルでは画像データの形状を保ったまま入力することが可能である。実験により得られた観測画像のサイズは縦 60 ピクセル、横 160 ピクセルであるが、畳み込みニューラルネットワークへの入力画像は正方サイズが好ましいことが多い。そこで観測画像の上下に黒のふちをつけて画像サイズを $160 \times 160$ にリサイズしている。次に畳み込み層を 2 層続けて配置している。1層目の畳み込み層は $5 \times 5$ のフィルタが 8 枚、ストライドは 2、活性化関数は Relu 関数である。2層目の畳み込み層は $3 \times 3$ のフィルタが 16 枚、ストライドは 1、活性化関数は Relu 関数である。さらに、畳み込み層の後ろにはプーリング層が続く。このプーリング層では最大プーリングを適用し、プーリングサイズは $2 \times 2$ 、ストライドは 2 とした。その後は、Flatten 層により 16 次元のデータを 1 次元のデータに変換した後、全結合層が 3 つ配置され、最終層では熱伝達係数の予測値が出力される。また、過学習を防ぐためにプーリング層と全結合層の間に Dropout 層を挿入している。この予測モデルの総パラメータ数は

23,882,513 個である.

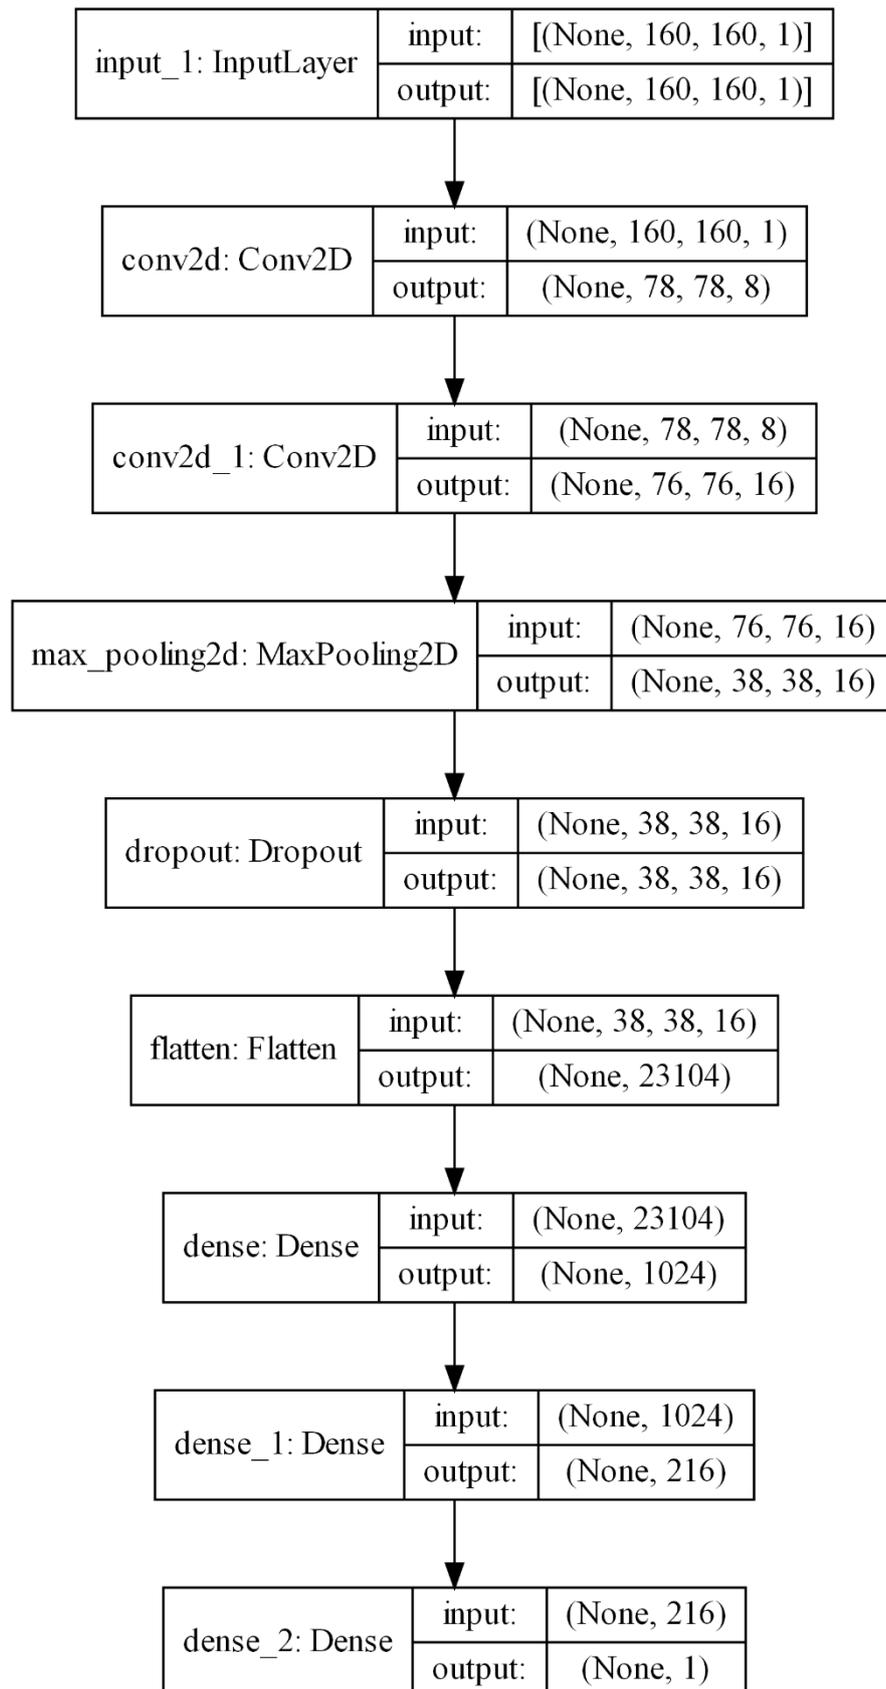


図 4.23 熱伝達係数予測モデル

#### 4.2.5 畳み込みニューラルネットワークによる熱伝達係数の予測

本項では畳み込みニューラルネットワークを用いて熱伝達係数の予測とその考察を行う。全データセットを回帰分析と同様、学習用のデータセット 1800 個とテスト用のデータセット 900 個に振り分けた。モデルの学習はエポック数を 50、バッチサイズを 16 として行った。また、学習用のデータセットは学習ごとに 80%が訓練用に、20%が検証用に分けられる。ニューラルネットワークを含む深層学習の短所として学習に時間を要することが挙げられるが、本モデルの学習時間は7分11秒を要した。

図 4.24 は損失関数の推移の様子である。横軸は学習の回数であり、縦軸は損失の大きさである。損失が小さくなるにつれて予測モデルの精度が向上していることを示す。図 4.25 には回帰分析と同様に実測値と予測値のプロットを示す。また、表 4.10 は予測モデルの精度指標であり、これも回帰分析と同様のものである。

図 4.24 より、学習回数を重ねるにつれて損失が減少していることが確認できる。このことから畳み込みニューラルネットワークによる熱伝達係数の予測が可能であると考えられる。また、過学習の特徴である損失値の再増加や学習用のデータと検証用のデータに対する損失値の大きな乖離も起こっていない。表 4.10 のテストデータに対する予測精度指標を見ると、平均絶対誤差は 720、二乗平均平方根誤差は 951、平均絶対誤差は 8.39%である。精度指標の点からは回帰分析で最も精度指標の良かったモデルよりも非常に高い精度で予測ができていることが分かる。図 4.25 からも畳み込みニューラルネットワークの予測精度の高さが見て取れ、回帰分析ほど誤差率の分布にばらつきが見られない。全テストデータのうち、誤差率が 20%を上回る予測結果が占める割合は 5.4%であり、回帰分析に比べ予測精度が大幅に改善されていることがこのことから分かる。

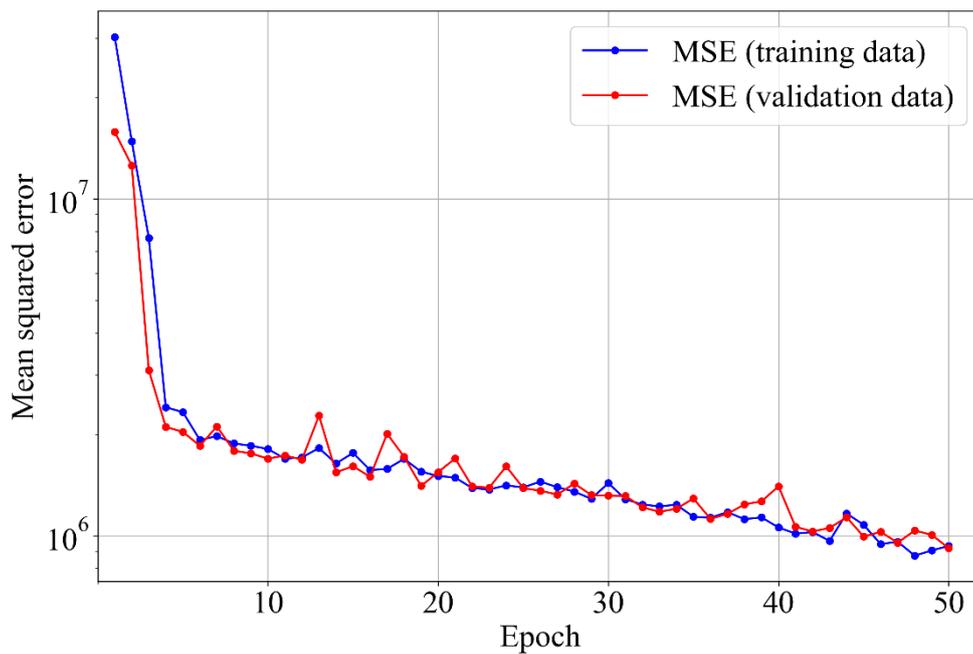


図 4.24 学習の推移

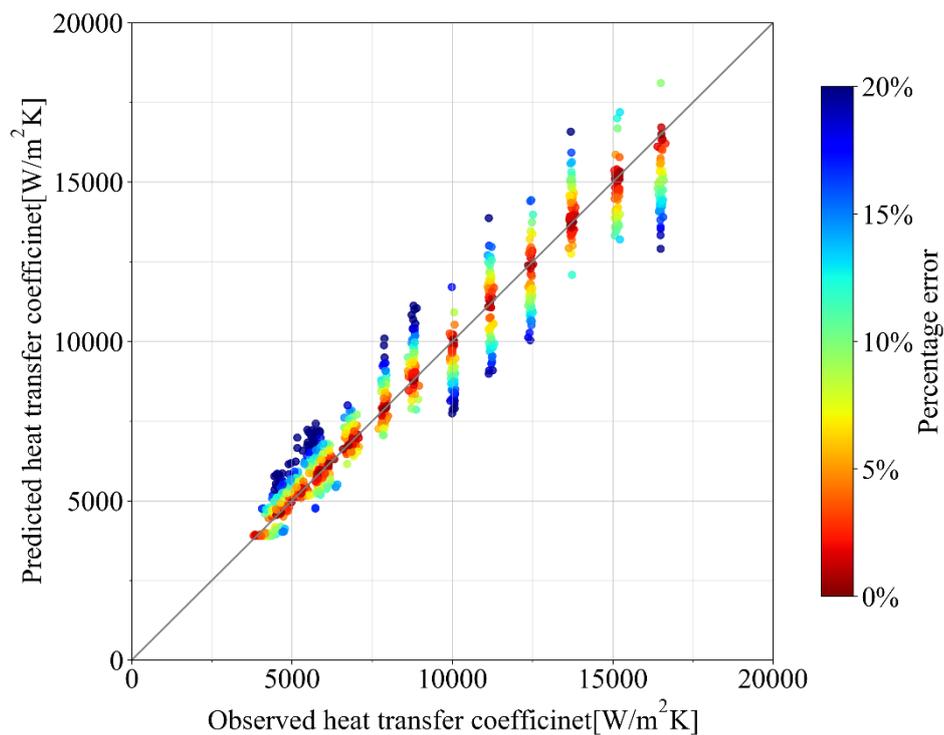


図 4.25 畳み込みニューラルネットワークの実測値ー予測値プロット

表 4.10 畳み込みニューラルネットワークの予測精度評価

平均絶対誤差MAE [W/m <sup>2</sup> K]	720
二乗平均平方根誤差RMSE[W/m <sup>2</sup> K]	951
平均絶対パーセント誤差MAPE[%]	8.39
決定係数R <sup>2</sup>	0.943
RMSE/MAE	1.320

回帰分析では熱伝達係数の予測値の平均を取ることで予測精度の向上を図ることができた。そこで、畳み込みニューラルネットワークでも予測値の平均化による予測精度の向上を試みる。平均化の方法は第 4.1.9 項と同じく、 $t$  番目の熱伝達係数を  $t - 4$  番目から  $t$  番目までの予測値の平均で表す。

図 4.26 に実測値と予測値のプロットを示す。横軸は熱伝達係数の実測値、縦軸は予測値である。表 4.11 に平均絶対誤差MAE、二乗平均平方根誤差RMSE、平均絶対パーセント誤差MAPE、決定係数R<sup>2</sup>、RMSEとMAEの比をそれぞれ示す。

図 4.26 より、高い誤差率を示す青色のドットが著しく減少していることが分かる。20%を上回る誤差率は全体の 2.4%であり、先の畳み込みニューラルネットワークと比べても大きな改善である。表 4.11 の精度指標も改善が見られ、特に誤差の分布を表すRMSE/MAEの比は 1.277 と正規分布に近づいている。

熱伝達係数の予測値を時系列間の平均値とすることは回帰分析・畳み込みニューラルネットワークの双方で予測精度の向上に繋がった。平均化が予測精度を向上させた要因として第 4.1.9 項でも述べた通り、蒸気泡の生成から離散までの速度が挙げられる。蒸気泡の生成から離散までは非常に高速かつ発生場所も任意でないため、すべての画像内の蒸気泡の数が等しくなることはなく、同じ熱伝達係数を持つデータ画像の中にも蒸気泡の数にばらつきが生じた。特に、本章のデータセットは 1 秒ごとの熱伝達係数とその画像のペアであるため、ばらつきによる予測への影響は大きかったと考えられる。このばらつきによる予測精度への影響は平均化のほかに、時系列データを扱うことができる再帰型ニューラルネットワークを使用することで対処に期待ができる。また、1 秒毎の熱伝達係数に対し、その間の画像を複数用意し、予測値をその平均とすることでもばらつきの影響を軽減させることが可能であると考えられる。

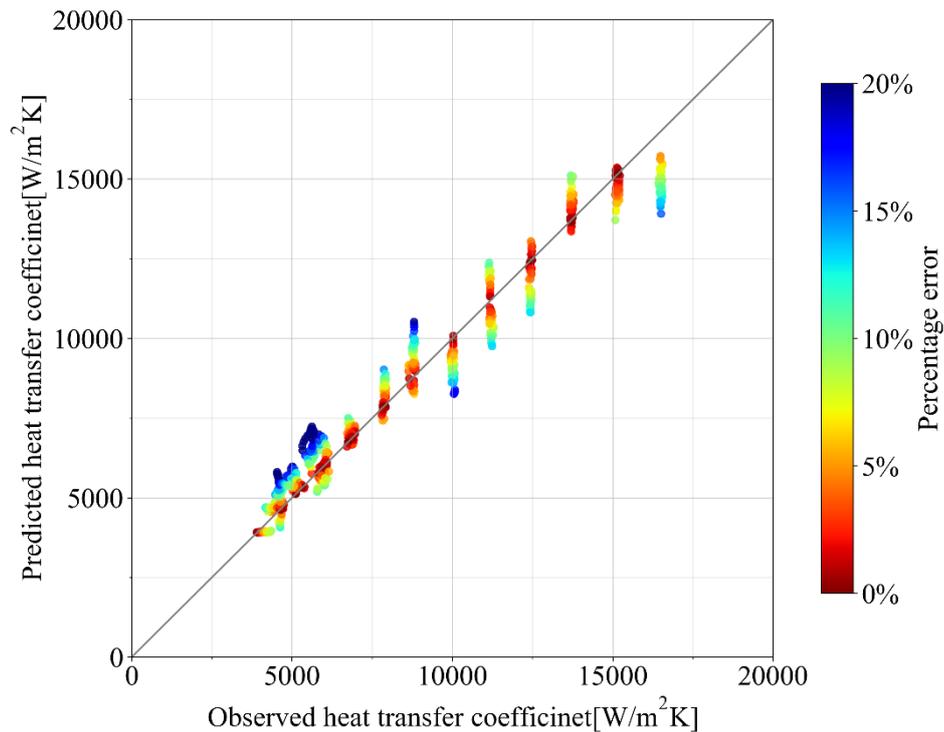


図 4.26 平均熱伝達係数データセットを用いた畳み込みニューラルネットワークの実測値—予測値プロット

表 4.11 平均熱伝達係数データセットを用いた畳み込みニューラルネットワークの予測精度評価

平均絶対誤差MAE [W/m <sup>2</sup> K]	591
二乗平均平方根誤差RMSE[W/m <sup>2</sup> K]	755
平均絶対パーセント誤差MAPE[%]	7.15
決定係数R <sup>2</sup>	0.964
RMSE/MAE	1.277

#### 4.2.6 畳み込みフィルタと特徴マップの可視化

畳み込みニューラルネットワークのフィルタは画像の特徴的な濃淡パターンを抽出する役割を持っているが、畳み込み層を重ねるほど、そのフィルタを解釈することは難しくなる。そこで、最も浅い畳み込み層に絞ってフィルタを可視化することで、その解釈を試み

る。特徴マップにも同様のことが言えるため、最も浅い特徴マップのみを可視化する。

図 4.27 に第 1 層の畳み込みフィルタを示す。フィルタの数は 8 枚である。重みは正に限らず、負の値もとるが、標準化を行いグレースケールに変換している。フィルタ 1, 2, 7 に関しては白と黒が散布しており、全体的にぼやけた印象になっている。それ以外のフィルタは濃淡に方向性があるように見え、画像から濃淡のパターンを抽出していることが考えられる。これらのフィルタとその特徴マップから畳み込みが如何にして熱伝達の情報を読み取っているのかを考察する。

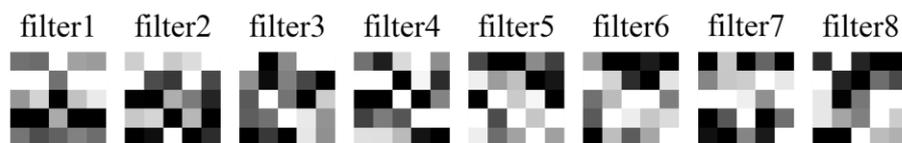
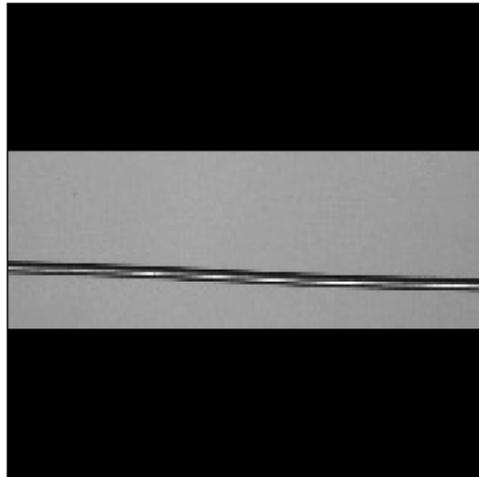


図 4.27 畳み込みフィルタ

まず、熱伝達係数が小さい自然対流域の観測画像の特徴マップについて考察する。図 4.28 に観測画像とその特徴マップを示す。特徴マップは畳み込みフィルタと同じ 8 枚である。この観測画像の熱伝達係数の実測値は 4909、予測値は 4783 であった。

図 4.28(b)中の特徴マップのほとんどは、白金線の濃淡パターンに対して、その特徴を抽出しているように見える。ただし、白金線の濃淡が熱伝達に関する情報を保持しているとは言い難い。しかし、特徴マップのいくつかは周囲流体の濃淡に対して反応しているように見られ、熱伝達の情報である周囲流体の動きを読み取っていると考えられる。

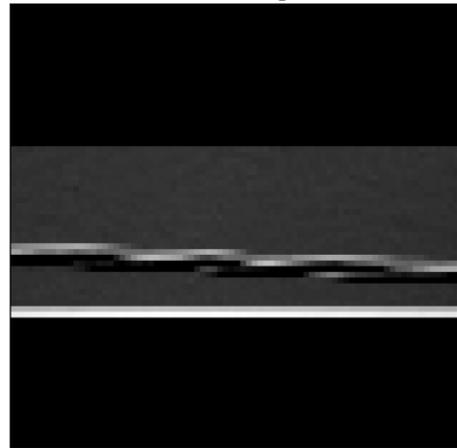


(a) 観測画像

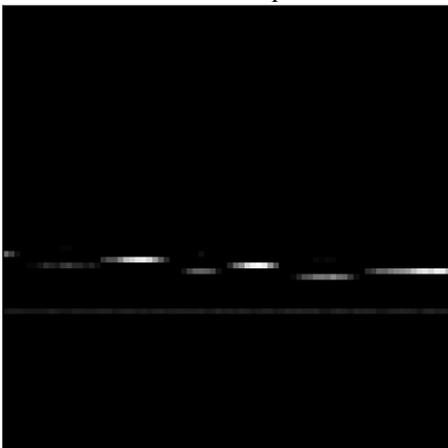
feature map 1



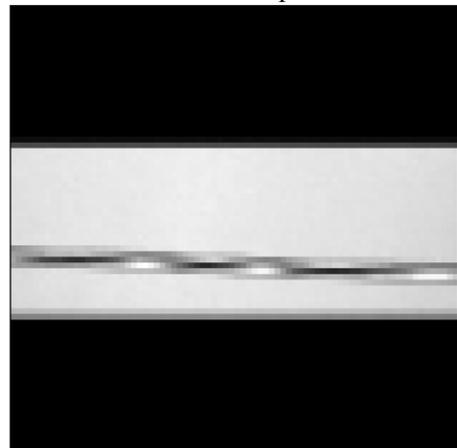
feature map 2

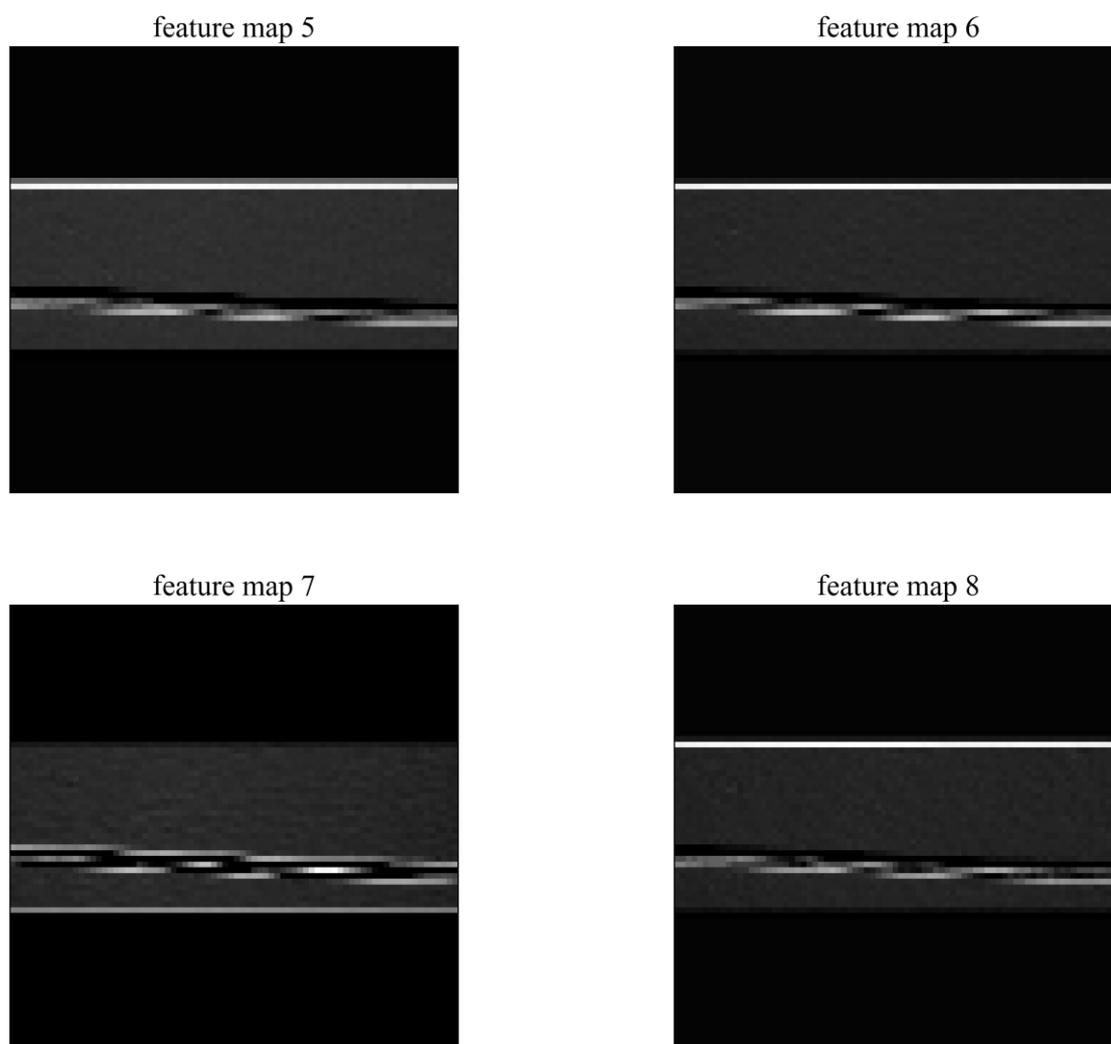


feature map 3



feature map 4



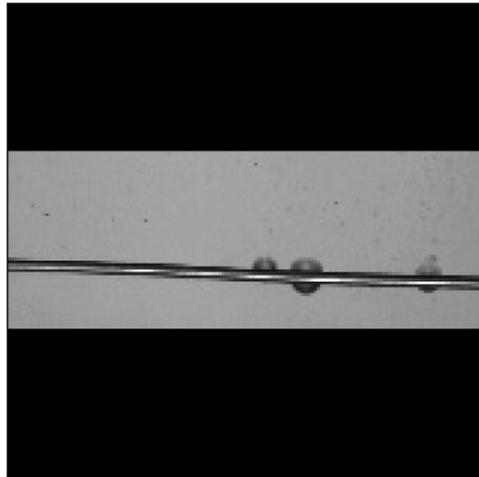


(b) 特徴マップ

図 4.28 自然対流領域の観測画像および特徴マップ

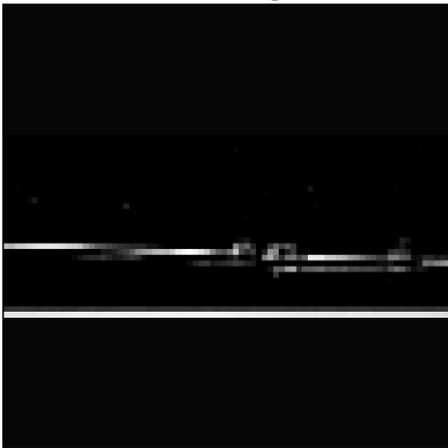
次に、初期の核沸騰領域の観測画像の特徴マップについて考察を行う。図 4.29 は、図 4.28 と同じく、観測画像と 8 枚の特徴マップを表す。観測画像の熱伝達係数実測値は 8792、予測値は 8900 であった。

図 4.29 の観測画像には蒸気泡が含まれており、特徴マップにも蒸気泡に関する情報が含まれていることが確認できる。特に、蒸気泡と周囲流体の境界に対して、フィルタが強く反応し、蒸気泡の形状や大きさなどの情報が特徴マップに表れている。さらに、周囲流体の運動が増していることが、特徴マップにおける周囲流体の濃淡が自然対流領域のそれと比べることで分かる。

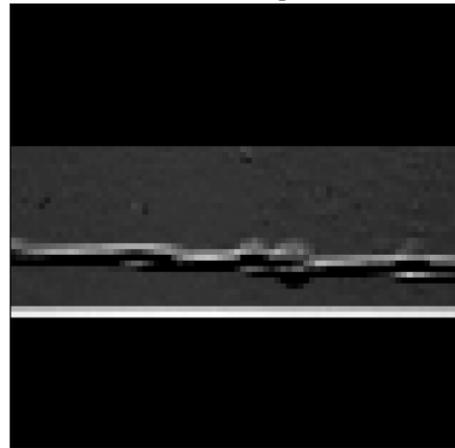


(a) 観測画像

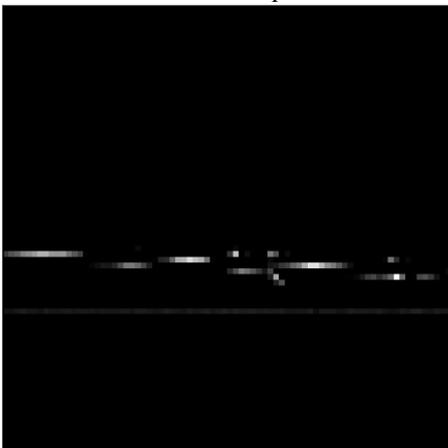
feature map 1



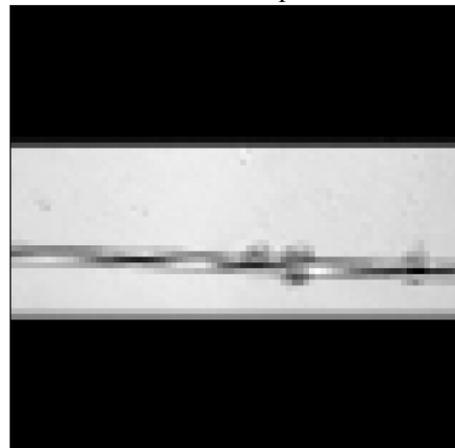
feature map 2

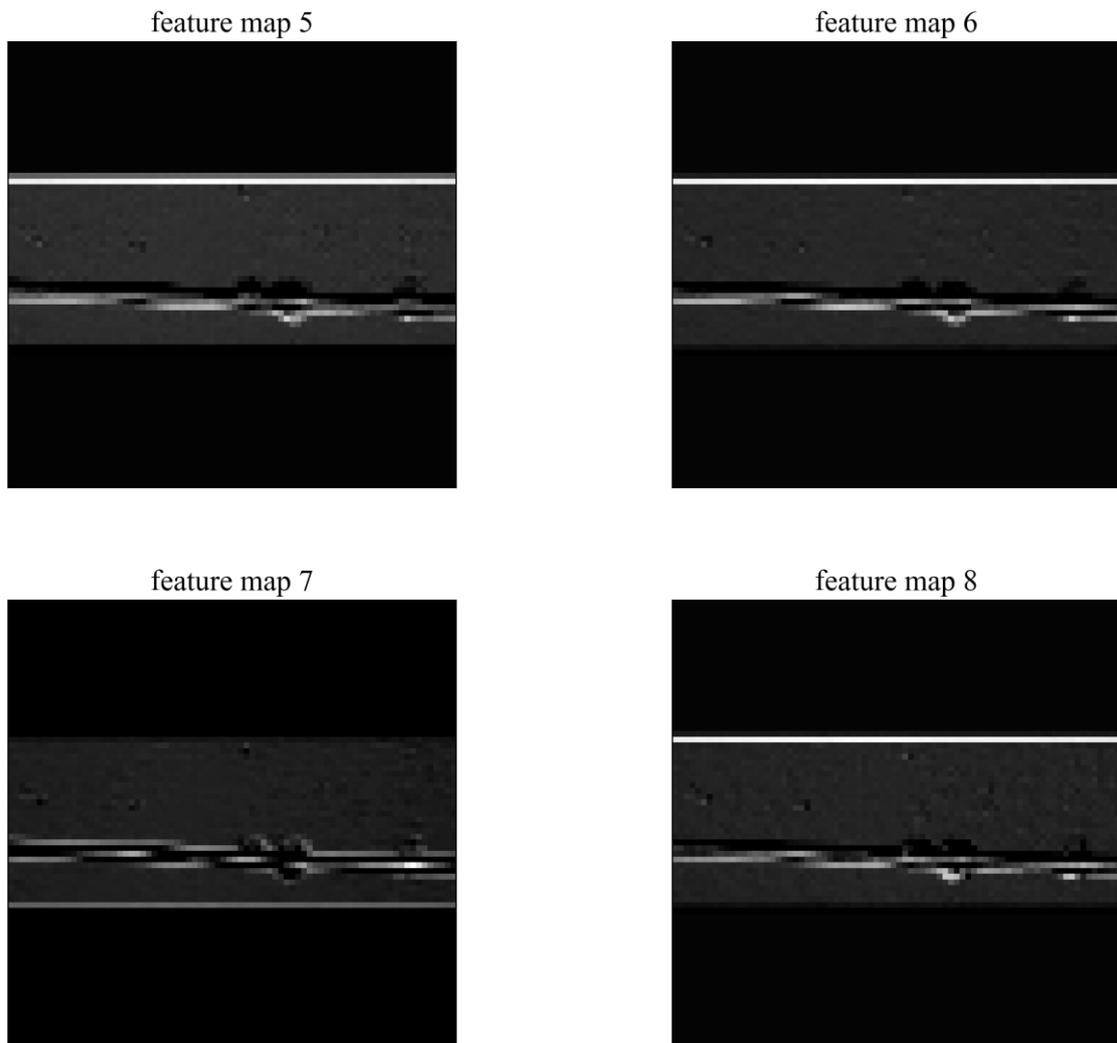


feature map 3



feature map 4

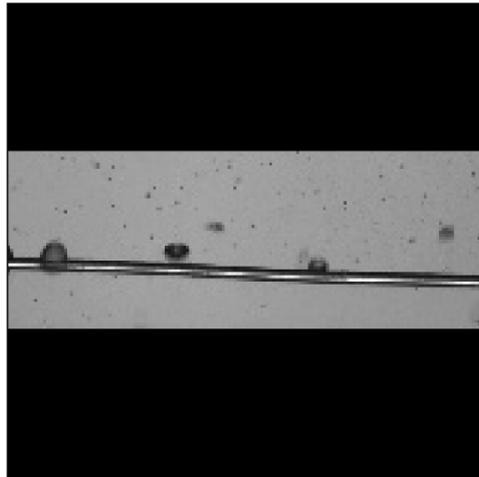




(b) 特徴マップ

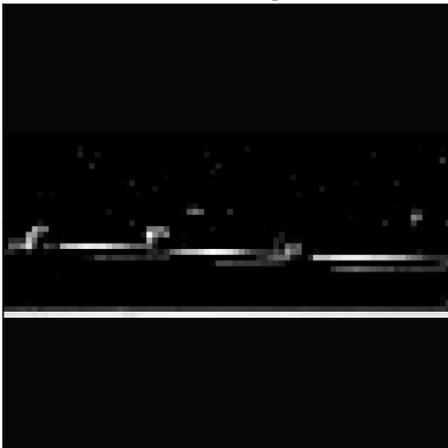
図 4.29 核沸騰初期の観測画像および特徴マップ

さらに，核沸騰域の観測画像について，その特徴マップを示す．図 4.30 中の観測画像の熱伝達係数実測値は 13779 と，図 4.29 中の観測画像に比べて熱伝達係数は大きく，観測画像からもそれがうかがえる．この観測画像に対する熱伝達係数の予測値は 14318 であった．さらに，特徴マップも，観測画像から濃淡パターンを抽出することで，複数の蒸気泡の形状を読み取っており，図 4.29 の特徴マップとの違いが見て取れる．周囲流体に対しても，同様のことが言え，これらの違いから熱伝達係数の大きさの違いを推定していると見られる．これは，人が沸騰熱伝達の大きさを蒸気泡の数や周囲流体の動きから推定することと同じであり，機械学習であれば，その大まかな数値まで予測することが可能である．

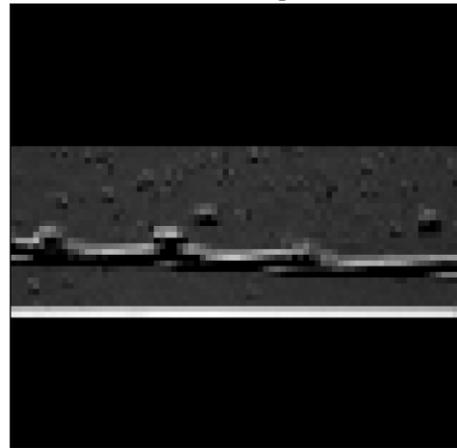


(a) 観測画像

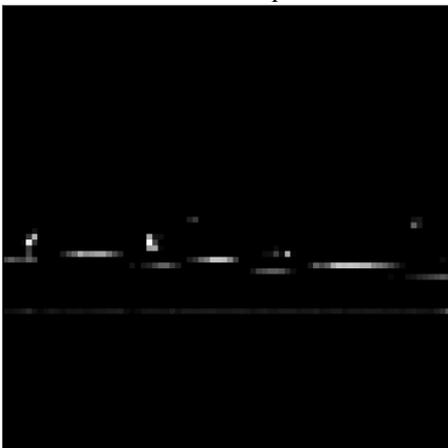
feature map 1



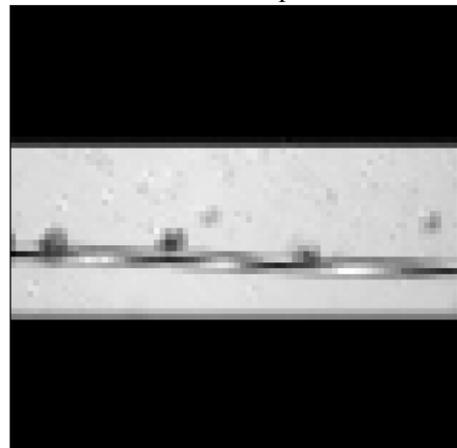
feature map 2

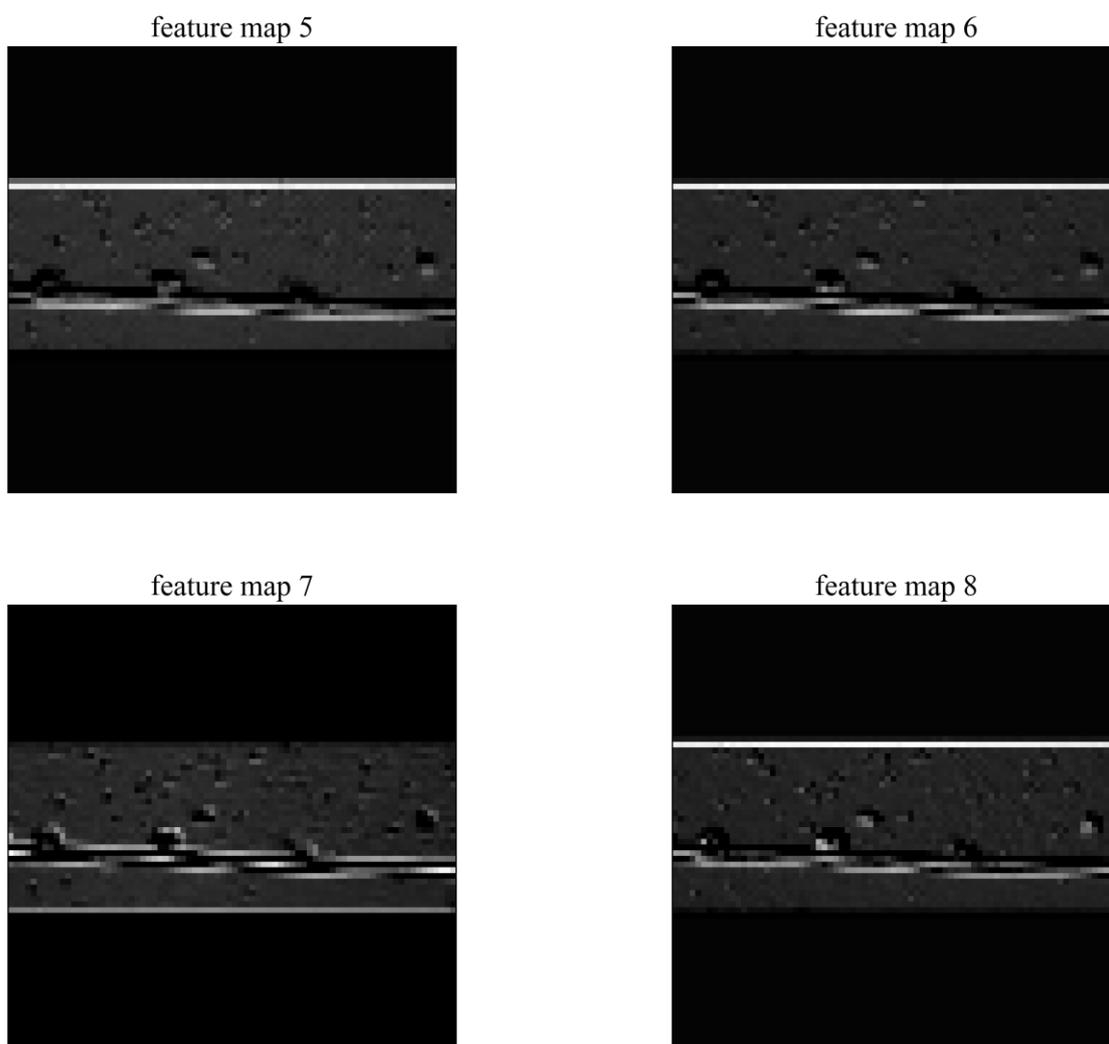


feature map 3



feature map 4

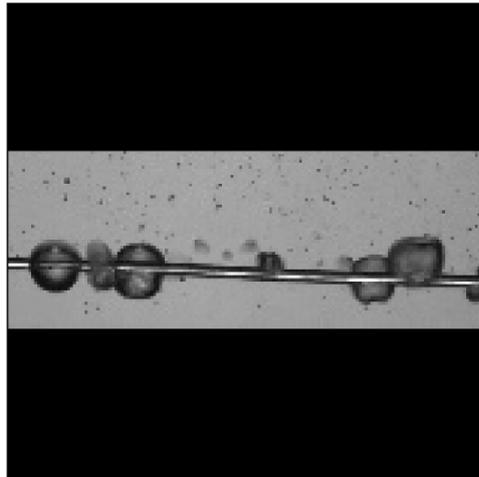




(b) 特徴マップ

図 4.30 核沸騰中期の観測画像および特徴マップ

最後に、核沸騰域の中でも、径が大きい蒸気泡に関する観測画像の特徴マップを可視化する。図 4.31 中の観測画像の蒸気泡は、図 4.29 や図 4.30 の観測画像の蒸気泡の径より大きいことが確認でき、かつ、特徴マップにもそれが表れている。この観測画像の熱伝達係数の実測値は 16551 であり、予測値は 16005 であった。このことから、蒸気泡の径が大きいほど熱伝達係数が大きくなることを予測モデルが学習していることが推察できる。

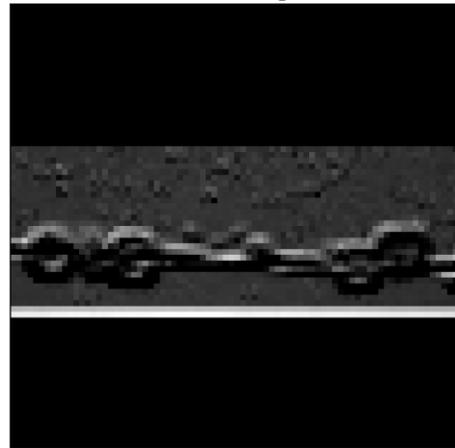


(a) 観測画像

feature map 1



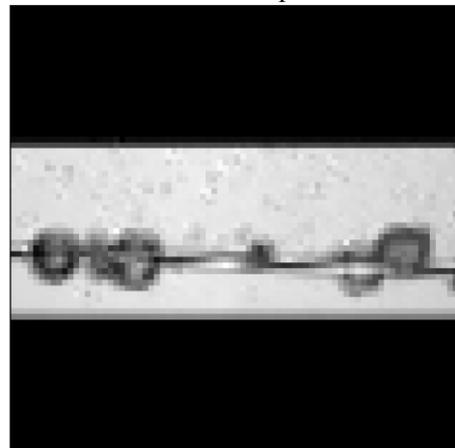
feature map 2

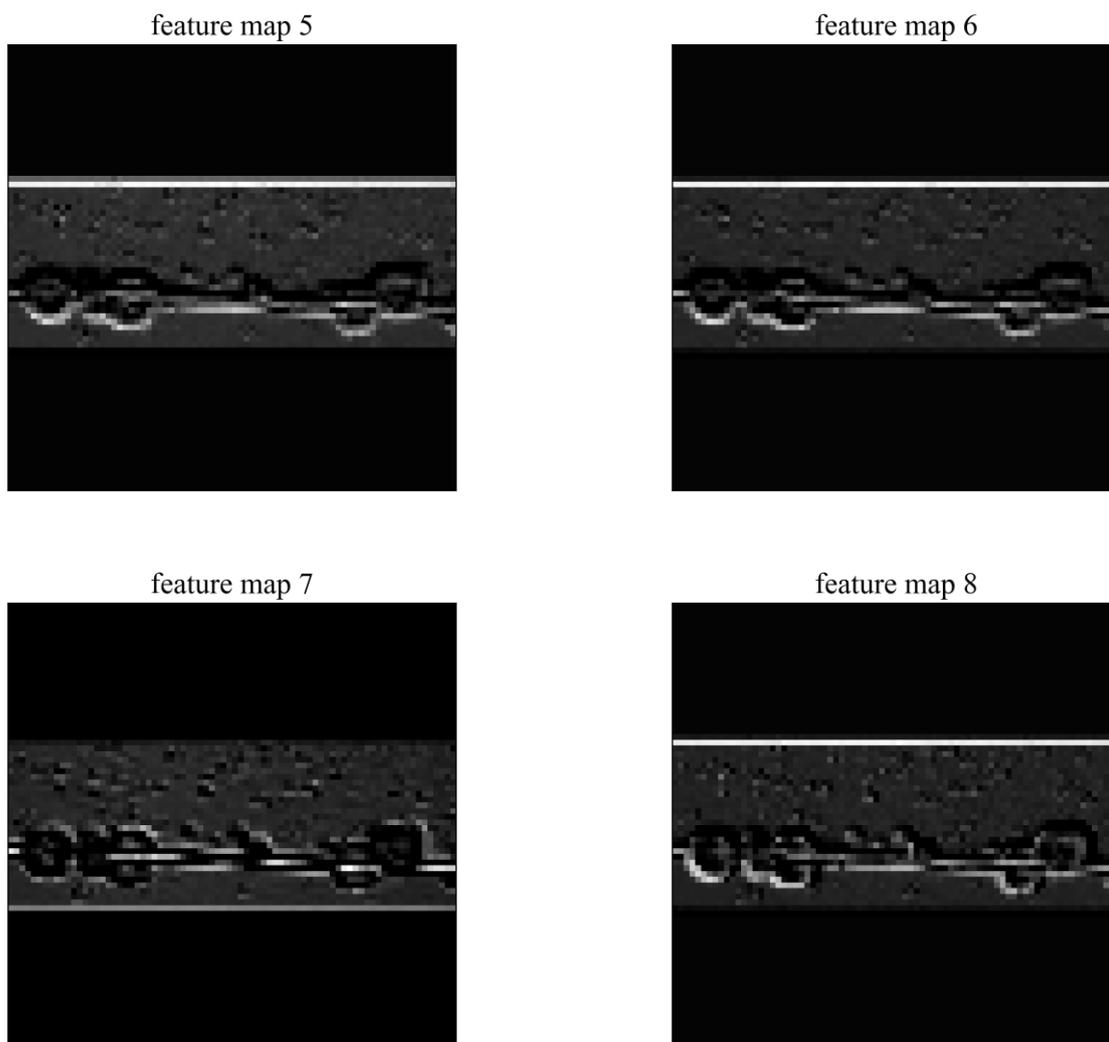


feature map 3



feature map 4





(b) 特徴マップ

図 4.31 核沸騰後期の観測画像および特徴マップ

総じて、畳み込みフィルタは熱伝達に関する情報を観測画像から読み取り、それらの情報を特徴マップに落とし込んでいることが分かった。このことから、畳み込みニューラルネットワークは熱伝達を持つ視覚的な特徴に基づいて熱伝達係数を予測していることが確認できた。

## 第5章

畳み込みニューラルネットワークの発展とともに物体検出の精度も実用化レベルとなった。物体検出のアルゴリズムを用いて蒸気法を検出する研究は近年活発に取り組まれている。前章では、畳み込みニューラルネットワークが蒸気泡の特徴を抽出し、熱伝達を予測していることが確認できた。そこで、本章では、リアルタイムでの検出も視野に物体検出の手法を用いて蒸気泡の検出を行い、蒸気泡径の計測の効率化や沸騰状態の制御や解析の可能性を探求する。

### 5.1 物体検出の歴史

物体検出は、画像内から定められた物体の位置とカテゴリを検出する分類器である。歴史的には、2001年に提唱された Haar Cascade<sup>[17]</sup>から始まり、様々なアプローチが試みられた。その1つとして、ニューラルネットワークや深層学習が発展する以前には輝度の勾配を特徴ベクトル化する HOG(Histograms of Oriented Gradients)と分類アルゴリズムである SVM(Support Vecotr Machine)を組み合わせたアルゴリズムが Navneet と Bill Triggs によって提唱された<sup>[18]</sup>。ニューラルネットワークや深層学習の登場後は、画像認識において高い精度を持つ CNN のアルゴリズムを応用しようという動きが見られ、その先駆けとして R-CNN が Girshick, R らによって提唱された<sup>[19]</sup>。R-CNN は CNN の計算コストを軽減するために Selective Search と呼ばれる物体候補アルゴリズムを使用している。しかし、その実行時間は1枚の画像に対して10秒から45秒ほどであり、リアルタイムでの実行には程遠いものであった。このネックは後に登場した Fast R-CNN<sup>[20]</sup>や Faster R-CNN<sup>[21]</sup>によって改善され、Faster R-CNN の実行速度は R-CNN の250倍である。また、Faster R-CNN は End-to-end 学習を実装した物体検出手法としても知られている。物体検出は画像内の物体の位置を特定する検出とその領域内のクラスを判断する識別から成る。この検出から識別までを一貫して行うのが End-to-end 学習である。End-to-end 学習以前のアルゴリズムは検出と識別が別々のアーキテクチャーとなっており、これが実行速度に影響をきたしていた。また、End-to-end 学習のアルゴリズムは検出から識別に至るまで深層学習の最適化を適応することができ、高速で高精度の検出が可能である。代表的なアルゴリズムとして、Fatsrer R-CNN のほかに YOLO (You Only Look Once) <sup>[22]</sup>や SSD (Single Shot Detector) <sup>[23]</sup>が知られている。

## 5.2 YOLO (You Only Look Once)

YOLO (You Only Look Once) は物体検出モデルの 1 つであり、Joseph Redmon によって初めて実装された。前述の Faster R-CNN と同じく End-to-end 学習であるが、Faster R-CNN と比べても処理速度が速いという特徴を持つ。Faster R-CNN は 1 つのアーキテクチャー内で検出の後に識別を行う直列的な処理方法を採用している。それに対し、YOLO は検出と識別を同時に行うことで処理速度を向上させた。

YOLO にはいくつかのバージョンが存在し、そのバージョンごとに構造が若干異なる。基本的なフレームワークは Backbone 部、Neck 部、Head 部に大別される。Backbone は画像の特徴量を抽出する役割を持つ。Neck は Backbone から受けた特徴マップからより良い特徴量を生み出すレイヤーである。Backbone と Head の中間に位置する Neck レイヤーはバージョンによっては存在しないことがある。最後に位置する Head はクラス分類やバウンディングボックスの位置を予測する。

YOLO は現在までに 6 つのバージョンが実装されている。YOLOv1,v2,v3<sup>[22][24][25]</sup>は YOLO の作者である Joseph Redmon らによって開発された。YOLOv4<sup>[26]</sup>は darknet をフォークして開発を進めていた Alexey Bochkovskiy が第 1 著者となっている。YOLOv4 以降の全てのバージョンには元々の作者である Joseph Redmon は携わっていない。YOLOv5<sup>[27]</sup>は YOLOv3 の PyTorch 版を実装した Glenn Jocher によって開発された。Glenn Jocher は YOLOv4 に採択されているモザイクデータの増強にも関与している。現時点での最新のバージョンは Zheng Ge らによる YOLOX<sup>[28]</sup>である。YOLOX は COCO AP のベンチマークにおいて YOLOv5 を超える性能を実現している。

本章では YOLOv5 を用いて蒸気泡の物体検出を試みる。

## 5.3 自作データセット

物体検出モデルはその他の推定器同様、モデルの学習が必要である。YOLO を含めた著名なフレームワークには学習済みのモデルが公開されていることが多く、誰でも利用することが可能である。しかし、検出することができるクラスは限られており、目的のクラスが学習済みモデルに含まれていない場合には、学習用のデータセットを用意しなければならない。そこで第 2 章で撮影した蒸気泡を用いて自作のデータセットを作成した。データセットは目的のクラスが含まれた画像とその物体のクラス名、物体を囲むボックスで構成される。目的の物体を囲む矩形はバウンディングボックスと呼ばれ、物体の左上端の座標

とボックスの高さと幅の大きさから一意に求まる。つまり、データセットは画像と画像内に存在する物体のクラス名、左上端の  $x$  座標、 $y$  座標、ボックスの高さ、幅の 5 つの変数から成る。画像の総数は 210 枚であり、蒸気泡が確認された 22A から 32A までの 7 条件から 30 枚ずつの画像から構成される。1 つの画像内には複数の蒸気泡が存在することがあるため蒸気泡の数はデータセットの画像枚数よりも多い。

## 5.4 評価指標

分類問題や回帰問題同様、評価指標を用いてモデルの評価を行う。物体検出は物体の位置とクラスの識別の精度、処理の速度が重視される。そのため、物体の位置を正しく検出できているかを評価する IoU (Intersection over Union)、物体のクラスを正しく識別できているかを評価する適合率 (Precision) や再現率 (Recall)、処理速度を評価する fps (Frames per second) など複数の指標を用いて評価される。

### 5.4.1 処理速度

物体検出は自動運転などリアルタイムでの実行を望まれることがしばしばである。処理速度の指標には、1 秒間で処理される画像の枚数を表す *fps* や単に 1 枚の画像の推論に要した時間を用いることが多い。処理速度は使用するコンピュータの能力に大きく左右されるため、評価や比較を行う際には注意しなければならない。一般的にアーキテクチャーが複雑なモデルほど精度は向上するが、処理速度は低下する。

### 5.4.2 IoU (Intersection of Union)

IoU とは正解のバウンディングボックスと予測のバウンディングボックスの重なり合いを示した指標である。図 5.1 に IoU の定義を示す。IoU は 2 つのバウンディングボックスの重なりを和集合で除したもので計算され、0 から 1 の値を取り、完全に重なると 1、全く重ならなると 0 になる。IoU は閾値を設定し、閾値より大きければそのバウンディングボックスを正解とする。

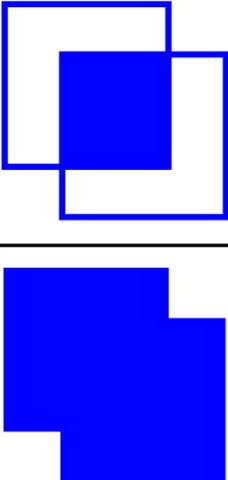
$$IoU = \frac{\text{Area of Intersection}}{\text{Area of Union}}$$


図 5.1 IoU

### 5.4.3 適合率 (Precision)

適合率はすべての予測のうち、正しく予測できた割合を示す評価指標である。物体検出の分野のみならず、一般的な分類問題や画像分類の評価指標としても用いられるが、ここでは物体検出における定義を記す。

物体検出モデルが予測したバウンディングボックスのうち、閾値を超えたものは TP (True Positive)、超えなかったものは FP (False Positive) と判定される。TP はモデルが物体を検出した場所に実際に物体が存在することを意味しており、FP はモデルが物体を検出した場所に実際には物体が存在していないことを意味する。適合率はこの TP を全ての予測結果、すなわち TP と FP の和で除したもので、式 5.1 で表される。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5.1)$$

適合率が大きい値であるほど予測結果が確かであることを表す。しかし、実際には物体が存在したにもかかわらず、モデルが検出できずに取りこぼした場合でも適合率には影響を及ぼさない。そこで取りこぼしの少なさを表す再現率と組み合わせて評価を行うことが多い。

### 5.4.4 再現率 (Recall)

再現率は全ての正解のバウンディングボックスのうち、正しく予測できた割合を示す評

価指標である。適合率が予測結果の確からしさを表すのに対し、再現率は取りこぼしの少なさを表す。

画像内の正解のバウンディングボックスのうち、物体検出モデルが正しく予測できたものは TP、正しく予測できなかったものは FN (False Negative) と判定される。ここでの TP は前項のものと同様である。また、TP と FN の和は正解のバウンディングボックスの数に等しい。再現率は式 5.2 で表され、モデルが正しく予測できた数を正解のバウンディングボックスの数で割ったものである。

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5.2)$$

再現率は大きい値であるほど取りこぼしなく回収できることを表す。取りこぼしが致命的なミスとなり得るケースでは再現率が重視される。適合率と再現率はトレードオフの関係にあり、どちらか一方が高くなると、もう一方は低くなる傾向にある。目的に合わせてどちらを重視するほか、総合的に評価する F 値や AP, mAP を使用することが多い。

#### 5.4.5 F 値

適合率と再現率から計算される両方の値を考慮した評価指標に F 値がある。特に、適合率と再現率の調和平均は  $F_1$  スコアと呼ばれ、式 5.3 で表される。

$$\begin{aligned} F_1 &= \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}} \\ &= 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \\ &= \frac{2TP}{2TP + FP + FN} \\ &= \frac{TP}{TP + \frac{1}{2}(FP + FN)} \end{aligned} \quad (5.3)$$

より一般的な  $F_\beta$  スコアは適合率と再現率の加重調和平均であり、これを式 5.4 に示す。

$$F_{\beta} = (1 + \beta^2) \cdot \frac{\text{Precision} \cdot \text{Recall}}{(\beta^2 \cdot \text{Precision}) + \text{Recall}} \quad (5.4)$$

ここで  $\beta$  は正の係数であり，再現率が適合率の  $\beta$  倍重要であるということを表す． $\beta$  が 1 のとき， $F_1$  スコアすなわち調和平均に等しくなる． $\beta$  の値としては 1 の他に 0.5 及び 2 を用いることが多い．0.5 を使用する場合，適合率を再現率に比べて 2 倍重要視することを，2 を使用する場合には再現率を 2 倍重要視することを表す．この  $F_{0.5}$  スコアと  $F_2$  スコアを式 5.5，式 5.6 にそれぞれ記す．

$$\begin{aligned} F_{0.5} &= (1 + 0.5^2) \cdot \frac{\text{Precision} \cdot \text{Recall}}{(0.5^2 \cdot \text{Precision}) + \text{Recall}} \\ &= 1.25 \cdot \frac{\text{Precision} \cdot \text{Recall}}{0.25 \cdot \text{Precision} + \text{Recall}} \end{aligned} \quad (5.5)$$

$$\begin{aligned} F_2 &= (1 + 2^2) \cdot \frac{\text{Precision} \cdot \text{Recall}}{(2^2 \cdot \text{Precision}) + \text{Recall}} \\ &= 5 \cdot \frac{\text{Precision} \cdot \text{Recall}}{4 \cdot \text{Precision} + \text{Recall}} \end{aligned} \quad (5.6)$$

目的に応じていずれかの F スコアを選択することになる．総じて，高い F スコアは適合率と再現率がともに高いことを示すが，適合率か再現率のどちらかが極端に小さい場合には F スコアは小さい値を示す．

#### 5.4.6 AP, mAP

F 値と同じく適合率と再現率から計算される評価指標に AP (Average Precision) と mAP (mean Average Precision) がある．AP は AUC (Area Under the Curve) の一種であり，PR 曲線 (Precision-Recall curve) の面積で表されるため PR-AUC や AUC-PR とも表記される．PR 曲線は縦軸に適合率，横軸に再現率を取った曲線で図 5.2 のようなグラフとなる．

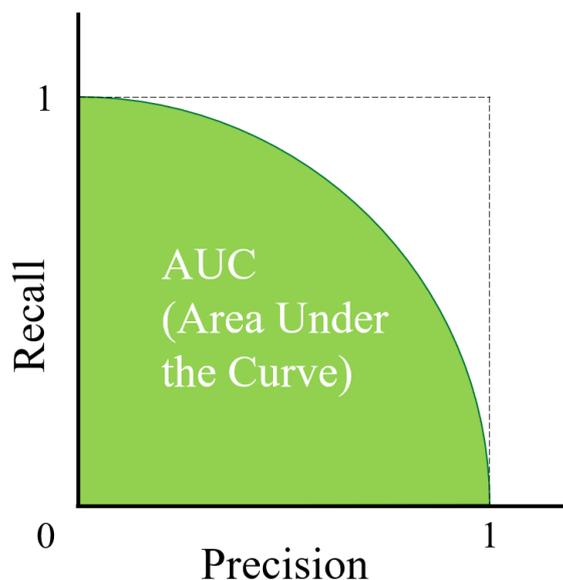


図 5.2 PR 曲線の例

図 5.2 からも分かるように、適合率と再現率がトレードオフの関係にあることから右肩下がりになる傾向を持つ。AUC は図 5.2 中の PR 曲線の下側の領域を指す。面積の大きさは 0 から 1 までの値を取り、大きいほど優れていることを示す。  $p$  を適合率の変数、  $r$  を再現率の変数とすると、AP は一般的に式 5.7 のように積分を用いて表すことができる。

$$AP = \int_0^1 p(r) dr \quad (5.7)$$

AP は 1 つのクラスラベルに対する評価指標である。モデルが複数の物体を検出するときにはそれぞれのラベルごとに AP を計算し、その平均を取る。これを mAP と呼ぶ。

適合率や再現率は IoU の閾値によって異なる値を取る。それにより、mAP も変動するため、  $AP^{IoU=.50}$  や  $AP_{75}$  のように閾値を併せて表記されることが多い。複数の閾値に対する AP を列記する場合や、  $AP@[.50:.05:.95]$  のように閾値を 0.50 から 0.95 まで 0.05 ずつ増加させたときの平均を記す場合もある。また、閾値の大きさではなく検出対象のオブジェクトの大きさごとに AP を計算し、比較する方法も提案されている。  $AP^{small}$  は  $32 \times 32$  pixels 未満のオブジェクト、  $AP^{medium}$  は  $32 \times 32$  pixels 以上、  $96 \times 96$  pixels 未満のオブジェクト、  $AP^{large}$  はそれ以上の大きさのオブジェクトを対象とし、AP を算出している。

## 5.5 YOLOv5 による蒸気泡の検出

本節では YOLOv5 のフレームワークと第 5.3 節で作成したデータセットを用いてモデルの学習を行い、蒸気泡の検出及び処理速度を計算した。

### 5.5.1 学習

本節では蒸気泡検出モデルの学習を行い、1Epoch の学習が終了するごとに、Precision および Recall を算出した。学習に要した時間は 43 分 33 秒であり、使用したバージョンは YOLOv5m である。また、Precision と Recall を用いて PR 曲線を描き、そこから算出される AP や F 値を用いて訓練の進みを確認する。

図 5.3 および図 5.4 に学習中の Precision と Recall の推移を示す。さらに、図 5.5 に Precision と Recall の PR 曲線を示す。最後に、表 5.1 に最も損失が小さかったときの Precision, Recall, F<sub>1</sub> 値, F<sub>0.5</sub> 値, F<sub>2</sub> 値, AP<sub>0.5</sub> および AP@[.5:.95]をまとめる。データセットに含まれるクラスは 1 つであるので、AP と mAP は同義となる。

まず、図 5.3 の Precision について見る。学習が進むごとに Precision が増加していることから、蒸気泡のバウンディングボックスの位置に予測のバウンディングボックスを出力できていることが分かる。さらに、Precision について詳しく見ると、多少の浮き沈みはあるものの 60Epoch までは Precision が大きくなっているが、それ以降ではほとんど横ばいになっている。今回の学習では見られなかったが、再度 Precision が低下する過学習も起こり得る。過学習防止のため、この物体検出モデルでは 1Epoch ごとにモデルの重みを保存し、最も損失が小さかったときの重みを用いて最終的な予測モデルとする。

同様に、図 5.4 の Recall について見る。再現率を表す Recall も先ほどの Precision の推移と似た傾向が見られる。再現率が高いことから観測画像内の蒸気泡を取りこぼすことなく検出できることが期待される。さらに、Precision と Recall がともに高いことから、予測性能がかなり高いことが期待できる。その一方、汎化性能については低下している恐れがある。これについては PR 曲線でも後述する。

図 5.5 の PR 曲線から、Precision と Recall の関係を推察することができる。図 5.3 と図 5.4 から高い Precision と Recall であることが分かるが、PR 曲線ではそれらの関係性の強さ、つまり、トレードオフの強さを詳しく見ることができる。図中の Precision を軸に考えると、Recall が 1 に近づくと Precision は 1 から 0 に低下している。すなわち、AUC

は最大で1である。実際には、PrecisionとRecallはトレードオフの関係にあるため、AUCが1となることはほとんどない。図5.5の総面積は0.99とかなり大きい。一般的には1に近いほど予測性能が高いとされるが、分類問題の指標として用いられる正解率(Accuracy)同様、ほとんど1である場合、汎化性能の低下が疑われる。AUCが過剰に大きくなった原因としては次のことが考えられる。1つ目に、データが不足していたことが挙げられる。データセットに含まれる観測画像はすべて単一の実験装置により撮影されたものである。データセットには、1つのクラスに対し、複数の大きさや異なる背景を持つ画像が用意されていることが望ましい。そうでなければ、検出モデルが学習するそのクラスに対する特徴は偏ったものとなり、PrecisionやRecallが非常に高い値となることがしばしば見られる。2つ目に、この物体検出のアーキテクチャーが蒸気泡の特徴を捉えるには重たいことが挙げられる。蒸気泡の形状はシンプルなのに対し、物体検出のアーキテクチャーは細かな形状にも重みを付けられるように深い層で構成されている。そのため、データセットが不足しているとき同様、モデルが蒸気泡の偏った特徴を学習していることが考えられる。データの種類を増やすことで汎化性能を向上させる方法は最も単純かつ効果的である。蒸気泡に関してはこれまでも多く研究されており、観測画像のデータを増やすことはさほど困難ではないが、クラスラベルやバウンディングボックスを付加する作業には多くの時間を要する。さらに、本研究の目的は伝熱解析における機械学習の利用を探求する、もとい、その基礎を得ることにあるため、データの種類は増やさず、この学習モデルを用いた。

表5.1からも、これまでの結果と同じく高い精度を示していることが分かる。PrecisionとRecallがどちらも高いことから、 $F_1$ 値、 $F_{0.5}$ 値、 $F_2$ 値のいずれも高い学習結果となっている。

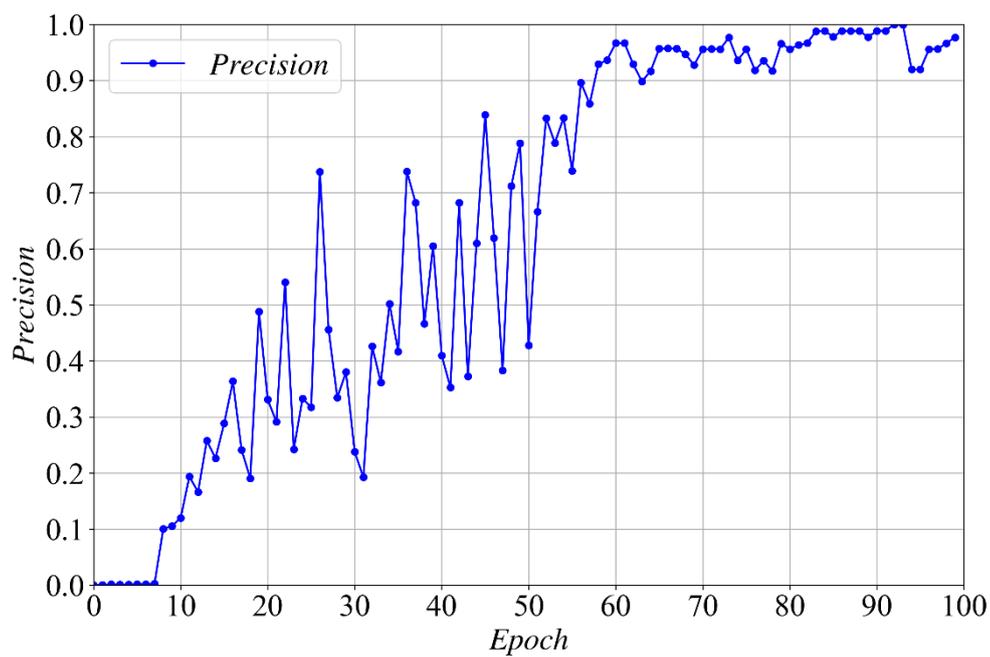


図 5.3 適合率の学習推移

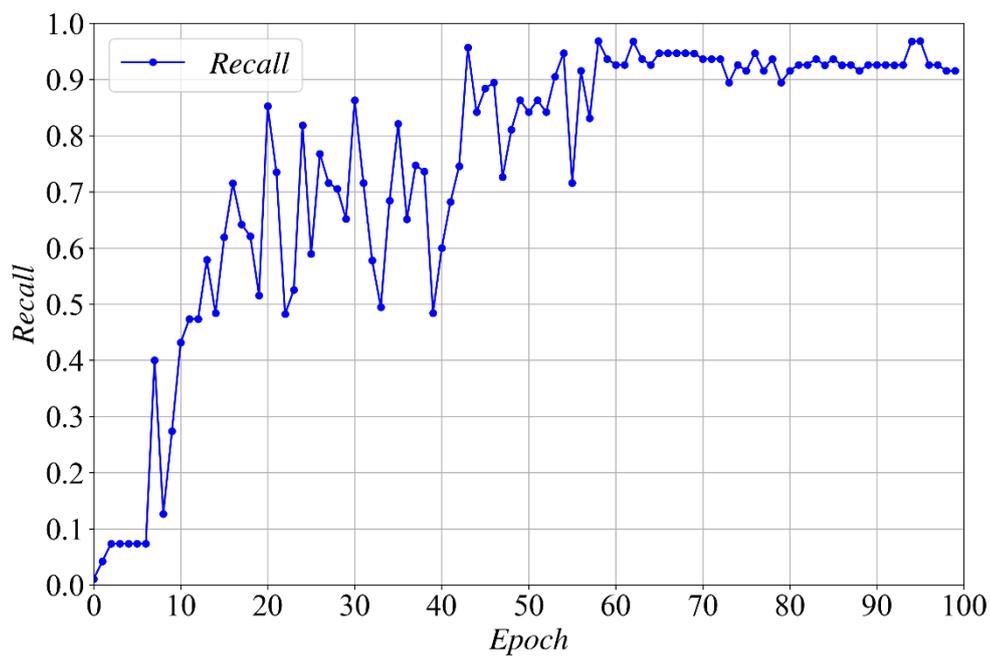


図 5.4 再現率の学習推移

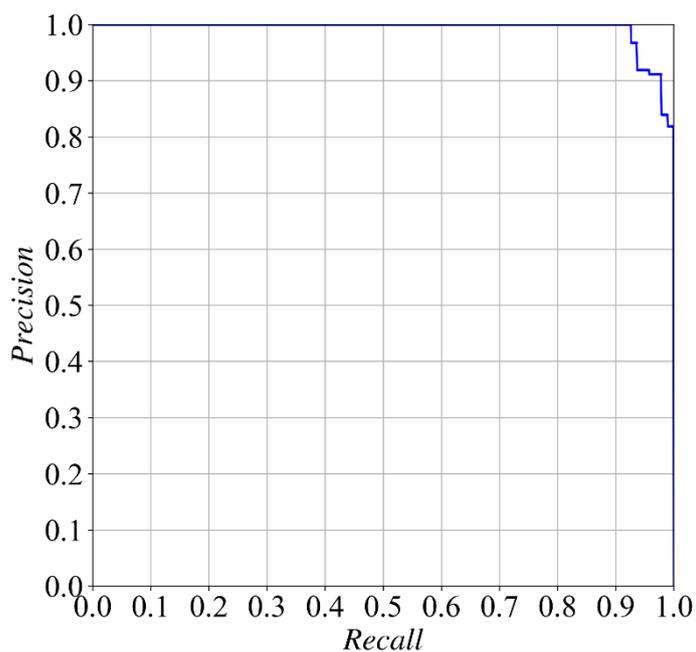


図 5.5 PR 曲線

表 5.1 評価指標

Precision	1
Recall	0.926
F <sub>1</sub> 値	0.945
F <sub>0.5</sub> 値	0.964
F <sub>2</sub> 値	0.927
AP.5	0.988
AP@[.5:.95]	0.589

### 5.5.2 蒸気泡の検出

前節で学習を行ったモデルを用いて蒸気泡を検出することで、評価指標からは読み取ることができない検出モデルの性能を明らかにする。検証用の画像として、観測画像内に蒸気泡が含まれるものと含まれていないものを複数用意した。これらの画像はモデルの学習には用いていない。

図 5.6 に、計 10 枚の検証用の観測画像と検出結果を併せて示す。検証用の画像を左側に、検出結果画像を右側に配置している。図 5.6 全体を通して、前項の高い評価指標が示

すように、蒸気泡の検出が可能であることが分かる。それぞれの画像について詳しく見ていくと、図 5.6(a)から図 5.6(c)には蒸気泡が含まれていないが、検出結果にも FP となる誤検出は確認されない。蒸気泡が含まれている図 5.6(d)から図 5.6(j)においてはいくつかの誤検出が見受けられるため、これらについて考察する。図 5.6(d)と図 5.6(e)の白金線上の最右端には FP となるバウンディングボックスがそれぞれ確認される。この原因としては前項でも述べた蒸気泡の偏った特徴が挙げられる。データセットには白金線から離脱する前の状態の蒸気泡が多く含まれている。そのため、モデルが白金線そのものを蒸気泡の特徴として誤って学習してしまったと推察される。また、FN となる誤検出が図 5.6(d)から図 5.6(j)を通して、複数見受けられる。この誤検出のほとんどは小さな蒸気泡を検出できていないためである。YOLO および他の物体検出アルゴリズムは小さい物体の検出を得意としておらず、径が大きい蒸気泡と比較して、径が小さい蒸気泡は取りこぼしが目立っている。さらに、図 5.6(f)のように、1つの蒸気泡に対し、複数のバウンディングボックスが出力されているケースや、図 5.6(i)のように、複数の蒸気泡が1つのバウンディングボックス内に含まれるケースも確認された。

これらの誤検出や取りこぼしを改善するための方法として挙げられるのは、データの数を増やすことである。しかし、データの数を増やすことが不可能な場合では、元ある画像に様々な処理を施し、疑似的にデータの数を増やすこともよく行われる。

検証用の観測画像を用いて蒸気泡の検出を行うことで、精度指標からは読み取ることができない検出モデルの性能が明らかになった。検出モデルは蒸気泡の位置や大きさを高い精度で検出できており、蒸気泡の径の大きさを物体検出により計測することが可能であることが確認した。しかし、前項の精度指標でも挙げられたデータの種類の不足していることが本項でもネックであることが分かった。



(a)



(b)



(c)



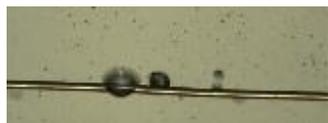
(d)



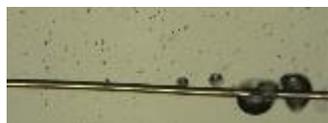
(e)



(f)



(g)



(h)



(i)



(j)

図 5.6 観測画像と検出結果

### 5.5.3 推論時間および処理速度

本項では，観測画像と観測動画の両方に対する推論時間と処理速度を算出し，それらを纏め記す．

表 5.2 に，画像と動画に対する推論時間と処理速度をまとめる．推論時間とは 1 枚の画像を処理するために要する時間であり，処理速度とは fps のことを指す．画像および動画はいずれも  $160 \times 60$  であるが，検出モデル内で  $640 \times 640$  に変換されている．画像に対する推論時間および処理速度は 10 枚の画像を断続的に処理したときの平均から算出されるものであり，動画に対するそれらは 30 秒間の動画を連続的に処理したときの数値である．

画像に対する推論時間よりも動画に対する推論時間の方がわずかであるが短い結果となっているが，検出モデルの画像と動画に対する検出プロセスの違いによるものであると考えられる．総じてみると，約 20 - 30 ms の推論時間であり，1 秒間で 30 - 45 枚のフレームを処理できることが確認された．他の物体検出モデルと比べてもかなり推論時間は短く，リアルタイムでの計測や解析，制御を可能であると考えられる．しかし，すべてのフレームを用いるリアルタイム計測のためには，本研究で用いた YOLOv5m よりも処理が軽い YOLOv5n や YOLOv5s を用いることや変換されるサイズを  $640 \times 640$  よりも小さいサイズに変更することが推奨される．

表 5.2 推論時間と処理速度

	推論時間[ms]	fps[frames/s]
画像	31.2	32
動画	21.9	45

## 第6章 総括

第1章では、本研究の研究背景および本研究に関連する従来研究についてまとめ、本研究の意義と目的を述べた。

第2章では、まず、実験装置および実験方法について述べた。次に、沸騰熱伝達係数測定実験から、機械学習に用いる学習用のデータセットを作成し、それを示した。

第3章では、主成分分析をデータセットに適用し、その結果から以下の知見を得た。

- (1) 第1主成分は、観測画像から周囲流体の運動や蒸気泡などの熱伝達の特徴を抽出しているため、熱流束や熱伝達係数を予測するための特徴量に適している。
- (2) 第2主成分以降の主成分に関しては、データセットの分散を保持し、熱伝達の特徴を捉えてはいるものの、局所的な特徴であるため、予測のための特徴量としては適さない。

第4章では、機械学習を用いて、従来の計測手法とは異なる観測画像からの熱伝達係数の測定を目指した予測モデルを作成し、以下の知見を得た。

- (1) PCA+回帰分析による熱伝達係数の予測は、10%の平均誤差率で予測ができることが確認できる。
- (2) 畳み込みニューラルネットワークによる熱伝達係数の予測は、PCA+回帰分析による予測よりも小さい誤差で予測が行えることが確認された。
- (3) 畳み込みフィルタは蒸気泡の輪郭など熱伝達の特徴となるものを抽出していることを確認し、畳み込みニューラルネットワークによる熱伝達係数の予測は熱伝達の視覚的な情報に基づいて行われていることを示した。

第5章では、物体検出アルゴリズムを用いて、蒸気泡の検出を試み、伝熱解析のための検出精度や処理速度をまとめ、以下の知見を得た。

- (1) 蒸気泡の検出精度は、適合率・再現率ともに0.9を超え、非常に高い検出精度であり、蒸気泡に関する計測の効率化が見込める。
- (2) 検出速度は20-30msであり、リアルタイムでの検出も可能であることから、観測画像による沸騰状態の制御にも期待できる。

## 謝辞

九州大学大学院総合理工学研究院教授 宮崎 隆彦 教授には、本研究の遂行にあたり、数多くの的確かつ有益な御指導、御鞭撻を賜りました。また、本論文の作成についても、丁寧な御指導、御鞭撻を賜りました。ここに、深く感謝の意を表し心から厚く御礼申し上げます。

九州大学大学院総合理工学研究院准教授 Kyaw Thu 准教授には、本研究の遂行にあたり、数多くの貴重なご指導、ご鞭撻を賜りました。ここに、深く感謝の意を表し心から厚く御礼申し上げます。

九州大学大学院総合理工学研究院 高田 信夫 技術専門職員には、本研究を遂行する上で特に装置、機械、部品などの技術的な面のみならず研究室の生活において、数多くの御助言、御協力を賜りました。ここに、心から深く御礼申し上げます。

九州大学大学院総合理工学研究院 Frantisek Miksik 特任助教には、研究の専門知識、装置に関する助言に加え、研究室内の生活の部分でも支えていただきました。ここに感謝の意を表し、心からお礼申し上げます。

九州大学大学院総合理工学府環境エネルギー工学専攻宮崎研究室に所属する、博士課程 3 年 Mansoor Abdul Aziz さん、Chairunnisa さん、Yang Changru さん、Abirham Yemanebirhan Tadesse さん、Colombatanirige Uthpala Perera さん、Moket Relebohile さん、博士課程 1 年 Motaz Mabrok Mohamed Salama さん、Sagar Saren さん、Yang Zhaosheng さん、Yu Hao さん、Seo Sang Won さん、Marco Reyes Lao さん、Haoulomou Pepe さん、Sannan Salabat Butt さん、Xuetao Liu さん、Denis Mutebi さん、Mojtaba Purjam さん、修士課程 2 年 登川 智也 さん、富來昌哲 さん、中島 隆宏 さん、Chen Haonan さん、Yang Cheng さん、修士課程 1 年 伊藤 大芽 さん、川喜田 幹太 さん、郡 光春 さん、前城 裕太 さん、益守 航 さん、Chai Jiazi さん、Shen Jiaqi さん、学部 4 年 中津 英彬 さん、溝部 幸輝 さんには、公私に渡り親切な御助言を賜るとともに御激励をいただきました。ここに深く感謝の意を表し、心より御礼申し上げます。

研究室秘書 大和 裕里 さんには、事務的な手続きなど多くの便宜を図って頂き、また、学生生活においても大変お世話になりました。ここに、心から深く御礼申し上げます。

最後に、著書の学生生活を温かく見守り、最後まで支え続けてくれた家族に、心より感謝します。

## 参考文献

- [1] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- [2] McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- [3] Geoffrey E. Hinton; R. R. Salakhutdinov (2006-07-28). "Reducing the Dimensionality of Data with Neural Networks". *Science* 313 (5786): 504-507.
- [4] 抜山四郎. (1934). 金属面と沸騰水との間の傳達熱の極大値並に極小値決定の實驗. *機械學會誌*, 37(206), 367-374.
- [5] 吉田駿, 伝熱学の基礎, 1999.
- [6] 日本機械学会, 伝熱工学資料 (改定第4版), 1986.
- [7] Stephan, K., & Abdelsalam, M. (1980). Heat-transfer correlations for natural convection boiling. *International Journal of Heat and Mass Transfer*, 23(1), 73-87.
- [8] Hobold, G. M., & da Silva, A. K. (2018). Machine learning classification of boiling regimes with low speed, direct and indirect visualization. *International Journal of Heat and Mass Transfer*, 125, 1296-1309.
- [9] Hobold, G. M., & da Silva, A. K. (2019). Visualization-based nucleate boiling heat flux quantification using machine learning. *International Journal of Heat and Mass Transfer*, 134, 511-520.
- [10] 榎木光治, 清雄一, 大川富雄, & 齋藤潔. (2017). 人工知能の深層学習による円形微細流路内水平流の沸騰熱伝達の予測. *混相流*, 31(4), 412-421.
- [11] Haas, T., Schubert, C., Eickhoff, M., & Pfeifer, H. (2020). BubCNN: Bubble detection using Faster RCNN and shape regression network. *Chemical Engineering Science*, 216, 115467.
- [12] Fu, Y., & Liu, Y. (2019). BubGAN: Bubble generative adversarial networks for synthesizing realistic bubbly flow images. *Chemical Engineering Science*, 204, 35-47.
- [13] Cerqueira, R. F., & Paladino, E. E. (2021). Development of a deep learning-based image processing technique for bubble pattern recognition and shape reconstruction in dense bubbly flows. *Chemical Engineering Science*, 230, 116163.

- [14] Lemmon, E.W., Bell, I.H., Huber, M.L. and McLinden, M.O., NIST Standard Reference Database 23, Reference Fluid Thermodynamic and Transport Properties-REFPROP, Version 10.0, Standard Reference Data Program, NIST, 2018.
- [15] Pearson, K. (1901). On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2(11).
- [16] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- [17] Viola, P., & Jones, M. (2001, December). Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001 (Vol. 1, pp. I-I)*. Ieee.
- [18] Dalal, N., & Triggs, B. (2005, June). Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05) (Vol. 1, pp. 886-893)*. Ieee.
- [19] Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 580-587)*.
- [20] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision (pp. 1440-1448)*.
- [21] Ren, S., He, K., Girshick, R., & Sun, J. (2016). Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149.
- [22] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788)*.
- [23] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016, October). Ssd: Single shot multibox detector. In *European conference on computer vision (pp. 21-37)*. Springer, Cham.
- [24] Redmon, J., & Farhadi, A. (2017). YOLO9000: better, faster, stronger. In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7263-7271)*.
- [25] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint*

arXiv:1804.02767.

- [26]Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. arXiv preprint arXiv:2004.10934.
- [27]Ultralytics YOLOv5: <https://github.com/ultralytics/yolov5>
- [28]Ge, Z., Liu, S., Wang, F., Li, Z., & Sun, J. (2021). Yolox: Exceeding yolo series in 2021. arXiv preprint arXiv:2107.08430.