

機械学習を用いたレーザー溶接における

溶け込み深さの予測とブローホール検出モデルの構築

福山 遼（情報・生産技術部加工評価グループ）

奥田 誠（情報・生産技術部システム技術グループ）

1. はじめに

レーザー溶接においては溶接条件に数多くのパラメータがあるため、狙った溶け込み深さの条件選定に多数の試作検証が必要である。さらに、代表的な溶接欠陥であるブローホールは適切な加工条件においても突発的に発生するため後工程での検査が必要である。この検査工数削減のためにインプロセスモニタリングシステムが活用されており、例えばプラズマ光や反射光による発光強度を用いた手法がある¹⁾。

近年ではアルゴリズムやコンピュータの進化によって敷居が低くなってきた機械学習を溶接技術に応用する試みが報告されるようになってきた^{2), 3)}。溶け込み深さの条件選定では、パターンや相関関係を学習したモデルを構築することで実験や試行錯誤が減少し、迅速な条件選定が可能になる。また、ブローホールの検出においては、モニタリングする発光強度から得られる特徴量を機械学習モデルで解析する手法があり⁴⁾、さらなるブローホールの検出精度の向上が求められている。

そこで、本研究では機械学習を用いたレーザー溶接における種々の加工条件を用いた溶け込み深さの予測と、加工時に発生する発光強度のモニタリング信号を用いたブローホール検出モデルの構築を目的とした。

2. 実験及び結果

図1に本研究における実験構成の概略図を示す。レーザーには、波長 1030 nm、定格出力 3 kW のディスクレーザー (TruDisk3006, TRUMPF) を $\phi 0.6$ mm に集光して用いた。供試材には SUS304 の板材 (寸法 75 mm^w × 30 mm^t × 1 mm^d) を用い、2 枚の重ね溶接を行った。レーザー溶接時の発光強度は、レーザーの分岐光学系から光ファイバーを通して、分光光学系により R、G、B、IR のそれぞれの波長ごとにフォトダイオードに取り込み、データロガーを用いて取得した。次に、レーザー溶接の実験条件を表1に示す。レーザー出力やレーザー走査速度のような基本的な加工条件に加え、シールドガス種、ギャップ (板間隙間)、レーザーのデフォーカスや照射角度を変えることで、幅広い条件下での溶け込み深さとブローホールの発生状況のサンプルを全 115 通り取得した。なお、溶け込み深さは溶接中央断面を切断した断面組織写真より測定した。また、ブローホールの位置を特定するアノテーションには図2に示すように放射線透過試験 (RT) を用いた。各サンプルの RT 像より、ブローホ

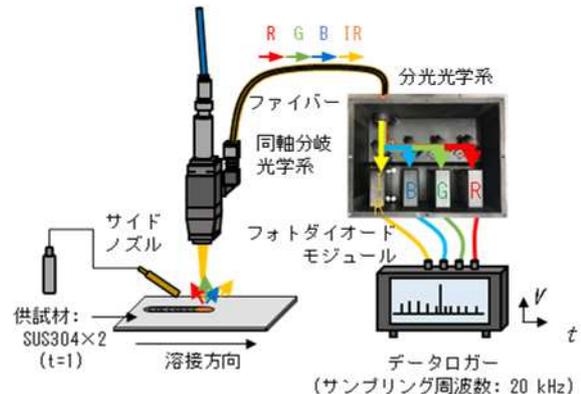


図1. レーザ溶接における発光強度測定システムの概略図

表1. レーザ溶接の実験条件

レーザー出力 [kW]	1-3
レーザー走査速度 [m/min]	1-12
供試材	SUS304
溶接長さ [mm]	50
シールドガス流量 [L/min]	20 (Ar)
	15 (N ₂)
ギャップ [mm]	0.1-0.4
デフォーカス [mm]	-1.8-+1.8
レーザー照射角度 [°]	-15-+15

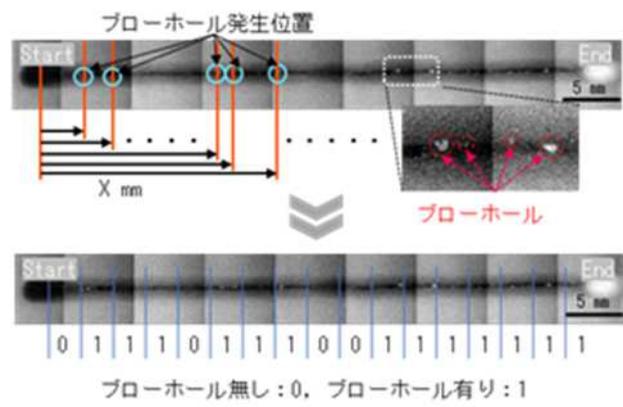


図2. ブローホール位置特定のアノテーション

ールが発生した各点の加工開始点からの距離を算出し、一定長に分割された各エレメントにおいてブローホールの発生有無を判定した。

溶け込み深さの予測については加工条件を説明変数とした。得られたデータの8割を学習用に、2割を評価用としてランダムフォレストによる教師あり学習を行った。また、ブローホール検出モデルについては発光強度の生データを低周波成分と高周波成分にフィルタ処理し、低周波成分では統計量（平均、標準偏差、最大、最小、極大の数、傾きなど）を、高周波成分ではMFCC（メル周波数ケプストラム係数）を機械学習の特徴量とした。これらの特徴量を説明変数とし、ブローホール有無の2クラス分類についてニューラルネットワークによる教師あり学習を行った。

溶け込み深さの予測を機械学習により解析した結果を図3に示す。学習データを青点、評価データを赤点でプロットしており、構築したモデルによる溶け込み深さの予測精度の平均絶対値誤差（MAE）は0.134 mmであった。

次にブローホール検出モデルの2クラス分類を機械学習により解析した評価結果を図4に示す。混合行列内の数値は評価したエレメント数であり、各セルについては左上と右下は正しく予測、右上は過検出、左下は見逃しを表している。評価した2360エレメントの中で正しく予測できているのは1998+203エレメントであり、全体の正答率は93.3%であった。検出システムで重要となるのは見逃しを最小限に抑えることであるが、80件の見逃しであった。また、実際にブローホールがあった中でブローホールが発生した割合である再現率（Recall）は71.7%であった。このとき学習に用いたデータセットは正常データ（ブローホール無し）2077エレメントに対し、異常データ（ブローホール有り）283エレメントであり、正常と異常のエレメント数が不均衡である。学習時にはモデルの過剰適合を抑えるために、溶接ビードの各エレメントに対して取り出す開始位置を前後に最大20 ms ランダムにずらしている。このような手法をエレメント内の異常データのみで改めて複数回適用することで、異常データ数の拡張を行った。拡

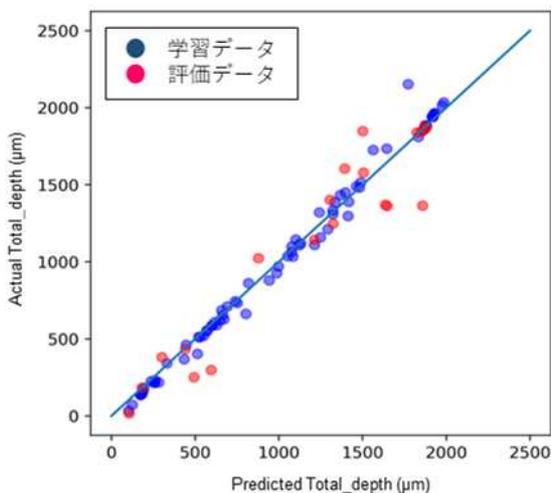


図3. 溶け込み深さの予測結果

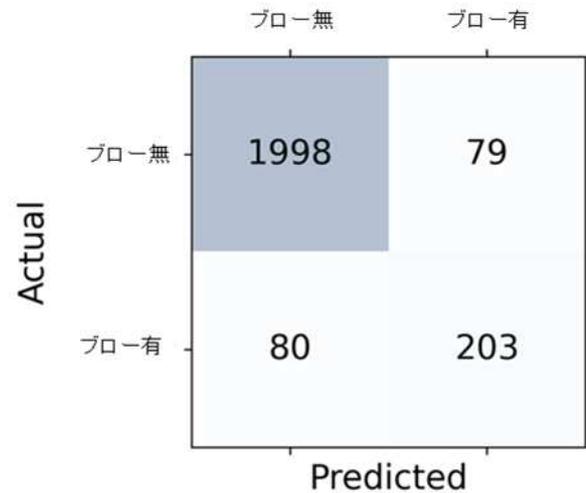


図4. ブローホール有無の2クラス分類の評価結果

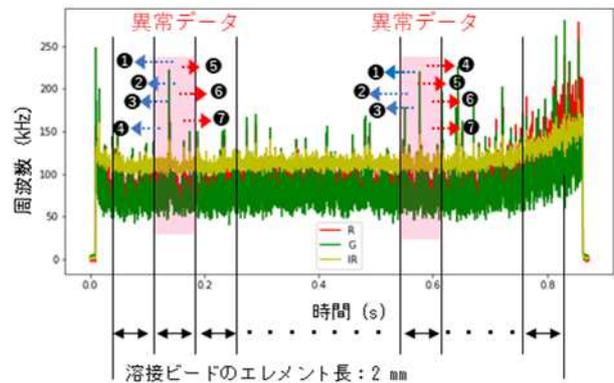


図5. 異常データとなるエレメント数の拡張のイメージ

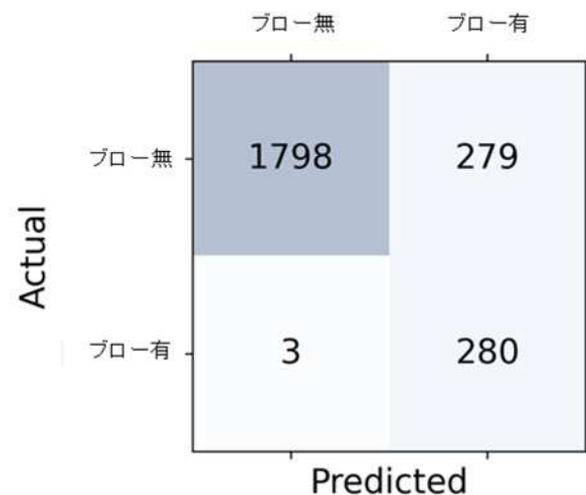


図6. 学習に用いた正常・異常のエレメント数を均衡調整したブローホール有無の2クラス分類の評価結果

張時に取り出されたデータは算出される特徴量もわずかに変化するため、全く同じデータの水増しとはならない。したがって、図5に示すように異常データ数を7倍に拡張することで、正常データ2077エレメント、異常データ1981

エレメントとなり、学習に用いる両者のエレメント数が均衡となるよう調整した。

図6に学習に用いた正常・異常のエレメント数を均衡調整したブローホール有無の2クラス分類の評価結果を示す。全体の正答率は88.1%であり、見逃しは3件に減少し、Recallは98.9%に向上した。

3. おわりに

本研究ではレーザー溶接における種々の加工条件と加工時に発生する発光強度のモニタリング信号を用いた機械学習を行い、以下の結論を得た。

■ 溶け込み深さの予測について

予測精度はMAE=0.134 mmであり、得られた予測精度は実測時の測定誤差を踏まえて、加工条件のみの説明変数で実用に耐えうる十分な予測精度であると考えられる。

■ ブローホールの検出について

予測精度はRecall=98.9%であり、発光強度に含まれる高周波成分が強いためブローホールの検出が可能と考えられる。また、本研究のように正常と異常のデータ数が不均衡の場合、データ拡張によりモデルの過剰適合を抑えられ、汎化性能の向上に有効であると考えられる。その一方

で、さらに多くの教師データを取得する方法の検討と、半教師あり学習などの適応を検討することが課題である。

【参考文献】

1. T. Tarui, K. MoriQuality assurance technology for body laser welding, Automotive Circle International, EALA2014 (2014) .
2. 芦田強、岡本陽、尾崎圭太、飛田正俊、山下隆義：溶接自動化のための画像センサ技術の開発（ディープラーニングによる画像認識）、神戸製鋼技報、68-2(2018)、63-66。
3. Dongsen, Y., Hong, G. S., Zhang, Y., Zhu, K., Hsi Fuh, J. Y.: Defect detection in selective laser melting technology by acoustic signals with deep belief networks, International Journal of Advanced Manufacturing Technology, Feb. (2018) .
4. 森清和、石川毅、薩田寿隆、奥田誠、福山遼、中村紀夫：機械学習によるレーザー溶接モニタリング技術、レーザー加工学会誌、28(2)、99-105 (2021)。

【外部発表】 口頭発表 1件