



---

# 卒業研究報告書

令和元年度

---

研究題目

はんだ付け装置の圧力変化を用いた  
機械学習による不良はんだの検知

---

指導教員 上野秀剛 准教授

---

氏名 福光嘉伸

---

令和2年1月30日 提出

奈良工業高等専門学校 情報工学科

# はんだ付け装置の圧力変化を用いた

## 機械学習による不良はんだの検知

上野研究室 福光嘉伸

はんだ付けの品質は電子機器全体の品質に大きく影響するため、厳しい品質と信頼性が求められる製品において最重要工程となっている。共同研究先は、窒素ガスを充填した筒を基盤に被せ、その中に常に一定量のはんだを落下させ溶融して高品質なはんだ付けを行うロボット“スマートショット”を開発した。スマートショットは筒の基板への密着、はんだ片落下、はんだ溶融、といった工程ごとに筒内の圧力が変化する。私は圧力変化にははんだの成否を判別するための特徴があると考えている。例として、不良はんだは融解したはんだが基盤に流れず、筒内を塞ぎ続けるため正常はんだの場合と比べ圧力低下が緩やかになる。本研究でははんだの成否を識別できる特徴量を明らかにすると共に、機械学習によってはんだの成否を分類したときの精度を評価する。実験では、異なる環境ではんだしたときのデータを用いて機械学習を行う。その際の特徴量の重要度を分析することではんだの成否を識別できる特徴量を明らかにする。実験の結果、波形の尖度やはんだ付け完了後の圧力降下を特徴として用いることで、99.3%の精度で正常はんだと不良はんだを判別できた。

# 目次

<b>1</b>	<b>はじめに</b>	<b>2</b>
<b>2</b>	<b>関連研究</b>	<b>3</b>
2.1	はんだ付けの自動検査	3
2.2	波形を用いた機械学習	3
<b>3</b>	<b>機械学習</b>	<b>4</b>
3.1	概要	4
3.2	Random Forest	4
3.3	階層クラスター分析	5
<b>4</b>	<b>実験</b>	<b>6</b>
4.1	対象データ	6
4.1.1	データセット	6
4.1.2	スマートショットの出力	6
4.1.3	前処理	7
4.2	特徴量抽出	9
4.2.1	平均圧力	10
4.2.2	最大圧力	10
4.2.3	尖度	11
4.2.4	ピーク長	11
4.2.5	圧力降下にかかる時間	11
4.3	分析	11
4.3.1	概要	11
4.3.2	実験環境におけるはんだ付けの分類	12
4.3.3	はんだ付けデータの分析	12
4.3.4	実環境におけるはんだ付けの分類	13
<b>5</b>	<b>結果と考察</b>	<b>14</b>
5.1	実験環境におけるはんだ付けの分類	14
5.2	はんだ付けデータの分析	15
5.3	実環境におけるはんだ付けの分類	18
<b>6</b>	<b>おわりに</b>	<b>22</b>
	謝辞	23
	参考文献	24

# 1 はじめに

電子基板と素子を接合するはんだ付けは電子機器の品質に大きく影響するため、はんだ付けには厳しい品質と信頼性が求められる [1][2][3]。また、はんだの不良は、はんだ接合部の品質に依存するため、はんだ接合部の検査は重要な工程である [4][5]。

はんだ接合の成否は目視によって検査するが、作業者の経験に依存するため検出効率が低下しやすい [6][7]。また、近年電子部品のサイズが小さくなり、集積度が増加したため目視検査が困難になってきている [8][9]。そのため、はんだ接合部の検査を自動で行い高品質・高速化を行う必要性が高まっており、自動検査に関する研究 [10][11][12] が良く行われている。

共同研究を行っている企業は、高品質なはんだ付けを行うことを目的としてはんだ付けロボット“スマートショット”を開発した。スマートショットは窒素ガスを充填した筒を基盤に被せ、その中に常に一定量のはんだ片を落下させ溶融させることにより酸素を遮断した状態で定量のはんだ付けを行うことができる。このとき、筒の基板への密着、はんだ片落下、はんだ溶融といった工程ごとに筒内の圧力が変化する。

私は圧力変化には、はんだの成否それぞれに異なる特徴があると考えている。はんだの成否を決めるはんだの基板への流れ具合や溶け具合等の要素が、圧力変化に現れると考えられる。例として、不良はんだははんだ溶融後にはんだが基盤に上手く流れず、筒内を塞ぎ続けるため正常はんだの場合と比べ圧力低下が緩やかになる。圧力変化を波形としてデータ化し、その波形からはんだの成否を識別する特徴を抽出することができれば、機械学習によりはんだの成否を分類し、不良はんだの自動検出に用いることができる。本研究でははんだの成否を識別できる特徴量を明らかにすると共に、機械学習によってはんだの成否を分類し精度を検証する。

以下、2章では関連研究について示し、3章では本研究で用いる機械学習について説明する。4章では用いる手法や実験の内容について紹介し、5章では結果を示した後それに対する考察について述べる。

## 2 関連研究

### 2.1 はんだ付けの自動検査

はんだ付けの自動検査を目的に、機械学習を用いた手法が多数提案されている。従来研究の多くは、プリント基板の画像からはんだ接合部を抽出し、画像認識によってはんだの成否を分類する。

松嶋ら[13]はニューラルネットワーク(NN)学習アルゴリズムを利用して、はんだ接合部の外観からはんだの成否を学習・判断する視覚検査システムを構築した。主成分分析を用いて入力パラメータを削減した結果、平均で約80%の精度で予測できた。Wu[14]は5つの機械学習の手法(決定木,k近傍法,SVM,NN,Random Forest)について精度を比較した。正常はんだ109枚,不良はんだ171枚の計280枚のデータセットで実験を行った結果,Random Forestの場合で5種類の不良はんだを100%と最も高い精度で予測できた。Liu et al.[15]は画像特徴を高次元線形空間に投影することで不良はんだのカテゴリ間の差を線形分離できるようにk近傍法を改良した結果,精度が向上した。

しかし,熱不足が原因で発生するイモはんだ等の不良は100%検査できていないのが現状であり,実際に車載部品メーカーが,全数画像検査の場合にはんだ付け不良品を流出させている。本研究では,はんだ付け時の圧力変化にはんだの成否を分類する特徴があると考え,圧力変化を用いた機械学習を行う。はんだには温度が高い方へ流れる性質があるため,十分に基盤の全体が温められていない状態では一部にはんだが集中して流れイモはんだとなる。圧力変化による成否の識別では,はんだの基板への流れ具合が波形中の圧力低下の部分に現れるため分類できると考えられる。

### 2.2 波形を用いた機械学習

本研究で用いるはんだ付けの圧力変化に限らず,時系列データの波形を用いた機械学習による分類に関する研究がされている。古林ら[16]は心電図の正常・異常をCNNと呼ばれる複数の特徴的な機能を持った層で構成されたNNを用いて判定した。その際に,アルゴリズムとしてアンサンブル学習を用いることで10%以上精度を向上した。菊池ら[17]は深発月震の震源を複数の手法と2つの特徴量をそれぞれ用いて分類を行い,性能を比較した。比較結果から分類性能は特徴量に大きく起因しているということが分かった。

本研究では,分類を行う場合はアンサンブル学習を用いたRandomForestを手法として設定する。また学習モデルの作成後,特徴量の重要度について分析することによりはんだの成否を識別できる特徴量を明らかにする。

## 3 機械学習

### 3.1 概要

機械学習とは、サンプルデータから統計的な性質を学習することで、データ群の特徴やパターンを見つけ出す手法である。機械学習の各アルゴリズムは与えられたデータをもとに学習を繰り返すことで、学習モデルを作成する。学習モデルに対して新たなデータを入力することで、パターンに従い予測することができる。また、機械学習に用いるサンプルデータをデータセットという。

### 3.2 Random Forest

Random Forest は決定木を弱学習器としたアンサンブル学習を用いた機械学習アルゴリズムである [18]。アンサンブル学習とは、高精度でない分類器を複数組み合わせることにより、精度を向上させる手法である。Random Forest は一般的に少ないサンプルデータでも高い精度が出やすいという特徴がある。本研究が対象とする不良はんだは発生頻度が少なく、データを大量に得られないため、Random Forest を採用する。

Random Forest は以下の手順によって学習を行う [19]。

1. 与えられたデータセットから無作為に復元抽出を行い、 $n_{tree}$  組のブートストラップサンプルを作成する。その際、各ブートストラップサンプルでデータの分割をランダムに行う。約  $1/3$  は検証用データとして分割され、検証用データは Out-Of-Bag(OOB) データと呼ばれる。分割した残りの  $2/3$  を学習用データとして用いる。
2. 作成したブートストラップ毎に分類木を作成し、OOB データを用いてテストを行う。テスト時の誤り率は OOB 推定値と呼ばれる。分類器の構築を行う際の各分岐ノードは、異なる木を多数生成するため、ランダムに  $m_{try}$  個の変数をサンプリングし、その中から最も良くサンプルを分類できる変数を用いる。
3. 分類器は、すべてのブートストラップサンプルの OOB 推定値に基づき多数決を取り、分類するクラスを決定する。

Random Forest では、構築する分類器の数  $n_{tree}$  と分岐の際に用いる特徴量の数  $m_{try}$  を調整できる。適切な数値を各パラメータに設定することで、分類精度を向上させることができる。本稿では、 $n_{tree}$  と  $m_{try}$  の数値を 5 章に示す実験により設定する。

### 3.3 階層クラスター分析

クラスター分析は多変量データの距離行列に基づき類似度の高い個体同士をまとめてグループ化する機械学習の手法の1つである [20]. クラスターの階層構造を求める階層的な手法では, 類似した個体を順次併合して最終的に全データを1つのクラスターにまとめる. また結果として, 縦軸がデータ間の距離, 横軸が各データの樹形図であるデンドログラムを出力する. 類似度が高いデータほど樹形図の下で結合するため, 各データで他データとの類似度が分かり, データを一定数の群に分けることができる. クラスター分析を行う上で, クラスター間及びデータ間の距離を計算する方法を決める必要がある. 本研究では, 波形から抽出した特徴量を用いて距離を計算する.

## 4 実験

スマートショットを開発した株式会社アンドからはんだ付けした際の圧力変化のデータを頂いた。はんだ付け時の筒内の圧力変化の波形から特徴量を抽出することによって機械学習による分類を行う。実験の準備として、データをそれぞれの属性毎に分割しデータセットを作成する。また、特徴量が適切に抽出できるような波形に処理を行う。

### 4.1 対象データ

#### 4.1.1 データセット

本研究で対象とするデータは、実験環境と実環境の2つの環境ではんだ付けを行い、計測する。実験環境では機械学習に用いる不良はんだのデータ数を増やすことを目的とする。不良はんだが発生しやすい条件を設定することに加え、複数の特徴が異なる条件を設定し、計測する。実環境のデータは実運用時と同じ条件で連続的にはんだ付けを行い計測する。それぞれの環境で計測した圧力変化のデータには、目視検査を行い対応する正常(OK)、不良(NG)のラベルを付与する。計測したデータは属性に従い、表1に示す4つのグループに分割する。データをどのようなグループに分割するかを示す。それぞれのデータグループにラベルを付けて今後の説明ではこの名称を用いることとする。

表1 データの分割

データグループ	ラベル	データ数
実験環境のOKはんだ	$Exp_{OK}$	298
実験環境のNGはんだ	$Exp_{NG}$	411
実環境のOKはんだ	$Prod_{OK}$	4430
実環境のNGはんだ	$Prod_{NG}$	5

#### 4.1.2 スマートショットの出力

スマートショットでは、はんだ付けの際、0.002秒毎に筒内の圧力値を取得しデジタル信号とする。1度のはんだ付け毎に図1のような波形が得られる。縦軸が筒内の圧力、横軸が時間である。

図の下部には、はんだ付けのプロセスを表す信号が表示されている。信号ははんだ付け開始(時間が0)から順に、はんだ片落下、はんだ付け完了、筒上昇、全プロセス終了の順に出力される。筒の基板への密着、はんだ片落下、はんだ溶融の工程ごとに筒内の圧縮比が上昇することにより圧力が上昇し、はんだ付け完了後に筒下部の隙間を解放することによりはんだが基板へと流れ込み圧力が降

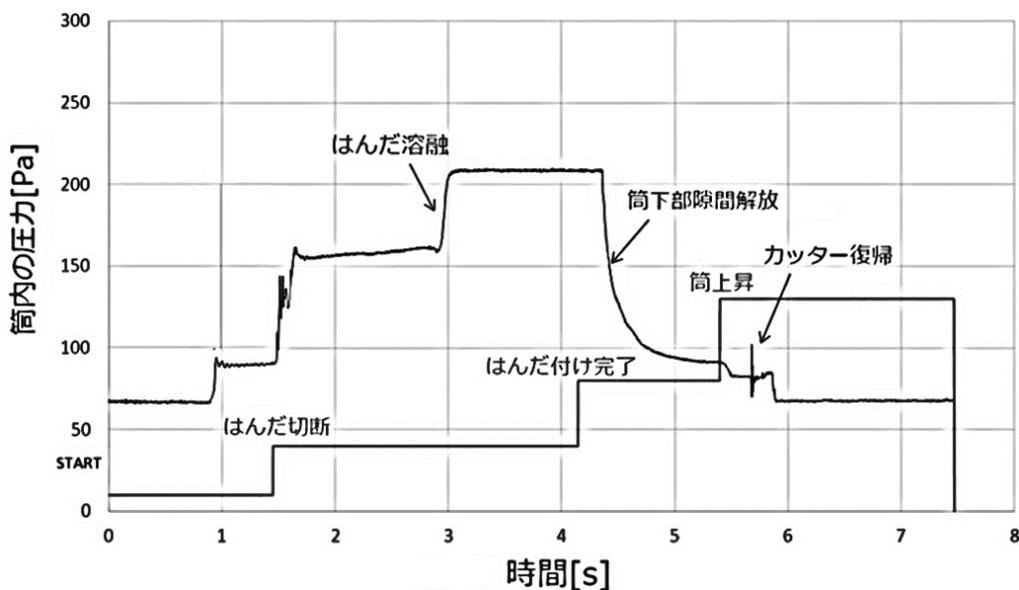


図1 圧力変化の波形

下する．筒が上昇した後，はんだを切断をするカッターが復帰するがこの部分の波形が4.2節に示す特微量抽出の際にノイズとなる．

また，スマートショットでは筒の中にはんだを落としそれを溶融するが，回数を重ねる毎に筒内部に汚れが付着する．筒内汚れによる波形への影響を図2に示す．縦軸が筒内の圧力，横軸はデジタル信号中の何点目かを示しそれぞれの波形が汎例に示す件数のはんだ付けである．件数は筒内部に汚れが一切付着していない状態のはんだ付けを1件目とする．図から初期圧力，圧力降下部は筒内汚れによる影響を受けていることが分かる．

#### 4.1.3 前処理

カッター復帰によるノイズを除去するために，筒上昇の信号を受け取った時点でそれ以降のデータを削除することでカッター復帰の影響を受けないようにする．図3にデータ削除による波形の変化を示す．図3中の四角の枠線で囲まれた部分が削除された部分である．次に波形が汚れの影響を含んでいる場合，件数毎に影響の強さが変化することによりはんだの成否を問わず波形の違いが生じると考えられる．そのことより，抽出した特微量が分類に有効的に作用せず分類精度の低下が考えられるため，汚れの影響を抑制した予測を行う必要がある．そのために，以下の補正式を圧力の各点に対して適用し，筒内の圧力を最高2，最低1とした相対的なグラフへと補正する．この補正は，実環境のはんだデータが含まれるデータセットを用いる際に適用する．

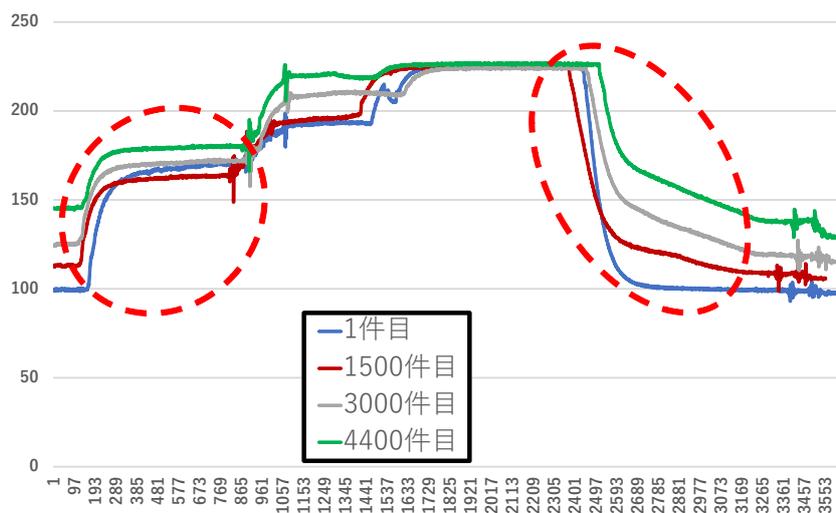


図2 筒内汚れによる波形への影響

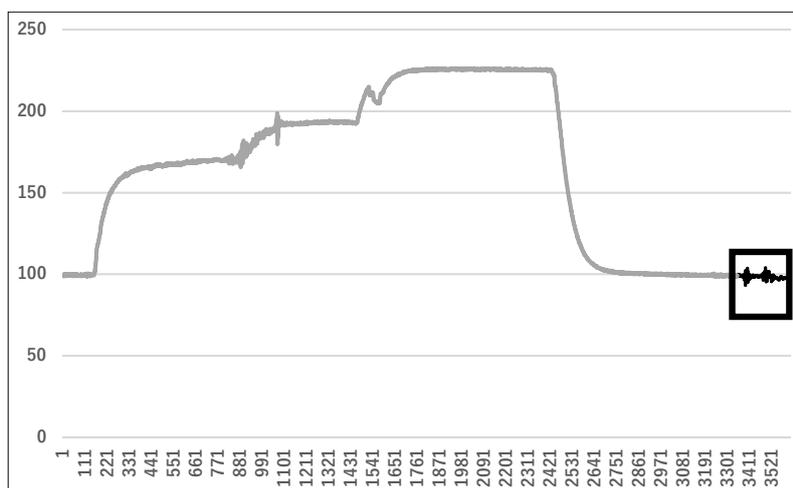


図3 カッター復帰部のデータ削除による波形の変化

$$\beta = 1 + (\alpha - x)/(x - y) \quad (1)$$

- $\alpha$  : 補正前の圧力値
- $\beta$  : 補正後の圧力値
- $x$  : データ中の圧力の最高値
- $y$  : 初期圧力の最小値 (0.02~0.04秒間での最小圧力)

図2の波形を上記の式で補正したものを図4に示す。図4から筒内汚れによる初期圧力上昇の影響を除去することは出来たが、圧力減少部の形状変化を補正しきれないことが分かる。

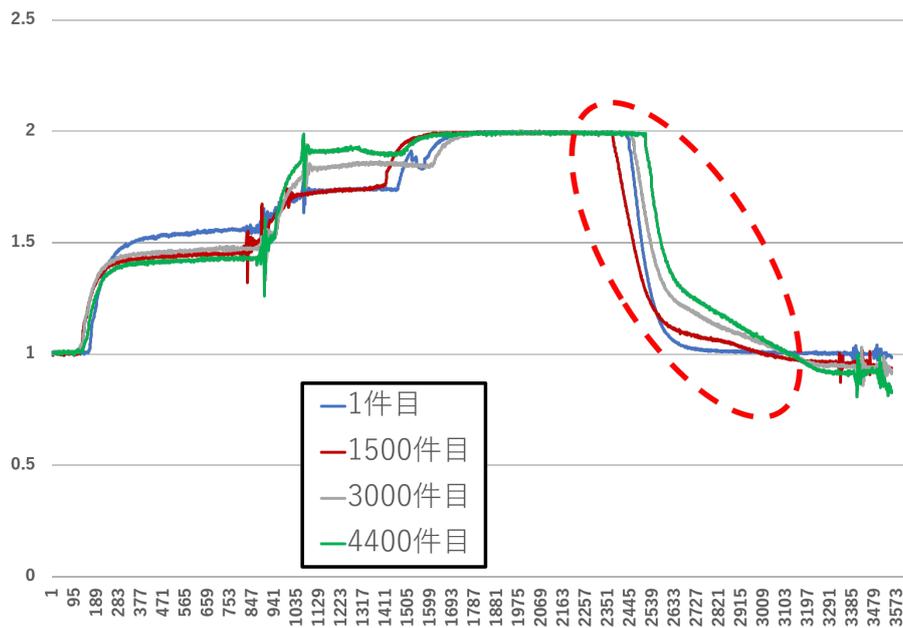


図4 補正後の波形

## 4.2 特徴量抽出

4.1.3項の前処理を行った波形から，以下の5種類の特徴量を抽出する．

- 平均圧力
- 最大圧力
- 波形全体の尖度
- ピーク長
- 最大圧力から90%~5%の圧力になるまで(圧力降下)にかかる時間

図5にどのように波形から特徴量を抽出するかを示す．はんだ溶融以前は全はんだ付けで共通であり，溶融以降ではんだの成否が主に決まると考えられる．そのため，その部分を効果的に抽出できる特徴量を選択した．

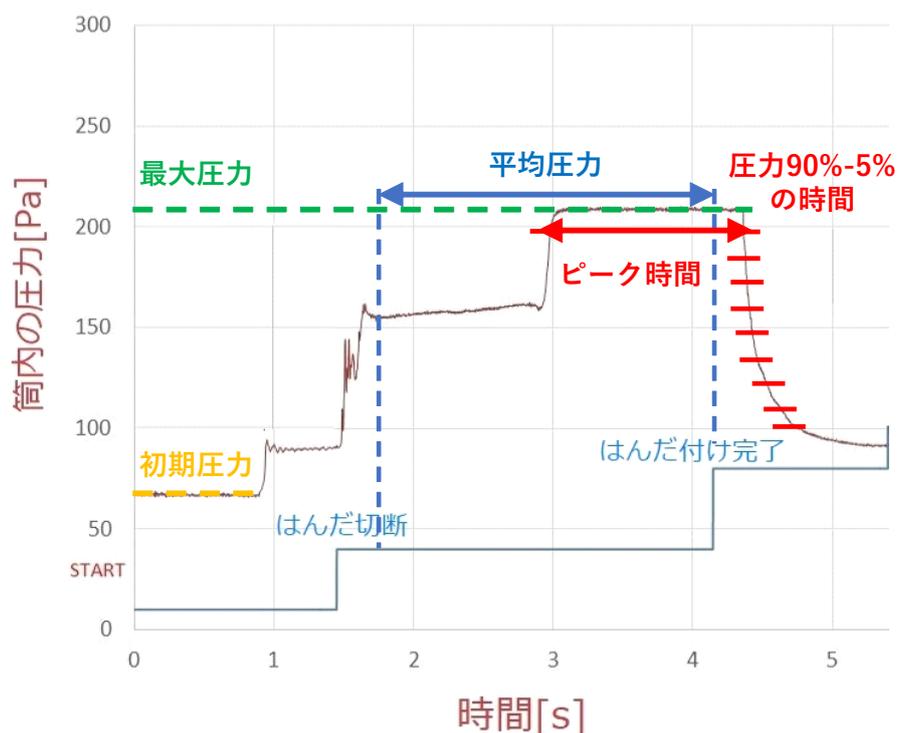


図5 波形からの特徴量抽出

#### 4.2.1 平均圧力

平均圧力は、はんだ片落下からはんだ付け完了までの圧力値の平均を取ったものである。はんだ切断の信号を受け取って0.2秒後から、はんだ完了の信号を受け取るまでの範囲の圧力値で平均を算出する。

はんだが溶けると、溶けたはんだが基板の穴を塞ぎ圧力が上昇することから、平均圧力を求めることではんだの溶け具合を特徴として扱うことができる。はんだの溶け具合によってはんだの成否は異なるため識別できると考えられる。なお、波形に対し補正式を適用すると、それぞれの圧力値は1波形での相対的な値(1~2の範囲)になる。そのため補正をかける実環境のはんだデータの分析では抽出しない。

#### 4.2.2 最大圧力

最大圧力は、1波形における最大圧力値である。外れ値を考慮して、圧力値の上位20~40番目の平均を取り算出する。最大圧力に達するときが、はんだが最大限溶けて基板を最も塞いでいるときである。最大圧力を求めることで、はんだが溶け切った後の溶け具合を特徴として扱うことができる。これにより、はんだの溶け残りを検出でき成否の識別が可能になると考えられる。平均圧力と同じく、補正をかける実環境のはんだデータを用いる分析では抽出しない。

### 4.2.3 尖度

尖度は分布の尖り度合いを表す値であり、尖った波形ほど大きい値となる。以下の数式により算出する。

$$\frac{1}{n} \sum \left( \frac{X_i - \mu}{\sigma} \right)^4 \quad (2)$$

上記の式の通り、標準化したそれぞれの値を4乗したものの平均が尖度の値となる。波形の尖度を求めることで、波形全体を1つの値で表すことができ大まかな波形の形状を特徴として扱うことができると考えられる。これにより、溶融される時間が少ない場合に熱不足が原因で発生する不良はんだを検出できると考えられる。

### 4.2.4 ピーク長

ピーク長ははんだが溶けて最大圧力に達した後、最大圧力値を持続した時間である。算出方法として、最初に「最大圧力\*0.9」となる点を始点とし、再び「最大圧力\*0.9」となる点を終点とする。始点と終点における時間の差分を圧力のピーク長として算出する。圧力がピーク長を求めることによって、基板のスルーホールが溶けたはんだによって埋まっている時間を表すことができる。これにより、はんだがどのように溶けているかを特徴として扱うことができ、尖度と同じく溶融される時間が少ない場合に熱不足が原因で発生する不良はんだを検出できると考えられる。

### 4.2.5 圧力降下にかかる時間

圧力降下にかかる時間は、最大圧力値から一定の割合まで圧力値が降下するまでにかかる時間である。圧力降下にかかる時間の部分を細かく10%毎に抽出することにより、降下の傾きが求められる。これにより、はんだの基板への流れ具合を特徴として扱うことができ、溶融後に基盤にはんだが上手く流れず不良はんだとなった場合に検出できると考えられる。なお、最大圧力から90%~5%の圧力になるまでの時間のうち、10%と5%になる時間は4.3.4項の実験の際に新たに追加したものであるため、それ以降の実験でのみ用いることとする。

## 4.3 分析

### 4.3.1 概要

実験環境、実環境それぞれではんだ付けの成否を識別できるかを検証するために機械学習による分類を行う。また4.1.3項の通り、波形から筒内汚れの影響を

除去しきることにはできないため実環境のデータに対して分析を行い、筒内汚れの影響について明らかにする。

#### 4.3.2 実験環境におけるはんだ付けの分類

実験環境の全はんだデータを使い、機械学習による分類を行う。表2に作成したデータセット1を示す。データセット1に含まれるデータは、各波形に対して4.1.3項に示したカッター復帰部の削除を行ったものである。

表2 データセット1

データセット1	データ数
$Exp_{OK}$	298
$Exp_{NG}$	411
合計	709

機械学習のアルゴリズムとして、Random Forestを用いる。Random ForestはR言語のパッケージ`randomForest`を使い実装する。3.2節に示した手順で学習を行った後、分類精度の評価値としてOOB推定値を用いることで検証を行う。その際、Random Forestのハイパーパラメータである`tree`、`mtry`を適宜変更し、検証を行うことでハイパーパラメータの最適化を行う。最適化後、各学習データにおいて、そのデータが学習に使われなかった木を集め、検証用データとして分類させOOB推定値を求める。その後、各特徴量でジニ係数による重要度を算出する。

#### 4.3.3 はんだ付けデータの分析

4.1.3項に示した通り、補正式を適用した場合でも圧力減少部の形状変化を補正しきることにはできない。そのため実環境で連続的にはんだ付けを行った $Prod_{OK}$ 、 $Prod_{NG}$ のデータを用いる上で、はんだ付けの筒内汚れによる影響を分析する必要がある。 $Prod_{OK}$ 4430件に対し、件数を細かく区切り波形を比較する。それにより、どれぐらいの件数から筒内汚れの影響を強く受けるのかを調査する。

次に、各データグループ間の特徴の一致度を調査するために、階層クラスタ分析を行う。距離を算出する際に用いる特徴量は、4.3.2項の実験の結果に基づいて有用な特徴量と考えられるものとする。

始めに、 $Prod_{OK}$ 、 $Prod_{NG}$ のみを対象に分析を行い、デンドログラムを作成する。次にその結果をもとに、 $Prod_{OK}$ から筒内汚れの影響を受けているデータを除外したデンドログラムを作成し、筒内汚れの影響がない場合の他データグループとの特徴の違いを分析する。データ数が多く、個々のデータについての分析は不可能なため4つのデータグループの特徴がどれだけ異なるか、傾向に着目する。

#### 4.3.4 実環境におけるはんだ付けの分類

実環境におけるはんだ付けデータにおいて、機械学習による分類を行う。  $Prod_{OK}$  を件数で区切り、精度を比較することにより筒内汚れが機械学習の結果に与える影響を推定できると考えられる。件数の区切り方については、4.3.3に示す実験の結果をもとに決定する。

機械学習のアルゴリズムはRandom Forestを用いることとする。ハイパーパラメータは4.3.2項の実験によって最適化されたものを設定し、検証や特徴量の重要度に関する処理は同様のものを行う。

## 5 結果と考察

### 5.1 実験環境におけるはんだ付けの分類

図6に異なるハイパーパラメータを用いたときのOOB値を示す。縦軸がOOB値、横軸が $tree$ の値を表し、各グラフが $mtry$ の値を表す。最大の分類精度が得られたのは、 $tree=500$ ,  $mtry=8$ の場合でありこれ以降はこの数値をハイパーパラメータとして設定する。

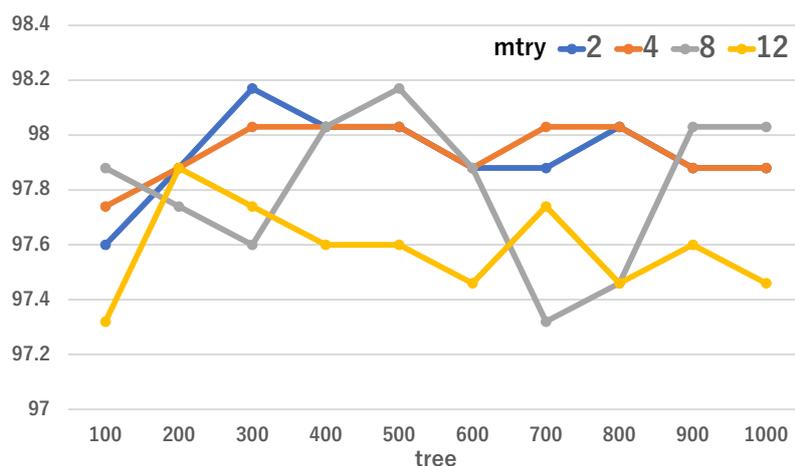


図6 各ハイパーパラメータにおけるOOB値(分類精度)

表3にデータセット1を用いた機械学習の結果を示す。分類成功とは成否を正しく分類したときのことであり、分類失敗とは成否を誤って分類したときのことである。それぞれのデータグループで分類成功、分類失敗したデータ数を示し、括弧内は分類精度を示す。各データグループで数件分類失敗しているものもあるが、比較的高い精度が得られたといえる。このことから各データグループ間に明確な特徴の違いがあり、その違いを表す特徴量の抽出が的確であったと考えられる。

表3 データセット1における機械学習の結果

データセット1	データ数	分類成功	分類失敗
$Exp_{OK}$	298	292(98.0%)	6(2.0%)
$Exp_{NG}$	411	404(98.3%)	7(1.7%)
合計	709	696(98.2%)	13(1.8%)

次に、図7にデータセット1で機械学習を行った場合の特徴量の重要度を示す。図7から圧力が20~30%になるまでの時間の重要度が高いことが分かる。このことより、 $Exp_{OK}$ と $Exp_{NG}$ は、圧力が低下しきる部分に特徴の違いがあると考えられる。



図7 データセット1における特徴量の重要度

表4に  $Exp_{OK}$  と  $Exp_{NG}$ , それぞれの圧力が20~30%になるまでの時間の平均値を示す. 表から  $Exp_{NG}$  は圧力が低下しるのが遅いことが分かる. 不良はんだの場合で溶融後にはんだが基盤に上手く流れず, 筒内を塞ぎ続けるため低下しきるまでに時間がかかると考えられる. 以上より, 圧力が低下する部分にはんだの成否を示す特徴があると考えられる.

表4 重要度の高い特徴量の平均値

平均値	30%時間	20%時間
$Exp_{OK}$	0.74	0.79
$Exp_{NG}$	1.75	1.97

## 5.2 はんだ付けデータの分析

筒内汚れの影響を分析するために  $Prod_{OK}$  の1-4400件目を500件毎に区切り, 1件目, 500件目, 1000件目のように区切りの件数に該当するデータの波形を比較する. 図8に該当のデータをグラフとして示す. 縦軸は補正後の圧力の相対的な値, 横軸はデジタル信号中の何点目かを示す. グラフは, 全体的な傾向を調べるために1-1000件目を黒, 1500件目を赤, 2000-3000件目を青, 3500-4400件目を緑で着色して比較する. はんだの成否を示す特徴があると考えられる圧力降下部に着目す

ると、降下の傾きの違いから1500件目以降は筒内汚れによる影響が大きいことが分かる。1500件目以前では降下の傾きが急であるのに対し、以降では筒内汚れの影響により傾きが緩やかである。そのため、1000-1500件目付近に波形に与える影響の変化点があると考えられる。

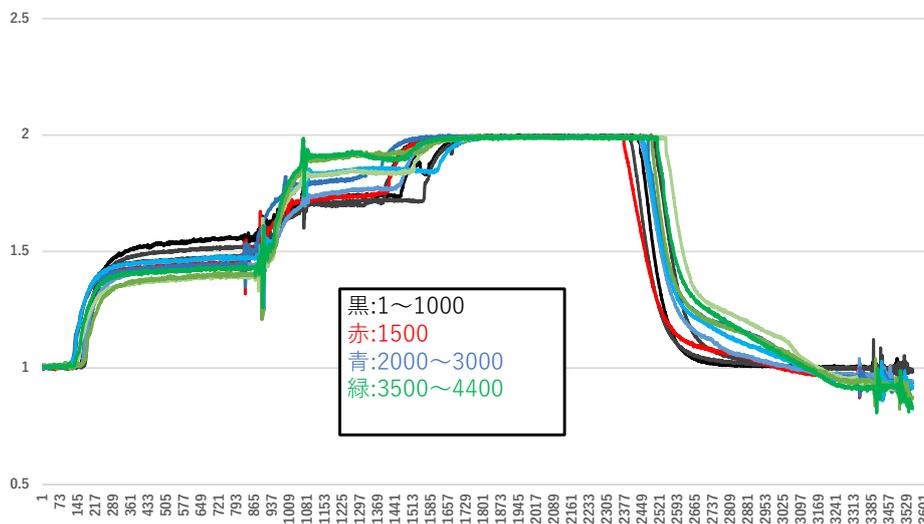


図 8 500 件毎の波形の比較

次に、1000-1500 件目を 100 件ずつ区切り、それぞれ波形を比較する。その際に、筒内汚れの影響を受けていない 1 件目、100 件目、500 件目を同時に比較する。図 9 に比較した結果をグラフとして示す。縦軸、横軸等のグラフの見方は図 8 と同様である。結果から明確な境界は見られず、変化点を明らかにすることは出来なかった。しかし、1200 件目以降は 1100 件目以前より圧力降下が緩やかである可能性があると考えられる。

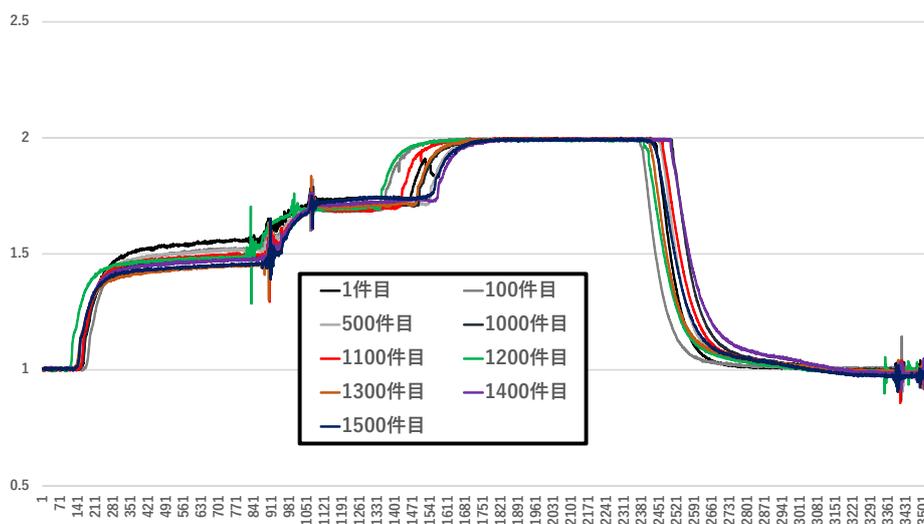


図 9 100 点区切りでの波形の比較

次に、階層クラスター分析の結果を示す。図10に  $Prod_{OK}$ ,  $Prod_{NG}$  を対象に階層クラスター分析を行った際のデンドログラムを示す。データグループ毎でラベルが重なることを避けるため、高さの差で種類分けすることとする。縦軸はデータ間の距離であり、それぞれにラベル付けがされている。また、本実験では  $Prod_{OK}$  を全体的な傾向を調べるために500件ずつ区切りラベルを付けることとした。

図から  $Prod_{OK}$  は500件ずつそれぞれのクラスターを形成し、順に件数が近いクラスターと結合していることが分かる。また、1-1500件とそれ以外ではクラスター間の距離が大きく、1-1500件の中でも1-500件のクラスターと500-1500件のクラスターに分かれる。そのため、 $Prod_{OK}$  は件数によって異なる特徴を持つことが分かる。このことから、筒内汚れによって特徴が変化しているといえる。また、デンドログラムから  $Prod_{OK}$  の1-1500件は、 $Prod_{NG}$  と距離が大きい。反対に、1500件以降には  $Prod_{NG}$  と距離が小さいデータが存在するため、機械学習の際に全ての  $Prod_{OK}$  のデータを学習すると、分類を上手く行うことができない可能性がある。

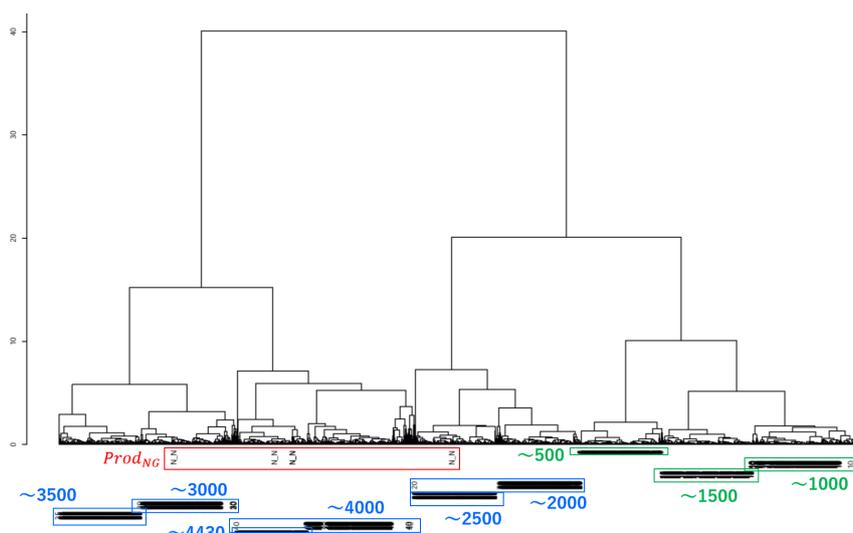


図10  $Prod_{OK}$ ,  $Prod_{NG}$  での分析

次に、図11に全てのデータグループを対象に階層クラスター分析を行った際のデンドログラムを示す。先程と同じく縦軸がデータ間の距離、横軸が各データでありそれぞれにラベル付けがされており高さの差で種類分けすることとする。また、本実験で行う分析では、 $Prod_{OK}$  を筒内汚れの影響が少ない1000件以前のみ絞り用いる。図から  $Exp_{NG}$  の一部は、 $Prod_{NG}$  との距離が小さいことから類似度が高く、似た特徴を持っていることが考えられる。そして、それらのデータは  $Prod_{OK}$  との距離が大きいため、データ数が少ない  $Prod_{NG}$  の代用として、 $Exp_{NG}$  を学習に用いることができる可能性がある。そして  $Prod_{OK}$  と、NGのデータグループとでは距離が大きく、特徴に違いがあると考えられる。

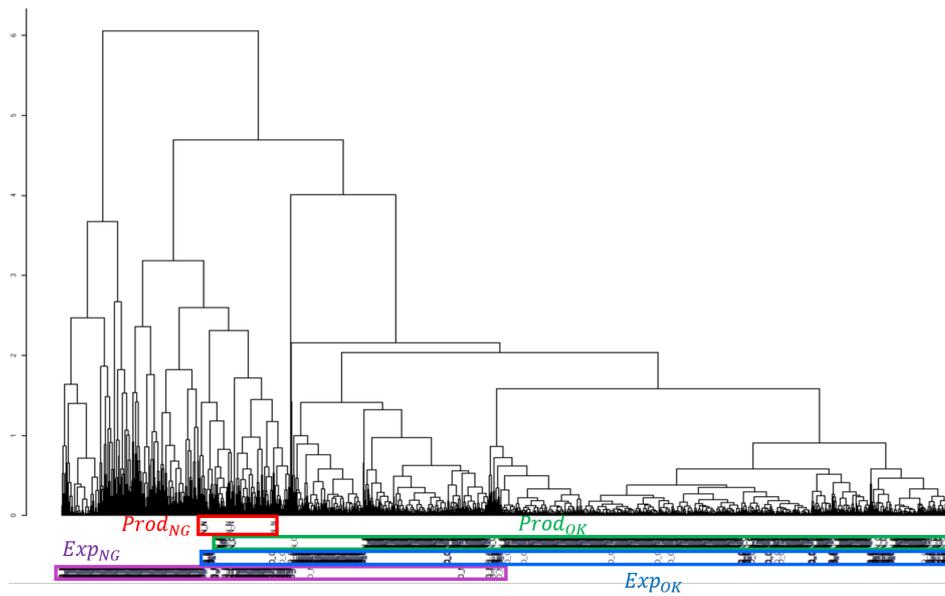


図 11 全データでの分析

### 5.3 実環境におけるはんだ付けの分類

5.1節の実験結果をもとに、データセットを作成し筒内汚れが機械学習に与える影響について分析すると同時に実環境のはんだ付けが機械学習によって分類できるかを検証する。5.1節から、1)1000-1500件目付近に筒内汚れが波形の圧力降下部に与える影響の変化点がある、2)1200件目以降は1100件目以前より圧力降下が緩やかである、3)データ数が少ない $Prod_{NG}$ の代用として実験環境NGを学習に用いることができる、という3つの可能性が示された。

そのため本実験では、 $Prod_{OK}$ の「筒内汚れの影響を受けていない(1-400件目)」、「筒内汚れの影響を多少受けているが変化点ではない(600-1000件目)」、「筒内汚れの影響の変化点である可能性が高い(900-1300件目)」をそれぞれ $Exp_{NG}$ と組み合わせ、3種類のデータセットを作成する。表5に作成したデータセット2, 3, 4を示す。これらのデータは、各波形に対して全てカッター復帰部を削除し筒内汚れの補正式による処理を行ったものである。 $Prod_{NG}$ のデータ数が5件であり、全体のデータ数と比べて少ない件数であるため本研究では学習データとしては用いず予測の検証データとして用いることとする。

表 5 データセット 2, 3, 4

	学習		予測
データセット 2	$Prod_{OK}$ 1-400 件目	$Exp_{NG}$ 411 件	$Prod_{NG}$ 5 件
データセット 3	$Prod_{OK}$ 600-1000 件目		
データセット 4	$Prod_{OK}$ 900-1300 件目		

表6, 表7, 表8それぞれにデータセット2, 3, 4での機械学習の結果を示す. データセット2, 3, 4いずれの分類精度も, 5.2節の実験で得られた98.2%と比べ向上したが, データセットのデータ数や用いたデータが異なるため良い学習をしたかどうかについては単純比較をすることはできない. また, 表6, 7, 8からどのデータセットでも精度は大きく変わらないといえる. このことから $Prod_{OK}$ の1-1500件において,  $Exp_{NG}$ と特徴が異なり, 筒内汚れの影響を受けている場合でも分類可能であると考えられる.

表9に各データセットで学習後,  $Prod_{NG}$ を予測したときの結果を示す. 表9からデータセット2の場合では5件とも予測成功, データセット3, 4の場合では4件予測成功, 1件予測失敗という結果が得られたことが分かる. このことから, 筒内汚れの影響が強いデータを学習させると $Prod_{NG}$ を上手く分類することができない恐れがあると考えられる. 要因として $Prod_{OK}$ の600件目以降では筒内汚れの影響により,  $Prod_{NG}$ 内の1データとの特徴の違いがなくなったと考えられる.

表6 データセット2における機械学習の結果

データセット2	データ数	分類成功	分類失敗
$Prod_{OK}$ (1-400件目)	400	399(99.7%)	1(0.3%)
$Exp_{NG}$	411	407(99.0%)	4(1.0%)
合計	811	806(99.3%)	5(0.7%)

表7 データセット3における機械学習の結果

データセット3	データ数	分類成功	分類失敗
$Prod_{OK}$ (600-1000件目)	400	399(99.7%)	1(0.3%)
$Exp_{NG}$	411	405(98.5%)	6(1.5%)
合計	811	804(99.1%)	7(0.9%)

表8 データセット4における機械学習の結果

データセット4	データ数	分類成功	分類失敗
$Prod_{OK}$ (900-1300件目)	400	400(100.0%)	0(0.0%)
$Exp_{NG}$	411	404(98.3%)	7(1.7%)
合計	811	804(99.1%)	7(0.9%)

表9  $Prod_{NG}$  の予測結果

データセット名	予測結果
データセット2	5/5 成功
データセット3	4/5 成功
データセット4	4/5 成功

次に、図12にデータセット2, 3, 4で機械学習を行った場合の特徴量の重要度を示す。図より最大圧力から10%の圧力になるまでにかかる時間の重要度がどのデータセットでも高いことが分かる。このことより、はんだ付けの成否を分類する場合には圧力が低下しきる部分が重要であると考えられ、はんだの成否は基盤への流れ具合により決まる可能性がある。加えて、図12からデータセット2, 3では10%時間, 20%時間の順で重要度が高いのに対し、データセット4では5%時間の重要度が特に高いことが分かる。よって、1000件以降を境に圧力波形の特徴が変わると考えられる。筒内汚れの影響は1000件以降に変化点があると考えられる。

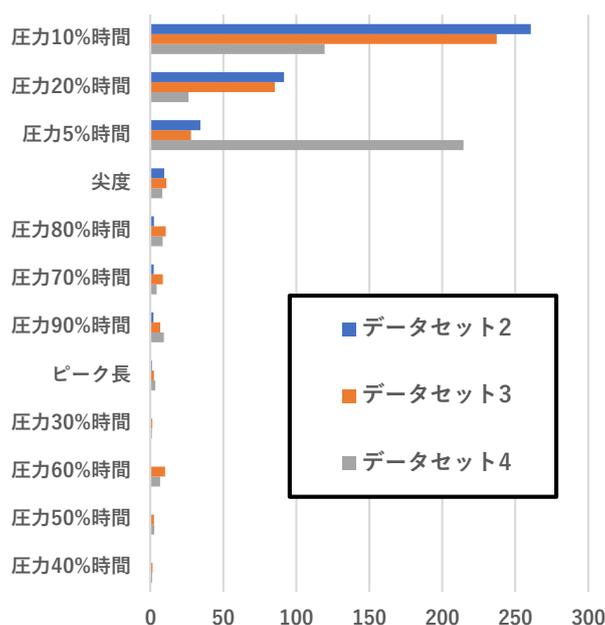


図12 データセット2, 3, 4における特徴量の重要度

実環境におけるはんだ付けの分類では高い分類精度が得られたが、 $Prod_{NG}$  のデータ数が少なく、 $Exp_{NG}$  で代用する形となった。現状のデータの成否を分類することは可能であるが実運用環境でも同様の精度が出るとはいえないため、今後実環境でさらなる検証を行うと共に  $Prod_{NG}$  のデータ数を増やす必要があると考えられる。しかし、実環境ではそもそも不良が稀にしか出ないためデータ数を大量に増やすことは難しい。そのため、実環境で不良が出る要因について分析

し不良が出やすい環境ではんだ付けを行うことにより実環境と同じ特徴を持つデータを得ることができると考えられる。

## 6 おわりに

本研究ははんだ付けロボットが行うはんだ付けの成否を識別することを目的に、はんだ部にある筒内の圧力変化から特徴量を抽出し機械学習を行った。実験環境で計測したデータセットを用いた分析の結果、はんだ部がはんだ対象物から離れた事を示す、圧力低下のタイミングが識別に重要であることが分かった。実環境での筒内汚れと各データグループの特徴に関する分析の結果、 $Prod_{OK}1-1500$ 件はNGはんだと特徴の違いがあり分類に有効である可能性があることが分かった。また、 $Prod_{OK}1-400$ 件目と、 $Exp_{NG}$ を合わせて作成したデータセットで分類を行った際に、99.3%と最も高い分類精度が得られた。実環境でも圧力低下のタイミングが識別に重要であった。

今後の研究では、 $Prod_{NG}$ のデータ数が少なく、 $Exp_{NG}$ で代用する形となったため実環境でさらなる検証を行う必要がある。検証により高精度ではんだ付けの成否を識別できると、スマートショットに本研究のアルゴリズムを用いた検査の搭載を視野に入れることができる。そのためには $Prod_{NG}$ のデータ数を増やす必要があるが、実環境で不良が出る要因を分析し、不良が出やすい環境ではんだ付けを行うことによりデータ数を増やすことができると考えられる。また、実用化に向けて更に分類精度の向上を図る必要性がある。新たに有用な特徴量を増やすことで、精度の向上及びはんだ付けにおいて重要な特徴量を明らかにすることができると考えられる。また人為的な特徴量の抽出を行わず、オートエンコーダを用いて自動的に特徴量を抽出することで分類精度が向上する可能性がある。今回用いた圧力変化と現在のはんだ付けの検査で良く行われている手法である、はんだ接合部の画像認識を組み合わせることで、より精度の高い分類を行うことができる可能性がある。

## 謝辞

本研究を進めるにあたり，多くの方々のご助力をいただきました．この場を借りてお礼を申し上げます．指導教員である上野秀剛准教授には，研究を進めるにあたって沢山の助言をいただきました．深く感謝申し上げます．査読教員である松尾賢一教授をはじめ，山口智浩教授，本間啓道講師には中間発表で大変貴重な意見を賜りました．厚く御礼申し上げます．

## 参考文献

- [1] Wu Hao, Zhang Xianmin, Hong Shiliang, “ A visual inspection system for surface mounted components based on color features. ”, Information and Automation, 2009. ICIA'09. International Conference on. IEEE, 2009: 571-576.
- [2] Lu Shenglin, Zhang Xianmin, “ Analysis and optimal design of illuminator for lead free tin solder joint inspection. ”, Optics And Precision Engineering, 2008, 16(8): 1377-1383.
- [3] Xie Hongwei, Zhang Xianmin, Kuang Yongcong, Ouyang Gaofei, “ Solder joint inspection method for chip component using improved AdaBoost and decision tree. ”, Components, Packaging and Manufacturing Technology, IEEE Transactions on, 2011, 1(12): 2018-2027.
- [4] Cai N, Zhou Y, Ye Q, et al., “ IC Solder Joint Inspection via Robust Principle Component Analysis. ”, IEEE Transactions on Components, Packaging and Manufacturing Technology, 2017, 7(2): 300-309.
- [5] Benedek C, Krammer O, Janóczki M, et al., “ Solder paste scooping detection by multilevel visual inspection of printed circuit boards. ”, Industrial Electronics, IEEE Transactions on, 2013, 60(6): 2318-2331.
- [6] Wu Fupei, Zhang Xianmin, Kuang Yongcong, Zhenzhen He., “ An AOI algorithm for PCB based on feature extraction Inspection. ”, 7th World Congress on Intelligent Control and Automation, 2008: 240-247.
- [7] Wu Fupei, Zhang Xianmin, Kuang Yongcong, Gaofei Ouyang., “ Robust Positioning Algorithm of Lead-Free Solder Joints Based on Gray-Level Integration Projection. ”, Journal of South China university of technology (nature science edition), 2009, 37(9): 99-102.
- [8] Wu Fupei, Zhang Xianmin, “ Feature-extraction-based inspection algorithm for IC solder joints. ”, Components, Packaging and Manufacturing Technology, IEEE Transactions on, 2011, 1(5): 689-694.
- [9] Wu Hao, Xu Xiangrong, “ Solder joint inspection using eigensolder features ”, Soldering and Surface Mount Technology, 2018, 30(4): 227-232.
- [10] Dom, Byron E., Virginia H.Brecher, Raymond Bonner, John S. Batchelder, and Robert S. Jaffe. , “ A system for automatic patterned wafer inspection. ”, Machine Vision and Applications, 1988: 205-221.
- [11] Yoda Haruo, Yozo Ohuchi, Yuzo Taniguchi, and Masakazu Ejiri., “ An automatic wafer inspection system using pipelined image processing techniques. ”, IEEE Trans. Pattern Analysis and Machine Intelligence, 1988, 1: 4-16.

- [12] Wu Hao, Zhang Xianmin, Hong Shiliang, “ Automatic Recognition and Location of Printed Solder Paste Base on Rough Set. ”, Journal of Test and Measurement Technology, 2009, 5(23): 423-428.
- [13] 松嶋道也, 福本信次, 藤本公三, “ はんだ接合部のニューラルネットワーク視覚検査における主成分分析を用いた入力次元数削減効果”, エレクトロニクス実装学会誌, 2013, 16(3): 206-210.
- [14] Wu Hao, “Solder joint defect classification based on ensemble learning. ”, Soldering & Surface Mount Technology, 2017, 29(3): 164-170.
- [15] Liu Meiju, Li Lingyan, Guo Wenbo, “The Improved K-nearest Neighbor Solder Joints Defect Detection ”, Proceedings of the 6th International Conference on Electronic, Mechanical, Information and Management Society, 2016: 651-657.
- [16] 古林せなみ, 今井健, 石原三四郎, 藤生克仁, 大江和彦, “深層学習を用いた心電図波形の正常異常判定に関する研究”, 医療情報学会・人工知能学会 AIM 合同研究会資料, 2018, 5(5): 1-5.
- [17] 菊池栞, 加藤広大, 山田竜平, 山本幸生, 廣田雅春, 横山昌平, 石川博, “深発月震源分類に適した機械学習法の研究”, 宇宙科学情報解析論文集, 2016, 6: 51-62.
- [18] L.Breiman, “ Random Forests. ”, Journal of Machine Learning, 2001, 45(1): 5-32.
- [19] 大橋亮太, 上野秀剛, 門田暁人, 荒木健史, 山田欣吾, 松本健一, “自動計測データと機械学習に基づくソフトウェア開発の作業目的の推定”, コンピュータソフトウェア, 2016, 33(2): 139-150.
- [20] 能島暢呂, 久世益充, 高島拓也, “地震動の経時特性の特徴抽出と階層的クラスタ分析による分類”, 日本地震工学会論文集, 2017, 17(2): 128-141.