

システム創成工学専攻
情報システムコース

Department of Systems Innovation
Advanced Information System Course

令和3年度 専攻科特別研究論文

スリーブはんだ付け装置の圧力変化を用
いた自動検査法

Defect Classification using Pressure
Change of Sleeve Soldering Machine

指導教員名 上野 秀剛 准教授

論文提出者名 福光 嘉伸

独立行政法人 国立高等専門学校機構

奈良工業高等専門学校 専攻科

National Institute of Technology, Nara College

Faculty of Advanced Engineering

スリーブはんだ付け装置の圧力変化を用いた自動検査法

Defect Classification using Pressure Change of Sleeve Soldering Machine

福光 嘉伸
Fukumitsu Yoshinobu

独立行政法人 国立高等専門学校機構

奈良工業高等専門学校 専攻科 システム創成工学専攻 情報システムコース

大和郡山市矢田町 22 番地 (〒 639-1080)

National Institute of Technology, Nara College, Faculty of Advanced Engineering
22 Yata-cho, Yamatokoriyama, Nara 639-1080, Japan

Abstract: Solder joint significantly affects the quality of the electronic equipment. A sleeve soldering system is one of the soldering equipment. The system puts a heated ceramic sleeve over the through-hole of the print circuit board and melts the solder piece dropped into the sleeve. The system also feeds a certain amount of nitrogen gas into the sleeve continuously, and the gas goes out through the lower end of the sleeve. Therefore, pressure in the sleeve is changed by narrowing down or blocking the exit hole in each soldering process, such as the sleeve approaches to the print circuit board, drop off the solder piece, and solder melting. Here, the pressure at each process may differ between correct and incorrect soldering. In this paper, the author classifies solder filling in a through-hole and absence of back fillet from the pressure change's features. In previous study, the soldering system's developer labeled the correct and incorrect of the solder joint. However, the criterion that decides the correct/incorrect solder is different by soldering target, and other conditions. The results of the experiment show that solder filling in a through-hole are classified with 95.5% accuracy and absence of back fillet are classified with 93.3% accuracy.

Keywords: soldering, sleeve soldering, fault classification, machine learning;

関連業績リスト

1. Yoshinobu Fukumitsu, Keita Nakamichi, Hidetake Uwano, and Hiroshi Fukuoka, “Defect Classification using Pressure Change of Sleeve Soldering Machine,” ICRCA 2021: 2021 the 5th International Conference on Robotics, Control and Automation, Mar. 2021.
2. 福光 嘉伸, “スリーブはんだ付け装置の圧力変化を用いた自動検査法,” 第3ブロック専攻科研究フォーラム, 2022.

目次

1.	序論	1
2.	準備	4
2.1	スリーブはんだ付け	4
2.2	関連研究	5
3.	実験	7
3.1	データセット	7
3.2	特徴量抽出	9
3.3	分類	10
4.	結果と考察	12
5.	結論	20
	参考文献	22

目次

1.1	スリーブはんだ付け装置	1
1.2	はんだ付け不良例	2
2.1	はんだ付け中のスリーブ内の圧力変化	5
3.1	圧力変化と圧力降下にかかる時間	11
4.1	データセット 1 のチューニング結果 (SVM)	13
4.2	データセット 1 における特徴量の重要度 (Random Forest)	14
4.3	富士山形とイモはんだの圧力変化	14
4.4	データセット 2 のチューニング結果	16
4.5	データセット 3 のチューニング結果	17
4.6	データセット 2 の詳細なチューニング結果	18
4.7	データセット 3 の詳細なチューニング結果	19

表目次

3.1	取得データ	8
3.2	データセット 1	8
3.3	データセット 2	9
3.4	データセット 3	9
4.1	データセット 1 に対する予測精度	12
4.2	データセット 2 の機械学習結果	16
4.3	データセット 3 の機械学習結果	17

1. 序論

電子基板と素子を接合するはんだ付けの良否は電子機器の信頼性に大きく影響するため、はんだ付けには高い品質と信頼性が求められる [8]。そのため、はんだ接合部の不良を検出する検査は重要な工程である [1]。従来、はんだ接合部の良否は基盤に空いたスルーホールにどれぐらいはんだが充填しているか、部品側ランドにはんだがあるか (バックフィレットの有無) を基準として目視によって検査している。目視検査による不良の検出率や作業効率は作業者の経験に依存するため、経験が少ない作業者の場合に検出率が低下しやすい [7]。また、近年電子部品のサイズが小さくなったことに加えて、部品の集積度が増加したため目視検査が困難である [6]。これらのことより、人間ではなく機械が検査を行い、集積度が高い場合にも検査可能な手法の必要性が高まっている。そのため、はんだ接合部の検査を自動で行い、高品質な検査を行うことができる自動検査に関する研究 [4] が行われている。




図 1.1 スリーブはんだ付け装置



図 1.2 はんだ付け不良例

はんだ付けを行う装置の 1 つとしてスリーブはんだ付け装置がある。図 1.1 にスリーブはんだ付け装置の実装例を示す。装置は熱したスリーブをはんだ付け対象の基板のスルーホールにかぶせ、スリーブ内に落下させたはんだ片を融解する。融解したはんだはピンを伝い自重でスルーホールに入り、はんだ付けを行う。一定時間が経過したらスリーブは上昇し、次のはんだ対象に移動する。はんだ付け中のスリーブ内の圧力値は、圧力孔に取り付けられたセンサにより測定している。装置はスリーブ内を窒素ガスで満たし、はんだの酸化を防止することで溶けたはんだがスルーホールに流れやすくなり、イモはんだを防止する。また、はんだ量がばらつくと、はんだを溶かす熱量が変化するため連続したはんだ付けが安定しない。図 1.2 にはんだ量のばらつきによって生じた不良はんだ例を示す。図 1.2 の左は、はんだ不足により生じた不良はんだであり、右ははんだの過多による熱不足で生じた不良はんだである。スリーブはんだ付けでは、はんだ片の長さをスルーホールや素子に合わせて調整することで、常に適量のはんだで接合ができる。加えて、スリーブ内ではんだを融解することでボールはんだの飛散を防ぐ。

本稿はスリーブはんだ付け装置を対象としたはんだ付けの自動検査法を提案する。スリーブはんだ付け装置は、スリーブ内に一定量の窒素ガスを投入し続けており、スリーブの下端（基板に触れる側）から常にガスが漏出する。そのため、スリーブの基板への密着、はんだ片の落下、はんだ溶融といった各工程でスリーブ内の穴が狭まったり、塞がることでスリーブ内の圧力が変化する。このとき、はんだ付けの良否によって圧力の変化に違いがあると考えられる。例えば、溶融したはんだがピンを伝わらず、ピンの頭頂部でイモはんだになった場合、スリーブが上昇し基板から離れ始めても、はんだがスリーブと基板との隙間を塞ぎ続ける。一方で溶融したはんだがスルーホールに流れた場合、スリーブが上昇し始めるとスリーブと基板との隙間から窒素ガスが抜けるため圧力が低下する。

先行研究 [5] では、圧力変化の波形から特徴量抽出を行った後、機械学習によってはんだの良否を分類し、精度を評価した。実験結果よりはんだの良否間に、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に違いがあることが分かった。先行研究では、共同研究先の良否を基準とした分類を行ったが、会社や製品によりはんだの良否の検査基準は異なるため、それぞれの基準に対応した検査を行う必要がある。

本稿では、はんだ付けの圧力変化を記録し、その特徴を機械学習する。本研究の目的は、先行研究 [5] とは異なり良否ではなく、スルーホールへのはんだ充填度やバックフィレットの有無を基準としたはんだ付けの詳細な評価を行い、その精度を評価することである。提案手法は、圧力変化の中でも特に、スリーブが基板から離れる際の圧力降下を特徴として用いる。

2. 準備

2.1 スリーブはんだ付け

従来のポイントはんだ付けにはコテはんだ付け、レーザーはんだ付けがある。コテはんだ付けは、加熱したコテ先ではんだを溶かし、ピンとプリント基板の接合部に供給する方法である。レーザーはんだ付けは、レーザーがピンとプリント基板に照射し、発熱することで接合部の温度をはんだの融点まで上昇させ、装置からはんだを供給する方法である。

スリーブはんだ付けは、他のポイントはんだ付けと比較して3つの利点があり、優れた手法である。コテはんだ付けに比べはんだの広がりや濡れ性がよく、コテ先の摩耗および交換の必要がない。レーザーはんだ付けに比べ、はんだの飛散がなく、一定量のはんだ片を供給できるため、品質が安定している。また、窒素ガスが酸素を遮断することにより、はんだ表面の酸化を防ぐ特徴がある。

図 2.1 は、はんだ付けを行っている際のスリーブ内の様子や圧力変化を示す。(a)-(c)は、それぞれ (a) スリーブと基板の接触、(b) はんだ片落下、(c) 溶融途中のはんだ片を示す。(d) は良好はんだの際のスリーブ上昇を、(d') は不良はんだの際のスリーブ上昇の状態を示している。はんだ片がスリーブ上部で切断された時刻を $t = 0 \text{ s}$ とする。(a) $t = -0.57 \text{ s}$ 、(b) 0.03 s および (c) 1.2 s において圧力上昇が確認できる。また、 $t = 2.5 \text{ s}$ において圧力降下が確認できる。(a) $t = -0.57 \text{ s}$ における圧力上昇は、スリーブと基板の接触により窒素ガスの流路が狭くなるため発生する。(b) $t = 0.03 \text{ s}$ における圧力上昇は、スリーブ内にはんだ片が落下し、スリーブ内が狭くなるためである。(c) $t = 1.2 \text{ s}$ における圧力上昇は、融解したはんだがピンと基板の隙間を埋めるためである。(d),(d') $t = 2.5 \text{ s}$ における圧力降下は、はんだ付け完了後にスリーブ上昇により、窒素ガスが流れ出したためである。不良はんだの場合はイモはんだになることが多く、圧力が下がりにくい。

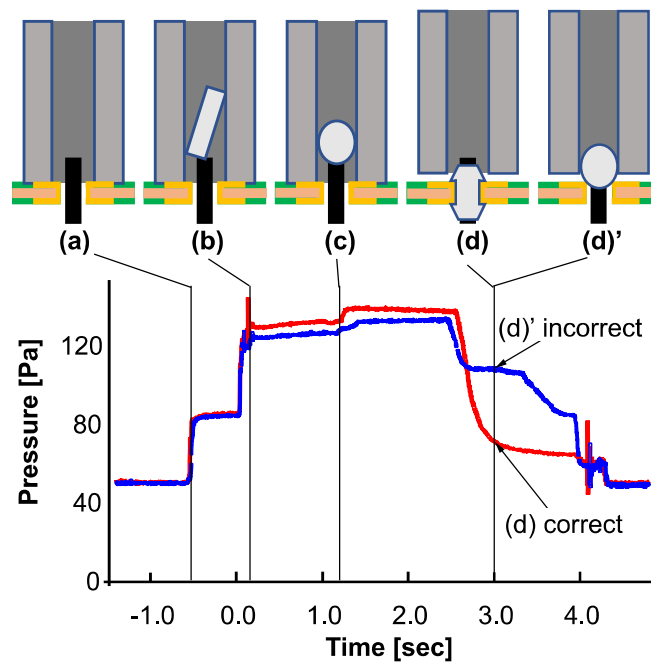


図 2.1 はんだ付け中のスリーブ内の圧力変化

2.2 関連研究

はんだ付けの良否を識別する既存研究としては、はんだ付けが完了した基板の画像から特徴量を抽出する手法が一般的である。Wu [9] は、基板画像からはんだ接合部を定位した後、画像特徴を抽出し機械学習を行った。その際、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。Random Forestの場合で、5種類の不良はんだを100%の精度で予測できた。Wentingら[3]はYOLOという物体検出手法を用いて、はんだ接合部の定位を行った後、CNNを用いて基板画像から特徴抽出をした。その後、半教師あり学習によりアノテーションコストの削減を行い、正常はんだと不良はんだの分類をした。基板画像から微小かつ間隔の狭いはんだ接合部の検出に成功し、全てのデータセットにおいてアノテーションの誤り率は1.5%未満であった。

基板画像を用いた従来研究と比較して、スリーブはんだ付け装置の圧力変化を見る提案手法にはいくつかの利点がある。画像を用いる従来手法は、装置から離れた後の基板を対象とする、post-process 評価である。そのため、基板1枚のはんだ付けが完全に終了するまで検査を行うことができない。一方で、圧力変化を用いる提案手法は基板上の個々の

スルーホールに対するはんだ付けを対象に、同じ基板の次以降のスルーホールをはんだをしている状態で in-process 評価が可能である。そのため、より早い不良はんだの検出ができ、不良が発生した場合基板の途中ではんだ付けを止めることができるため製造の効率化が可能である。また、圧力変化ははんだ付けの開始から終了までに存在する、複数の工程に関する情報を含んでいる。図 2.1 に示したように、スリーブの基板への接触や、はんだ片の投入、はんだの溶融など、1 度のはんだ付けを構成する複数の工程ごとに圧力が変化する。そのため、装置の動作タイミングと圧力変化の関係から個々の工程における異常を検出し、最終的なはんだの良否の予測に利用できる可能性があるため本稿では圧力変化を特徴量として用いる。

3. 実験

3.1 データセット

スリーブはんだ付けでの不良発生原因の 1 つである余熱不十分な状態ではんだ付けを行った時の圧力変化を計測する。実務で使う際と同様の設定ではんだ付けを行うと不良はんだが発生しにくく、学習に十分な数を実験で得ることが難しい。先行研究 [5] では、スリーブの温度と投入するはんだの量を変化させ、意図的に不良が発生しやすい環境を設定し、はんだ付けを行った。しかし、スリーブの温度やはんだ量を変化させた場合、圧力変化の特徴が実務設定と大きく異なる可能性がある。そのため本稿では、はんだ付け間の時間を空けて前回はんだ付けで温まった基板を十分に冷やすことで、余熱不十分な状態を設定し、不良はんだのデータを取得する。

はんだ付け装置として株式会社アンド製のスマートショットを用いる。図 1.1 に示すように、スリーブ上部に空けた穴から圧力センサをスリーブ内に入れ、はんだ付け時の装置の圧力を 500Hz で計測する。はんだ対象として 20*16 の計 320 個のスルーホールがあるユニバーサル基板を用いる。スルーホールは前回はんだ付けの熱の影響を受けないよう、同じ行を連続で行わず、一行ずつ開けて行う。測定したすべてのはんだ付けに対して、はんだ付け装置の開発者 1 名が目視で「スルーホールにはんだなし」「スルーホールにはんだあり」「部品側ランドにはんだあり (バックフィレットの形成)」のラベルを付与する。表 3.1 に取得した圧力波形のデータ数をラベル毎に示す。

表 3.1 の各データグループから 440 件抽出し、合計 1320 件のデータセット 1 を作成する。表 3.2 に作成したデータセット 1 を示す。 Exp_{GOOD} は「部品側ランドにはんだあり」データを、 Exp_{SUBTLE} は「スルーホールにはんだあり」データを、 Exp_{BAD} は「スルーホールにはんだなし」データを示すラベルである。件数が不均衡のとき、学習が上手く出来ない場合があるため、非復元抽出により、各データグループ同士の件数を合わせる。

また、スルーホールへのはんだの充填やバックフィレットの有無をまとめて分類する

表 3.1 取得データ

データグループ	データ数
スルーホールにはんだなし	440
スルーホールにはんだあり	2017
部品側ランドにはんだあり	669
合計	3126

表 3.2 データセット 1

データグループ名	データ数
Exp_{GOOD}	440
Exp_{SUBTLE}	440
Exp_{BAD}	440
合計	1320

データセット 1 の場合よりも分類精度が高いモデルを作成することを目的として、スルーホールへのはんだの充填とバックフィレットの有無を別々に分類基準とするデータセット 2, 3 を作成する。データセット 2, 3 により作成された分類モデルは、スルーホールへのはんだの充填とバックフィレットの有無のどちらか一方を成否の基準として使う場合に、より分類精度が高いモデルが使えるという点で有用であると考えられる。

表 3.3 と表 3.4 に作成したデータセット 2,3 を示す。 TH_{OK} は「スルーホールにはんだあり」データを、 TH_{NG} は「スルーホールにはんだなし」データを示すラベルである。 BF_{OK} は「部品側ランドにはんだあり」データを、 BF_{NG} は「スルーホールにはんだあり + スルーホールにはんだなし」データを示すラベルである。

表 3.3 データセット 2

データグループ名	データ数
TH_{OK}	450
TH_{NG}	440
合計	890

表 3.4 データセット 3

データグループ名	データ数
BF_{OK}	497
BF_{NG}	500
合計	997

3.2 特徴量抽出

スルーホールへのはんだ充填やバックフィレットの有無の区別が可能な特徴が圧力に表れると考えられる工程として、1) はんだ片の溶融、2) 溶融後のスリーブ上昇に着目する。スルーホールを埋めないはんだは、はんだ片を溶かす温度が低いと発生しやすい。温度が低いと 1) はんだ片の溶融が遅くなり、溶けたはんだがスリーブを塞ぐタイミングが遅くなる。スリーブが上昇するタイミングは一定なため、スルーホールを埋めていない場合は埋めている場合と比べて最高圧力を維持する時間長が短く、波形が尖った形状になると考えられる。そのため最高圧力を保持する時間や波形の形状を特徴量とすることで、スルーホールへのはんだ充填を分類できると考えられる。また、バックフィレットがある場合は部品側ランドまではんだが流れ込むため、2) スリーブの上昇によってより早い時間に基板との隙間ができ、圧力が早いタイミングで低下する。そのため、スリーブの上昇による圧力低下にかかる時間を特徴量とすることで、バックフィレットの有無を分類できると考えられる。

これら 2 工程におけるスルーホールへのはんだ充填やバックフィレットの有無の特徴を抽出できる特徴量として、尖度、ピーク長、圧力降下にかかる時間の 3 種類を用いる。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。そのため、1) はんだ片の溶融が遅いはんだを検出する特徴量として有用と考えられる。ピーク長ははんだが溶けて最高圧力に達した後、最大圧力値を持続した時間長である。はんだが溶け切って基板の穴を塞いでいる状態を最高圧力としたとき、最初に「最高圧力*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ピーク長として算出する。ピーク長は基板のスルーホールが溶けたはんだで埋まっている時間を表し、はんだがどのように溶けているかを反映する。そのため、1) はんだ片の溶融が遅いはんだを検出する特徴量として有用と考えられる。圧力降下にかかる時間は、最高圧力から指定の割合まで圧力が降下するのに要する時間と定義する。図 4.3 に圧力変化の例を示す。1 回のはんだづけに必要な工程が始まってから完了するまでに測定される圧力のうち、圧力計測を開始して 0.02 秒から 0.04 秒間の平均値を最低圧力と定義する。また、外れ値を考慮して、上位 20 番目から 40 番目の平均値を最高圧力と定義する。最低圧力はスリーブが基板に接触する前の状態を意味し、最高圧力はスリーブが基板に密着して、かつ、溶融したはんだがスルーホールを塞いだ（スルーホールを埋めていない場合は部分的に塞いだ）状態を意味する。また、はんだ付けが終了する際は、スリーブが基板から離れ接触する前の状態になるため最低圧力まで低下する。スリーブが基板から離れ、最高圧力から最低圧力まで低下する際、スルーホールを埋めていない場合では傾きが緩やかになるか、低下する時間が遅くなると考えられる。本稿では最高圧力を 100%、最低圧力を 0% とし、最高圧力から降下し、指定の 10 段階 (90%, 80%, ..., 10%, 5%) に到達する時間 ($T_{90\%}$, $T_{80\%}$, ..., $T_{10\%}$, $T_{5\%}$) を圧力降下の様子を表す特徴量として用いる。

3.3 分類

実験により計測した圧力データそれぞれから 3.2 節で説明した特徴量を抽出し、機械学習による分類を行う。機械学習のアルゴリズムとして、Random Forest [2] と Support Vector Machine (SVM) を用いる。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。ハイパーパラメータである *tree*, *ntry* 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、汎化性能を考慮した上で分類精度を算出するために、すべての学習データ 1 件ずつに対して、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る。SVM はデータの次元数が大きい場合でも識別精度が良いという特徴がある。ハイパーパラメー




図 3.1 圧力変化と圧力降下にかかる時間

タである σ , C は適宜変更し, 各パラメータの組み合わせで 10 点交差検証を 10 回行うことによりハイパーパラメータのチューニングを行う. σ は境界面の複雑さを表し, 値が大きいほど複雑な境界面を引く. C は誤判別をどこまで許容するかを表し, 値が大きいほど誤判別を許さない. チューニングは σ を 0.01-1.00 の範囲で 0.01 ずつ, C を 5-100 の範囲で 5 ずつ変化して全探索で精度検証を行う. 分類の評価指標として accuracy (Random Forest の場合は OOB 値) を用い, モデルの評価を行う. 本研究ではカーネルとして RBF カーネルを使用する.

4. 結果と考察

図 4.1 にデータセット 1 における SVM のチューニング結果を示す。縦軸は accuracy, 横軸は σ の値を示す。各グラフは C の値であり, 凡例に色毎の値を示す。図 4.1 から $C=10,15$ の場合に $\sigma=0.15-0.30$ の範囲で精度が高い傾向にあることが分かる。 C は 20 を境にグラフの形状が異なり, σ と C のどちらも値が大きすぎると精度が低下する。このことから, 境界面を複雑にすると過学習により汎化性能が低下し, 精度が低下すると考えられる。また, 分類に失敗しているデータとして, Exp_{GOOD} と Exp_{SUBTLE} 等の異なるデータグループの中でも同じ特徴を持つデータや, 反対に同じデータグループの中でも違う特徴を持つデータが存在する可能性がある。他にも σ の値が高く複雑な境界面を引く場合や, C の値が高く誤判別を許さない境界面を引く場合に過学習の影響で精度が低下している可能性がある。

表 4.1 にデータセット 1 に対する予測精度を示す。チューニング結果より高い精度が得られたパラメータの組み合わせ ($\sigma=0.17, C=15$) を設定する。結果より Random Forest よりも SVM の方が分類精度が高いことが分かる。SVM の精度が高かった要因として特徴量の次元数が大きい場合でも精度が良いという手法の特徴が関係していると考えられる。同じデータグループの中でも違う特徴を持つデータが存在する場合, Random Forest で決定木を作成する際に同じデータグループ内に複数の特徴が混在し, 上手く学習できない。そのため, Random Forest では精度が SVM より低くなったと考えられる。

表 4.1 データセット 1 に対する予測精度

データセット 1	accuracy
Random Forest	82.7%
SVM ($\sigma=0.17, C=15$)	87.1%




図 4.1 データセット 1 のチューニング結果 (SVM)

図 4.2 にデータセット 1 で機械学習を行った場合の Random Forest での特徴量の重要度を示す。図 4.2 から圧力が 50, 40% になるまでの時間 ($T_{50\%}, T_{40\%}$) の重要度が高いことが分かる。このことより、各データグループは、圧力が降下している中間の部分に特徴の違いがあると考えられる。これは熱不足が理由で発生するイモはんだの形状が影響していると考えられる。図 4.3 に富士山形とイモはんだの圧力変化を示す。縦軸は最低圧力を 1, 最高圧力を 2 となるよう正規化した圧力値であり、横軸は時間を示す。スリーブが上昇してもイモはんだはスリーブを部分的に塞いでいるため、降下し始めは正常な富士山形のはんだと同様に圧力が降下するが、途中からより緩やかに圧力が降下する。このことから、スルーホールを埋めるかどうかやバックフィレットが出来るかどうかは主に圧力降下の中間部分に起因すると考えられる。




図 4.2 データセット 1 における特徴量の重要度 (Random Forest)

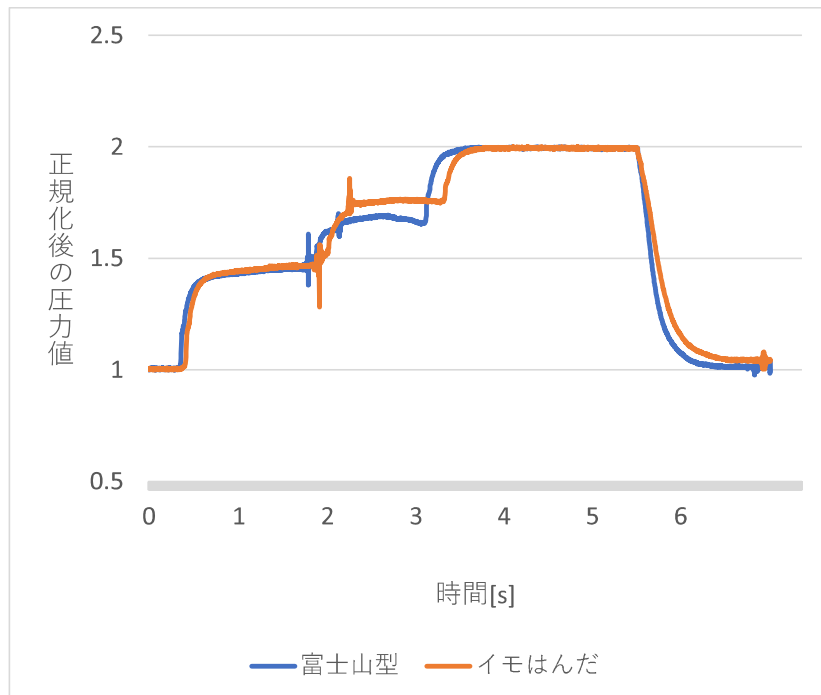


図 4.3 富士山形とイモはんだの圧力変化

図 4.4 にデータセット 2 における SVM のチューニング結果を示す。また、図 4.5 にデータセット 3 におけるチューニング結果を示す。縦軸は accuracy, 横軸は sigma の値を示す。各グラフは C の値であり、凡例に色毎の値を示す。図 4.4, 図 4.5 からデータセット 2 とデータセット 3 は共に, sigma と C の値を大きくしていく方が精度が低下することが分かる。このことから, どちらの分類でも境界面は簡単な方が高精度で分類可能であると考えられる。

次に高い精度が得られたパラメータの範囲 (sigma:0.01-0.2, C:5-15) とその前後を細かい粒度でチューニングを行う。sigma を 0.005-0.50 の範囲で 0.005 ずつ, C を 1-20 の範囲で 1 ずつ変化させて全探索で精度検証を行う。図 4.6 にデータセット 2 における SVM の詳細なチューニング結果を示す。また, 図 4.7 にデータセット 3 における詳細なチューニング結果を示す。図 4.6, 図 4.7 からどちらのデータセットも sigma と C の値が小さい場合に分類精度が高く, 大きくしていくと精度が低下することが分かる。このことから, 単純な境界面を引く方が分類しやすく, 複雑にすると過学習により分類精度が下がるといえる。単純な境界面を引く方が分類精度が高くなるのは, データセット 2,3 共に OK と NG で特徴が明確に異なるためであると考えられる。また, 境界面を複雑にしても精度が向上しないことから「OK に似た特徴を持つ NG」や「NG に似た特徴を持つ OK」が存在し, そのデータを分類失敗している可能性がある。異なるデータグループの中でも似た特徴を持つデータは, 過学習しないよう複雑な境界面を引くことが困難なため正しく分類することが難しいと考えられる。

表 4.2, 表 4.3 にデータセット 2, 3 を用いた機械学習の結果をそれぞれ示す。チューニング結果より高い精度が得られたパラメータの組み合わせを設定する。データセット 2 では sigma=0.04, C=1, データセット 3 では sigma=0.09, C=5 のパラメータを用いる。結果よりどちらのデータセットもデータセット 1 同様, Random Forest よりも SVM の方が分類精度が高いことが分かる。また, データセット 1 よりも accuracy が高いことから, 「スルーホールへのはんだ充填」・「バックフィレットの有無」はそれぞれ別で分類すると, 特徴の違いを捉えることができ高精度で分類可能であるといえる。特に, SVM は 2 クラスの分類に優れているため, Random Forest に比べ精度が高い結果が得られたと考えられる。




図 4.4 データセット 2 のチューニング結果

表 4.2 データセット 2 の機械学習結果

データセット 2	accuracy
Random Forest	94.5%
SVM (sigma=0.04, C=1)	95.5%




図 4.5 データセット 3 のチューニング結果

表 4.3 データセット 3 の機械学習結果

データセット 3	accuracy
Random Forest	89.9%
SVM (sigma=0.09, C=5)	93.3%




図 4.6 データセット 2 の詳細なチューニング結果




図 4.7 データセット 3 の詳細なチューニング結果

5. 結論

本研究はスリーブはんだ付け装置によるはんだ付けの詳細な評価を行った。提案手法はスリーブ内の圧力変化から特徴量を抽出し、機械学習によってはんだの成否を識別する。余熱不十分な環境で計測したデータセットを用いた分析の結果、「スルーホールへのはんだ充填」は95.5%、「バックフィレットの有無」は93.3%の精度で分類を行うことができた。

Future work として、本稿で分類を誤ったはんだ付けを正しく分類するための特徴量の提案・評価が挙げられる。異なるデータグループの中でも似た特徴を持つデータを分類するために、はんだ付けプロセス中のスリーブや基板の熱情報について違いがあるか分析する方法がある。熱情報には、はんだの溶け具合や流れ具合が含まれるため、違いがある場合には特徴量として追加することで本稿で分類失敗したデータを正しく分類できると考えられる。また、学習モデルの汎用化も重要な future work の1つである。様々な基板に対応した分類を行うために、基板が圧力変化に与える影響を分析する必要がある。複数の基板毎に特徴量の平均値や分散などを算出して、圧力変化をクラスタリングすることで基板特徴による圧力変化の傾向が分かり特徴量の改善が図れる。

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。

指導教員の上野准教授には，研究の知識やアドバイス，発表練習など様々な面でご指導をいただきました。査読教員である松尾賢一教授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] C. Benedek, O. Krammer, M. Janóczy, and L. Jakab, "Solder paste scooping detection by multilevel visual inspection of printed circuit boards," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 6, pp. 2318–2331, Jun. 2013.
- [2] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001.
- [3] W. Dai, A. Mujeeb, M. Erdt, and A. Sourin, "Soldering defect detection in automatic optical inspection," *Advanced Engineering Informatics*, vol. 43, p. 101004, Jan. 2020.
- [4] B. E. Dom, V. Brecher, R. Bonner, J. S. Batchelder, and R. S. Jaffe, "The p300: A system for automatic patterned wafer inspection," *Mach. Vision Appl.*, vol. 1, no. 4, pp. 205–221, Oct. 1988.
- [5] Y. Fukumitsu, K. Nakamichi, H. Uwano, and H. Fukuoka, "Defect classification using pressure change of sleeve soldering machine," *ICRCA 2021: 2021 the 5th International Conference on Robotics, Control and Automation*, Mar. 2021.
- [6] W. Fupei, and Z. Xianmin, "Feature-extraction-based inspection algorithm for ic solder joints," *IEEE Transactions on Components, Packaging and Manufacturing Technology*, vol. 1, no. 5, pp. 689–694, May 2011.
- [7] W. Fupei, Z. Xianmin, K. Yongcong, and O. Gaofei, "Robust positioning algorithm of lead-free solder joints based on gray-level integration projection," *Journal of south china university of technology (nature science edition)*, vol. 37, no. 9, pp. 99–102, Sep. 2009.
- [8] X. Hongwei, Z. Xianmin, K. Yongcong, and O. Gaofei, "Solder joint inspection method for chip component using improved adaboost and decision tree," *IEEE Transactions on Components, Packaging and Manufacturing Technology*, vol. 1, no. 12,

pp. 2018–2027, Dec. 2011.

- [9] H. Wu, “Solder joint defect classification based on ensemble learning,” *Soldering & Surface Mount Technology*, vol. 29, Jun. 2017.