

(論文)

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)


Development of Image Sensor Technology for Automatic Welding (Image Recognition by Deep Learning)



芦田 強^{*1}
Tsuyoshi ASHIDA



岡本 陽^{*1}
Akira OKAMOTO



尾崎圭太^{*1}
Keita OZAKI



飛田正俊^{*1}
Masatoshi HIDA



山下隆義^{*2} (博士(工学))
Dr. Takayoshi YAMASHITA

A system has been developed for automatic MAG welding with ceramic backing. This system comprises a camera to capture the images of molten pools for the recognition of feature points and controlling of the torch. A deep convolutional neural network of a regression type, which outputs continuous values from image inputs, was used to recognize feature points such as arc centers and molten pools. This has enabled the accurate recognition of the distance from the arc center to the tip of the molten pool, as well as the width of the molten pool, with an average error of 0.44 mm or less. Furthermore, the formation of a proper back bead has been confirmed in a welding experiment on a test piece with a tapered (from 3 to 10 mm) gap.

まえがき = 生産現場の生産性向上によるコスト競争力の強化や熟練溶接士の高齢化による溶接士不足を補うため、近年ではロボットによる自動溶接技術は必要不可欠となっている。しかし、装置上の制約や技能面から自動化が難しく、いまだに熟練溶接士でしか行えない溶接作業が数多くある。「セラミック裏当て材あり MAG 裏波溶接」はその一つである。

MAG 溶接はガスシールドアーク溶接の一種で、細径ワイヤに大電流を通電する高電流密度の溶接法である。このため、溶接部を深く溶け込ませることができ、強度を高くすることが可能である。さらにセラミック裏当て材を利用することによって裏側をシールドするとともに、溶接ビードを保持できることから適正な裏ビードが形成され、高い強度の溶接部が安定的に得られる。この適正な裏ビードを形成することは「裏波を出す」と呼ばれる。溶融池やアークの状態を見ながら溶接を制御する必要があり、現状では熟練溶接士しか対応できないことから自動化には至っていなかった。

いっぽうで近年、一般画像認識分野ではディープラーニングと呼ばれる手法により、人や物の認識、位置推定が高精度に実現可能となってきている。そこで本稿では、この「セラミック裏当て材あり MAG 裏波溶接」にディープラーニングの技術を適用し、自動化したのでその概要を述べる。

1. セラミック裏当て材あり MAG 裏波溶接

本稿では、ギャップ幅 3~10 mm の V 型開先を有する突合せ溶接を対象に、セラミック裏当て材を装着した




図 1 セラミック裏当て材あり MAG 裏波溶接
Fig. 1 MAG penetration welding with backing material of ceramics

ものを想定した (図 1)。初層溶接では、ギャップ変動、開先角度変動、裏当て材の装着状態などによって溶融池の状態が変化する。このため、既存のプレイバック方式のロボットではアーク切れや溶け込み不良が発生し、適正な裏ビードが得られないことが多い。適正な裏ビードを形成させるためには溶融池の溜 (たま) り方やアークの状態を適正に保つ必要があり、センシングしながら、リアルタイムに電流・電圧・ワイヤ送給速度・トーチ運棒などを制御しなければならない。本開発では安定した溶接のために下記制御方針を定めた。

- ①溶融池先端付近にアークを保持するようトーチを速度制御する。
- ②溶接線ずれに対応するため、ギャップ幅中央にトーチを保持するよう左右制御する。
- ③ギャップ幅がある一定値を超えると、ギャップ幅に応じてウィービング動作をさせる。

また、上記制御を実現させるために、溶接の状態をカメラで撮像しながら溶融池先端やアーク中心位置などの座標 (特徴点) を抽出した。

*1 技術開発本部 生産システム研究所 *2 中部大学 工学部情報工学科

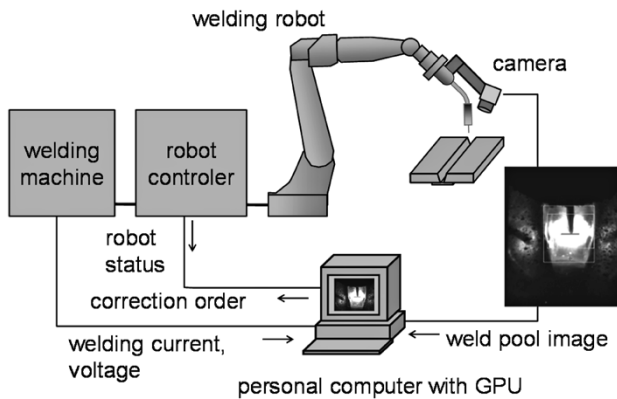


図2 システム構成
Fig. 2 System Configuration

2. 全体システム構成

システムの全体構成を図2に示す。カメラはトーチの斜め前方からアークや溶融池を撮る配置とした。PCへの画像取り込み速度は50 fpsで、20 msごとに画像特徴点を算出した。ただし、画像ごとに画像特徴量がランダムにばらつくため、過去20枚分の画像を平均して得られた平均画像特徴量から制御補正量（速度指令、トーチ左右指令、ウィービング幅指令）を演算した。制御補正量は200 msごとにロボットコントローラへ送信し、ロボットに溶接動作させた。画像特徴量算出が20 msごと過去20枚分から平均画像特徴量を取ったため200 msごとの制御補正量は400 msの移動平均値となる。

3. ディープラーニングを用いた溶融池特徴点検出

溶融池先端などを画像処理によって抽出するには、これまではエッジ抽出やラベリングといった画像特徴量を人間が組み合わせて抽出ロジックを構築するのが一般的であった。しかし、同じ対象継手形状でも、ギャップ幅や溶接条件が変化すると形状や見え方が変化し、都度、人間による画像処理ロジックの追加修正が必要となる。そこで、顔の器官検出や人の姿勢推定といった座標推定にも利用され高い認識精度を達成しているディープラーニングである回帰型Deep Convolutional Neural Network（以下、DCNNという）を使って溶融池先端やアーク中心位置などの特徴点を抽出することにした^{1), 2)}。

3.1 回帰型DCNN

処理の流れを図3に示す。濃淡画像を入力した後に、畳み込み層とバッチ正規化層、プーリング層がそれぞれ4層あり、その後に全結合層が3層あるネットワーク構成となる。最終の全結合層から出力される値は図4のようにアーク中心、ワイヤ先 endpoint、溶融池左右先 endpoint、溶融池左右端の座標値など、合計10点となる。畳み込み層はフィルタサイズ $N \times N$ の重みによる畳み込み演算を行い、畳み込まれた値 u を得る。今回、フィルタサイズは 3×3 を使用している。つぎに、その u に対して活性化関数を適用する。活性化関数は一般的にシグモイド関数やハイパボリックタンジェント関数、Rectified Linear Unit (ReLU) が用いられる。本システムでは活性化関数にReLUを用いた。このReLUは入力値 u が負

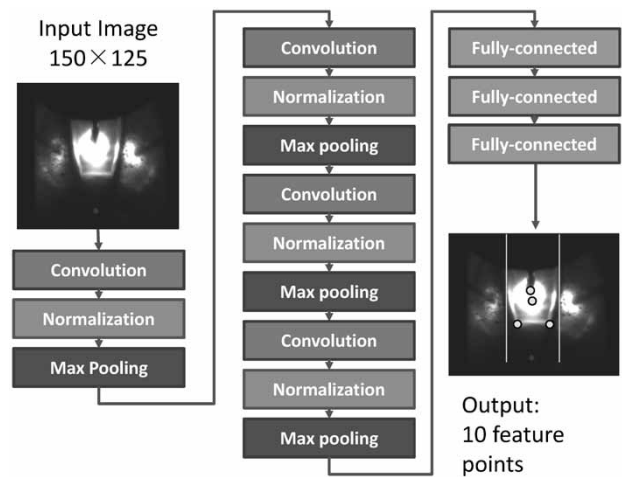


図3 回帰型畳み込みニューラルネットワーク
Fig. 3 Regression Deep Convolutional Neural Network




図4 溶融池の特徴点
Fig. 4 Feature points of molten pool

となった場合に0を返し、正の値となった場合には u をそのままの値として出力する関数である。畳み込み層、活性化関数後のバッチ正規化層では学習時に入力されるミニバッチ単位で特徴マップの要素ごとに平均0、分散1となるように正規化している³⁾。これによりアーク光のように輝度値が高い箇所の影響が少なくなり、相対的に輝度値が低い溶融池や溶接対象の板も考慮した上で出力値を得られる。プーリング層では、バッチ正規化層を通した後の特徴マップに対して収縮させる処理を行う。プーリング手法には平均値プーリングや最大値プーリングなどがある。本開発では一般的な物体認識で頻繁に使用されている 2×2 サイズの最大値プーリングを用いる。全結合層では、入力される特徴マップを1次元に変換させた後に全結合層への入力値としている。全結合層では過学習を抑制する手法であるドロップアウト⁴⁾を適用しており、ドロップアウトの確率は $p=0.5$ としている。この全結合層の出力値10個が予測する特徴点10点となる。

3.2 学習データとデータ拡張

学習データは、事前に撮像した溶接中の溶融池画像に対して、アーク中心、ワイヤ先 endpoint、溶融池左右先 endpoint、および溶融池左右端の座標値（以下、これらの座標値を特徴点という）を目視にて定めて入力した。これらの学習データは、溶接条件を変えた12回の溶接で得られた

溶接画像から2,400枚を選択して入力した。

ディープラーニングにおいては、学習データに対しては高い予測精度を得られるのに対して、学習データではないテストデータにおいて予測精度が低下することがある。この予測精度が低下する要因の一つとして、学習データとテストデータの見た目の違いが挙げられる。例えば、カメラの向きや認識対象の設置位置がずれており、学習データとテストデータで画像内の認識対象位置が異なる、あるいはカメラと認識対象との距離が異なり、学習データとテストデータとで画像内の認識対象の大きさが異なるといったことが挙げられる。

この要因による予測精度の低下を抑えるためには、見た目が違うこれらのデータも十分に収集して学習データに追加する方法がある。しかしながら、そのためには多くの実験を行い、得られた全ての画像に対して特徴点位置を人が指定する必要がある。そこで限られた学習データから認識精度を高めるためにデータ拡張を行った⁵⁾。このデータ拡張は、学習データに対して平行移動や水平垂直反転、拡大縮小といった変化を加えた画像を作成し、学習データに加える手法である。今回は、水平方向への鏡面反転、45度刻み8方向への5、10、15、20ピクセルの平行移動、および縦横方向にそれぞれ0.1刻みで0.8~1.2倍の拡大縮小を、それぞれランダムに加えることでデータ拡張を実施した。これにより、オリジナルの学習データ2,400枚とデータ拡張した9,600枚を加えた12,000枚を用意して学習を行った。

4. 評価実験

本システムの有効性を確認すべく、回帰型DCNNによる予測値の誤差と溶接実験による評価を行った。

4.1 予測値の誤差の評価

回帰型DCNNによる予測値の誤差を評価するため、従来の画像処理手法による特徴点抽出との比較を行った。従来の画像処理手法として、溶融池の輪郭となる左右下エッジをそれぞれ検出し、各エッジを曲線フィッティングによってその交点を溶融池の左右端と特定した(図5)。

学習データとは別のテストデータに対して、特徴点の抽出を基にアーク中心位置から溶融池先端までの距離Lead Y、および溶融池左右先端の距離Lead Wの算出を行い(図6)各手法で比較を行った。このLead Yと




図5 曲線フィッティングによるエッジ検出
Fig. 5 Edge detection by curve fitting

Lead Wは溶接制御に使われる重要な値である。

溶融池画像上の特徴点を目視にて選択した座標と、回帰DCNNおよび従来画像処理で抽出した特徴点の座標との誤差の平均を図7に示す。Lead Wでは従来画像処理と回帰型DCNNで同等の誤差であること、またLead Yでは従来画像処理に比べ0.3mmの改善を確認した。この改善は、従来画像処理ではスパッタを溶融池先端と誤認識していたなか、回帰DCNNでは正確に溶融池先端を認識できていることなどに起因する。

4.2 溶接実験

本システムの有効性を確認すべく、ギャップ(開先幅)がテーパ状に変動(3→10mm)するテストピースを用い、溶接最終教示点に対して、右側に10mmずらして配置して溶接実験を行った。溶接はフラックスコアードワイヤ(FCW)を用い、電流200A、電圧25V、CO₂ガスの条件で行った。テストピースの形状は図8、システム構成は図2のとおりである。トーチ先端に取り付けられたカメラから溶接の状態を撮像し、PC処理によって特徴点を抽出してLead WとLead Yを算出しており、これらの値を基に溶接速度などの制御量を決定した。溶接開始から終了までの溶接速度、Lead W、およびLead Yの変化を図9に、裏ビードを図10に示す。図8を見ると、アーク中心位置から溶融池先端までの距離Lead Yは一定の値となるように制御されているのが分かる。さらに、溶融池左右端の距離Lead Wはワークのギャップ幅と同じ値となるため、徐々に幅が広がっていることを




図6 特徴点とLead Y, Lead W
Fig. 6 Feature points and Lead Y, Lead W

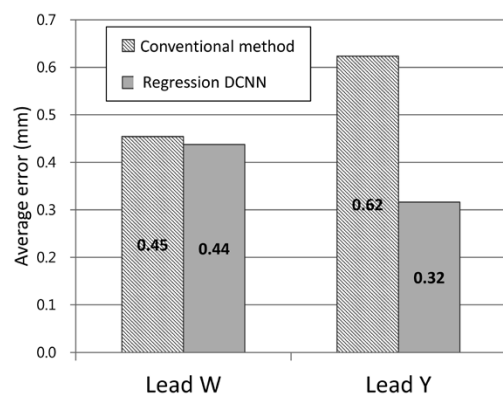


図7 特徴点の座標の平均誤差
Fig. 7 Average error of feature points' coordinates




図8 テストピース
Fig. 8 Test Piece




図9 制御パラメータの変化
Fig. 9 Changes of control parameters




図10 実験結果（裏ビードの外観）
Fig.10 Experimental result (appearance of back bead)

認識できていることが分かる。また、ギャップ幅が広がると溶融金属の溜りが遅くなるため溶接速度を遅くする必要があり、Lead Yが一定になるよう制御する必要から溶接速度も徐々に遅くなっていることが分かる。図10では左右ずれやギャップ変動があっても、適正な裏ビードが生成できていることが確認できる。

むすび＝「セラミック裏当て材ありMAG裏波溶接」を対象に、自動化のための要素技術を開発した。カメラによって撮像した溶融池を対象に、ディープラーニングによる状態認識に基づいてトーチを制御する自動溶接を行った。その結果、まだ限定した環境ではあるが、適正な裏ビードが生成できることが確認できた。今後、ディープラーニングによる対象継手の拡充や溶融池認識の汎用性向上に取り組む。

参考文献

- 1) 芦田 強ほか. 溶接学会全国大会講演概要 第101集. 2017, p.450-451.
- 2) T. Yamashita et al. "Facial Point Detection Using Convolutional Neural Network Transferred from a Heterogeneous Task", International Conference on Image Processing. 2015.
- 3) S. Ioeff et al. "Batch normalization: Accelerating deep network training by reducing internal covariate shift", ICML.
- 4) 岡谷貴之. 深層学習. 講談社, 2015, p.30.
- 5) 岡谷貴之. 深層学習. 講談社, 2015, p.35.

PDFにて本記事をご覧の方へ

図9にある動画マーク  をクリックいただくと動画が再生されます。