

溶接条件をパラメータとするディープラーニングによる自動溶接ビード外観検査手法の開発と現場適用に向けた基礎検討

渡邊, 範弘

<https://hdl.handle.net/2324/7363758>

出版情報 : Kyushu University, 2024, 博士 (工学), 課程博士
バージョン :
権利関係 :



溶接条件をパラメータとするディープラーニングに
よる自動溶接ビード外観検査手法の開発と
現場適用に向けた基礎検討

九州大学 工学府建設システム工学専攻

渡邊 範弘

2024 年 12 月

目次

第1章	緒論	1
1.1	研究の背景と目的	1
1.2	溶接欠陥推定に関する先行研究	3
1.3	本研究の構成	8
第2章	溶接条件データ並びに溶接ビード外観形状データの取得方法	9
2.1	水平すみ肉溶接試験と溶接条件データ	9
2.2	溶接ビード外観形状データの取得	16
2.2.1	二次元レーザ変位計を用いた測定	16
2.2.2	ロバスト推定法を用いた溶接ビード外観形状データの抽出	18
第3章	深層学習モデルの開発手法	26
3.1	深層学習の概要	26
3.1.1	深層学習モデルの設定	26
3.1.2	特徴量の作成	39
3.2	深層学習モデルの学習および評価に使用するデータセットの作成方法	40
3.2.1	窓の定義	42
3.2.2	窓を用いた学習, 検証, テストデータへの分割方法	43
3.3	深層学習モデルの予測精度の評価手法	47
第4章	実験室環境における適正な深層学習モデルの探索	49
4.1	標準化処理とハイパーパラメータのグリッドサーチ	49
4.2	窓大きさと窓移動量に関する検討	54
第5章	現場環境における検証	62
5.1	現場環境における実験方法	62
5.2	簡易溶接台車から取得した溶接機出力ログデータを用いた溶接欠陥の推定	72
5.3	考察	76
第6章	結論	78
	謝辞	80
	参考文献	81

第1章 緒論

1.1 研究の背景と目的

主要な国内造船所では、ラインウェルダなどの自動溶接機を導入することで、一定の溶接施工の自動化が達成されている。しかしながら、溶接後の溶接外観検査は目視に依存しており、全数検査が必要なため、検査そのものに多くの時間を要するだけでなく、短期間で正確な検査を行える検査員の育成が必要である。造船所での自主検査段階では溶接欠陥を見落とす場合もあり、後の船級検査や船主監督検査で欠陥を指摘されると後戻り工程としての補修作業が発生するため、生産効率の低下が懸念される。また、少子高齢化の進行により、生産年齢人口（15～64 歳）が2050 年には 5,540 万人（2023 年度 7,395 万人から約 25%減）へ減少すると見込まれている¹。そのため、省人化によるコスト削減、溶接部品質の健全性確保並びに、補修工程短縮による生産効率向上を目的とした溶接検査工程自動化システムの開発が期待されている。

造船現場では、Fig. 1-1 に例示するように、溶接工程において、簡易溶接台車、ラインウェルダ、溶接ロボットが使用される。これらの機械は、溶接中は通常無監視状態で使用されるため、検査工




Fig. 1-1 Examples of automatic welding machines used in ship construction processes.

(a) Welding carriages, (b) line welders and (c) welding robots

程自動化システムを搭載することで、効果が最大化されると期待される。

近年、深層学習を用いた溶接欠陥の推定に関する研究が増加している。深層学習とは、データの背後にあるルールやパターンを学習するために、ニューラルネットワークを多層に結合して表現、学習能力を高めた機械学習の一手法である。溶接欠陥の推定に関しては、電流、電圧、ワイヤ送給速度、トーチ姿勢、狙い位置、溶融池の画像などを入力データとして学習させアンダカットなどの溶接欠陥特徴量を推定することとなる。溶融池の画像を使用する方法では、高精度な推定結果が報告されているが高性能なカメラが必要なため、製造現場への導入に際しては高コストになることが懸念される上、溶接時に発生するヒュームのため安定した画像撮影が容易でないなど、造船所への導入に向けて課題がある。また、ビード形状を撮影した画像を学習させて判定を行うシステムの場合、スラグ除去後の外観画像が必要となるため、施工中の判定は困難となる。

以上の状況を考慮し、船体建造現場に適した溶接外観判定システムでは、画像を学習データとして使用せずに、溶接パラメータ(電流、電圧など)を入力情報として溶接ビード外観形状を精度よく推定できるシステムを開発するべきであろう。

本研究では、造船所の現場で適用可能な溶接検査工程自動化システムの構築を目指し、溶接電源から出力されるログデータ(溶接電流など)と施工時に一定値として指定する溶接条件(以降、「溶接固定条件」と称する)のみを学習データとして用いた深層学習モデル(Fig. 1-2 参照)の開発と現場適用試験を実施した。




Fig. 1-2 Conceptual diagram of in-line welding inspection system.

1.2 溶接欠陥推定に関する先行研究

溶接工程における溶接現象のモニタリングに関して、インプロセスでの品質管理を目的とした欠陥検知や、自動化のための制御などこれまでに画像や溶接信号、溶接音等様々なモニタリング対象、モニタリング方法、解析手法が提案されている。

画像を使用した事例では浅井は²高度な自動溶接システムを実現するキーテクノロジーとしてセンシング技術に着目しセンサの概要、応用が期待される基本的なアーク特性を利用したアーク電流-電圧特性を利用したアークセンサと光学式センサとくに照射されたレーザ光の反射をカメラで撮像するレーザセンサと溶接部を直視する CCD カメラについての基本的な考え方と適用事例を解説した。

笠野ら³は、MAG 溶接におけるブローホールや融合不良などの溶接欠陥発生のインプロセス検知技術の実現に向けて、アーク直下と同時に周辺の溶融池を含む箇所を容易な手法で観察可能な技術を開発するために、可視～赤外線領域の波長範囲に透過波長を有した BPF (Optical Band-path Filter) を選定し、CMOS カメラ、InGaAs カメラにて溶接現象を観察した結果、定量的に観察結果を評価する手法を考案し、BPF 選定の指針を考察した。

山根らは⁴、裏当材を使用しない裏波片面溶接法について CCD カメラを持つロボット溶接システムを用い、オンラインによるギャップ検出と溶融池制御の検討を行い処理された溶融池画像からギャップを検出できることを示し、溶接中オンラインにて溶接条件を制御するフィードフォワード制御システムを構築し、実験により有用性を示した。

山根ら⁵は、スパッタやヒュームが発生しないプラズマ溶接において 12 mm の厚板開先を持つ軟鋼板の突合せ溶接を対象とし、CCD カメラにより溶融池を明瞭に観察する方法および溶接線倣い制御を検討しデジタルコントローラの構築を試行した結果、電気ノイズの影響を防ぐ為に dsPIC を活用した溶接電源の制御、パルス電流溶接の定電流期間に同期した CCD カメラのシャッタタイミング、溶融池形状の特徴を用いた溶接線位置の検出を行い、開先倣いのアルゴリズムおよび制御器の有用性を確認した。

浅井は⁶、近赤外線 CCD カメラを用いた溶融池形状の計測や CCD カメラを用いた溶接ビード表面外観検査システムの構築、これらの機能を組み合わせたパルス MAG 溶接の開先突合せ溶接およびすみ肉溶接を対象とした実用的な全自動溶接システム製作と検証、レーザスリット光センサと IR-CCD カメラを用いた固定配管狭開先 GTAW システムの構築、レーザ超音波法による内部欠陥手法を加えたインプロセス品質管理システムの構築と検証等を行った。

山崎ら⁷は、レーザ溶接での厚板狭開先溶接においてレーザ光と同軸で溶接部を撮影する CMOS カメラを使用し、開先壁、開先幅、開先中心位置を求めるシステムを考案し、模擬狭開先試

験片への溶接実験により開先深さ 15 mm 以上、開先底幅 3 mm 程度の非常に深い狭開先底部の溶接において十分な追従性能があることを確認した。

Liu ら⁸⁾は、キーホールプラズマアーク溶接において溶接プール上部を低コストの CCD カメラをベースとし調光ガラスとバンドパスフィルタリングを備えた視覚的センシングシステムを開発し、上部から溶接プールとキーホールをセンシングすることで溶け落ちを予測する方法を提案した。

Hong ら⁹⁾は、極薄板のエッジ溶接部のマイクロプラズマアーク溶接(MPAW)中に溶け込み不足を検出するために溶接プールの鮮明な画像を取得するパッシブマイクロビジョンセンサーを開発し、取得した画像から溶接プールの形状特性をリアルタイムで抽出する大津法などを用いた画像処理アルゴリズムを開発し融合不良と高い相関関係をもつパラメータを確認しインプロセス監視ならびにリアルタイム制御のためのフィードバックを提供する欠陥識別の基盤として機能することを提案した。

笠野ら¹⁰⁾は、インプロセス溶接品質管理技術開発に向け、オンラインでの適用を想定し産業用 CMOS カメラ単体で高速度カメラと外部レーザ光源を組み合わせた場合とほぼ同様のアーク直下の溶接現象を観察できること、また熔融池およびアーク挙動をとらえるために必要なフレームレートは 100 Hz 以下であることを明らかにし、一般的な産業用 CMOS カメラが適用出来る可能性を示した。

Izutani ら¹¹⁾は、亜鉛メッキ鋼板の MAG 溶接中に形成されるブローホール生成挙動を高強度 X 線イメージング装置と高速度カメラを用いて観察し、アーク下でのポロシティ欠陥とスパッタを減少させる方法を検討した。

新田は¹²⁾は、炭酸ガスアーク溶接による薄板重ねすみ肉溶接と対象とし、狙い位置のずれおよび母材間のギャップを外乱因子と想定し、CMOS カメラによる撮影と画像処理技術を用いて熔融池特徴量を抽出し、溶接品質の相関を調べ溶接品質のインプロセスモニタリングの可能性について検討し、50 mm 試験片溶接程度の短い溶接長に対しても溶接品質の評価が可能であることを示唆した。

笠野ら¹³⁾は、高精度なインプロセスブローホール発生検知技術を目的に、鋼板(SM400)T 字すみ肉溶接部に Zn リッチプライマを塗布し、MAG 溶接部に発生したガスの気泡発生現象を高速度カメラにより観察し、アーク直下の気泡発生現象を捉えることが、インプロセスでのブローホール発生検知に有効であると考察した。

Wu ら¹⁴⁾は、GMAW(Gas Metal Arc Welding)で厚さ 1 mm の鋼材を溶接した実験にて溶接電圧と電流をモニタリングし、確率密度分布(PDD)およびクラス頻度分布(CFD)へ変換したデータから自動的にファジィルールとメンバーシップ関数を用いて溶接欠陥のあるグループと欠陥の内グル

ープの分類において 92% の認識率を達成した。

Zhu ら¹⁵⁾は、狭開先溶接線倣いの為に赤外線視覚センサを用いた偏差検出システムを開発し、エッジ位置を検出するための局所パターン認識(LPR)アルゴリズムを提案し実験により検証した結果、従来の平均アルゴリズムに比べて高い検出精度と効率を持ち、検出誤差は ± 0.086 mm 以内であることを確認した。

Shao ら¹⁶⁾は、シーム幅が 0.1 mm 未満のレーザ溶接において突合せ溶接シームの特徴を正確に取得し検出するために CCD カメラ、テレセントリックレンズ、4 つのレーザーストライブプロジェクター、1 つの光学フィルターで構成されたビジョンセンサと画像処理アルゴリズムを提案しシーム幅、シーム中心位置、法線ベクトルを同時に測定し、画像処理アルゴリズムを提案し実験した結果、平均測定誤差は 0.005 mm 未満であることを確認した。

解析に機械学習や深層学習を用いた事例では、金子ら¹⁷⁾は、パルス MIG 溶接における 3.2 mm 厚の軟鋼板 SS41 の溶融池の溶け込み深さのセンシングと制御に関して 2 台の CCD シャッターカメラの溶融池前方部の表面形状画像、溶接電流、開先幅の情報からニューラルネットワークを用い溶融池の溶け込み深さを推定する方法を提案し、溶け込み深さの出力から裏ビードのファジィ制御を行い、数学モデルで表すことが困難な制御対象の計測ならびに制御にニューラルネットワークおよびファジィ制御が有用であることを示した。

Suga ら¹⁸⁾は、軟鋼薄板への TIG 溶接において溶融プールの形状と寸法を、CCD カメラを使用しニューラルネットワークを用いて取得した画像を基に溶接電流を一時的に減少させ、溶接プールの寸法を最適に制御する溶接ロボットシステムを提案構築し、その有効性を確認した。

Zhang ら¹⁹⁾は、畳み込みニューラルネットワーク(CNN) と溶接画像を使用して、ロボットアーク溶接におけるアルミニウム合金のディープラーニングベースのオンラインでの溶け込み不足の欠陥検出について検討し、アーク光からの干渉を減らさずアーク光を組み合わせた特徴を形成し活用することで画像に対する平均分類精度が 99.38% の CNN モデルを示した。

竹中ら²⁰⁾は、溶接ビード画像から深層学習を利用し欠陥を判定するシステムを構築し学習モデルは畳み込みニューラルネットワークの一つである ResNet50 が最も良い有効性を示したこと、またオーバラップ、ピンホール、アンダカットそれぞれの画像の前処理手法の有効性についても確認し、適切な閾値設定が正答率、見逃し率に対して重要であることを示した。

Huang ら²¹⁾は、GMAW (Gas Metal Arc Welding) の裏波溶接において溶接プールの画像から溶融プールの形状パラメータを抽出し、溶接電流と速度に応じたパラメータの変化を分析し裏波ビード幅を従属変数とする多変量線形回帰モデルを構築した。

Yamane ら²²⁾は、プラズマアーク溶接(PAW)において、溶接プール画像から畳み込みニューラル

ネットワーク(CNN)を使用し溶接パラメータを選択し、ギャップ変動下での溶接パラメータの適応制御を提案し、その有効性を実験により検証した。

Xia ら²³は、キーホール TIG 溶接中に HDR 溶接カメラを使用し溶融プールとキーホール画像から畳み込みニューラルネットワーク(Resnet)を使用し健全な溶接、溶け込み不足、溶け落ち、狙い位置ずれ、アンダカットを認識する監視システムを開発した。

Xu ら²⁴は、溶接ロボットにおいて、視覚センサがキャリブレーション、溶接開始点補正、溶接シーモトラッキング、溶接プールの監視、ひずみの検出、欠陥検査に視覚センサを適用した研究開発についてまとめ、画像処理アルゴリズムの改善と機械学習の応用により、精度、適用範囲、リアルタイム性に大きな進歩を遂げたことを説明し、今後の発展方向を展望し、インテリジェントなロボット溶接が実現出来ることを予想した。

山根ら²⁵は、パルス MAG 溶接を用いた一般圧延鋼材(SS400)の開先角度が 45° の下向き突合せ溶接において CMOS カメラで取得した溶融池画像から畳み込みニューラルネットワーク(CNN)の一つである ResNet50 を使用し、ギャップ変動に対する裏波ビード制御に適用する開先ルート部の溶融状態推定の有効性を確認した。

中島ら²⁶は、超音波非破壊検査の一つであるレーザ超音波可視化試験(LUVT)画像から欠陥の自動検出と位置特定のために深層学習に使用される EfficientNetB0, ResNet18, ResNet34, ResNet50 を試行し、SUS304 平板の実計測データを用いた計算機実験により SoTA モデルと比較し、欠陥のカテゴリ分類はせず、欠陥の有無のみを予測する方法が、予測性能が優れ予測に必要な計算時間も高速であることを確認した。

劉ら²⁷は、半自動溶接機を使用し溶融池だけでなく、アーク溶接過程における溶接挙動の良否を、畳み込みニューラルネットワークの一つである Resnet18 を用いて「正常」、「短絡」、「スパッタ」の3つのクラスに分類し、溶接状態を判断する方法を検証し、適切な溶接条件の提示や、溶接技能の評価を可能とすることで溶接技術教育や自動溶接の支援を行う事を提案した。

Amarnath ら²⁸は、コンピュータビジョンを使用した GTAW における溶接欠陥検出への適用に関して畳み込みニューラルネットワーク(CNN)による解法やビジョントランスフォーマーを組み込んで改善する方法等、さまざまな分野の研究の概要をまとめ紹介した。

佐藤ら²⁹は、ホットワイヤ法と高出力半導体レーザを用いたホットワイヤ・レーザ溶接法の鋳鋼狭開先多層溶接において安価な一般的な産業用 CMOS カメラを使用したインプロセスモニタリングを実験し機械学習を適用することで、開先、溶融池、ワイヤを高精度に認識・分類可能であることを示し、フィードバック位置制御や欠陥検出への適用を提案した。

画像に加え溶接条件信号や音等をモニタリング対象とした事例に関して、貝原ら³⁰は、自動

GTAW 装置(ステンレス鋼, 炭素鋼板), 機械化 GTAW(炭素鋼板, ステンレス鋼板), 機械化 GMAW(アルミニウム合金), 機械化 SAW(炭素鋼板), 半自動 GMAW(炭素鋼板)のアーカ溶接のインプロセス欠陥検出と溶接管理について, 電圧・電流・溶接速度・運棒・シールドガス等の信号や状態センサとして CCD カメラ, 音圧, 音声マイクロフォンを使用し基礎実験と適用実験を行った結果, 溶接諸因子の異常は採取した溶接信号の複数信号と関連して現れ, 総合的な判断により異常診断ができ, 溶接継手の健全性を診断する手法として統計解析手法が有効であることを示した. また配管溶接ラインの自動 GTAW で各種溶接信号画面に CCD カメラによるアーカ状態の映像とサウンドを重ねさせた IPA システムの適用実験を行い溶接条件の異常から品質異常を診断できることを確認した.

溶接条件信号や音をモニタリング対象とした事例に関して, 手島は³¹, 溶接品質リアルタイム診断システムについて, 溶接中の溶接電流, 溶接電圧, 溶接速度等の値を取得し, 各条件に対する実験的に求めた閾値を複数組み合わせた推定ルールと比較し異常状態の発生有無をリアルタイムで検知し, 溶接部の品質良否を自動的に診断する方法の考え方と応用事例を示した. また実験をしなくても基本的な閾値データベースを得ることができれば, そこからの推定で閾値が得られるようなシステムの開発が望まれた.

Zhang ら³²は, アルミニウム合金の GTAW における溶接品質のリアルタイム監視のために, アーク電圧信号を取得し, 時間領域ではウェーブレットパケット変換により, 特徴パラメータへのパルス干渉を排除し, 周波数領域では Welch 法にもとづいて信号のパワースペクトル密度を計算し特徴量を抽出し標準偏差閾値法を用いて溶接ビードの品質を検出した結果, 溶け込み不足, 溶け落ち, ガス不足による欠陥を検出できることを確認した.

Na ら³³は, 溶接パスの逸脱を防ぐ為のオンライン監視のため, MIG 溶接ロボット用のデュアルマイクアレイを使用し, アーク音の特徴を一次の重回帰分析によりアークオン信号と溶接パスの逸脱の関係を取得しデュアルマイクアレイの監視システムはパルス MIG 溶接における溶接品質管理の位置精度要件を満たすことを確認した.

Yusof ら³⁴は, 溶接プロセス中にポロシティを検出するために, API 5LX70 パイプ鋼の MIG 溶接中に取得した音響信号をヒルベルト・フーリエ変換(HHT)を用いて分析し, 表面および表面下のポロシティが存在する領域で有意なエネルギー振幅パターンを示すことを確認し, オンライン溶接欠陥検出システムの開発に寄与する可能性を示した.

以上の先行研究事例ではインプロセスモニタリングでのモニタリング対象は画像が多く用いられており, 画像を使用しない研究, さらに機械学習や深層学習を使用した事例が少ないことを確認した.

1.3 本研究の構成

本論文の概要と構成は以下としている。

第 1 章は緒論で、本研究の背景と目的、関連する先行研究の動向、研究の構成について述べる。

第 2 章では、実験手法の詳細である、水平すみ肉溶接の試験体と溶接試験の方法、使用した機器、また溶接条件と溶接ビード外観形状データの取得方法と特徴量の抽出方法に関して説明する。

第 3 章では、溶接ビード外観形状の特徴量の推定に使用した深層学習の概要、入力データの前処理である窓大きさ、窓移動量の定義、学習・検証・テストに振り分けるデータ分割時の留意点、テストデータに適用したモデルの推定精度評価方法に関して説明する。

第 4 章では、実験室環境での実験により得られたデータに対する推定精度の高い深層学習モデルの探索に使用した、データの標準化処理、深層学習のハイパーパラメータ(ニューロン数、隠れ層の数、最適化アルゴリズム)の組み合わせと学習・検証・テストで使用する入力出力データの窓大きさと窓移動量が推定精度に与える影響を検討した結果を説明した。

第 5 章では、第 4 章にて検討した深層学習モデルの探索手法を造船現場に近い環境で検証するために行った実験方法とその結果、考察を述べる。

第 6 章では、本研究で得られた結果のまとめと結論、将来課題を示す。

第2章 溶接条件データ並びに溶接ビード外観形状データの取得方法

本研究では船体構造中に多く使用される開先無しの T 継手の水平すみ肉溶接のビード外観形状のうち脚長とアンダカットを対象とし、その他の外観形状、継手、試験体の内部に存在する内部欠陥(ブローホール、スラグ巻き込み、溶け込み不足、融合不良、ビード内部の割れ等)は対象としない。

試験体製作で行った溶接試験ではトーチの姿勢並びに溶接速度のデータは設定した条件で固定しており、これを固定条件と呼ぶ。電流、電圧、ワイヤ送給速度は設定条件とともに溶接中に変動する実データをモニタリングし取得した。これらを変動条件と呼ぶ。様々なビード形状を得るため、通常の建造工程で採用される適切な溶接施工条件に加え、適正条件からあえて逸脱させた施工条件での製作を含む計 90 の試験体を製作し、上述の「変動条件」と称する溶接施工データを取得した。

溶接後の試験体は二次元レーザ変位計により、溶接ビード外観形状の三次元座標を取得し、深層学習モデルに使用する溶接ビード外観形状データを求めた。

2.1 水平すみ肉溶接試験と溶接条件データ

本研究では船体構造中に多数存在する開先無しの T 継手を評価対象とした。継手製作に際して、あらかじめ試験体両端に長さ約 5 cm の仮付けを行ない、片側 1 パスずつ順に溶接して T 継手を製作した。溶接試験は計 2 回行い、1 回目は試験方法の確認のために 5 体の試験体を使用し、2 回目は 1 回目の試験での経験を活かし試験体を軽くするために主板の幅を 500mm から 150mm へ縮小した 85 体の計 90 体の試験片を溶接した。使用した溶接試験鋼材の形状と寸法を Fig. 2-1 並びに Table 2-1 に示す。鋼種は Fig. 2-2 のミルシートに示す通り、JIS G3101 SS400 と一般的な鋼材を使用した。継手製作の様子を Fig. 2-3 に示す。

溶接電源は、ダイヘンの溶接機電源 Welbee Inverter M500 を使用し、溶接中のパラメータを取得するため Table 2-4 に示すパラメータのモニタリングが可能な Welbee シリーズウェルディングモニタ E-2560 拡張ボードキットと K-7231 PC 用ソフトウェアを溶接電源に取り付け、毎秒 100 回(0.01 秒間隔)の速度で溶接電流、溶接電圧、ワイヤ送給速度を取得し、溶接方向の座標位置は溶接速度から算出した。

各試験体の設定した溶接条件は設定溶接電流(Arc current)、設定溶接電圧(Arc voltage)、溶接速度(Travel speed)、ワイヤ突き出し量(Distance of wire aiming point)、トーチ移動角(Torch

travel angle) , トーチ動作角 (Torch work angle)がある. 一回目の試験体群の試験体毎の溶接条件を Table 2-2, 2 回目の条件を Table 2-3 に示す.




Fig. 2-1 Test piece used for the Tee shaped-joint welding.

Table 2-1 Dimension of test pieces (unit in mm)

		Dimension of test piece					
	Number of the weld test	t1	t2	B1	B2	B3	L
1st Welding Test	5	12	9	500	100	245.5	1000
2nd Welding Test	85	12	10	150	100	70	1000

注 文 書
 SHIPPER : ITOCHU MARUBENI
 注文書照会番号
 REFERENCE No.: JE6 -05H24C
 契約番号
 CONTRACT No.: 0-165-K3-1-6-CY02
 商 品 名
 COMMODITY : HOT ROLLED STEEL SHEET IN COIL
 規 格
 SPECIFICATION : JIS G3101 SS400
 特 記
 NOTE :

鋼 材 検 査 証 明 書 INSPECTION CERTIFICATE

需 要 家
 CUSTOMER : YUTAKA KOZAI/KANDA
 顧客管理番号
 CUSTOMERS CONTROL No.:

日本製鉄株式会社
 NIPPON STEEL CORPORATION
 本 社 : 〒100-8071 東京都千代田区丸の内二丁目6番1号
 HEAD OFFICE : 2-6-1 MARUNOUCHI, CHIYODA-KU, TOKYO 100-8071, JAPAN
 大 分 地 区 : 〒870-0992 大分県大分市大字路ノ関1番地
 OITA AREA : 1, NISHIMOSHI, OITA-CITY, OITA-PREF., 870-0992, JAPAN
 証 書 番 号
 CERTIFICATE No.: 20K3212607
 頁
 PAGE : 1E
 発行年月日
 DATE OF ISSUE : 2020-07-04
 194

寸 法 SIZE MM	量 数 QUAN- TITY	質 量 MASS KG	製鋼番号 CAST No.	検査番号 INSPECTION No. COIL No.	引 張 試 験 TENSILE TEST				衝 撃 試 験 IMPACT TEST				化 学 成 分 CHEMICAL COMPOSITION																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																														
					引張強さ T.S. N/MM ²	引張伸び E.L. %	断面収縮 R.A. %	断面収縮 R.A. %	平均 AVG	個々 EACH	単位 J	試験温度 TEMP	C	Si	Mn	P	S	As	Grain Size	Grain Size	Grain Size	Grain Size																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																					
6.0X1534XC	16	1	24290	ZT3331	F09846-1 F09846	G	280	437	30					16	2	44	10	10																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																									

Fig. 2-2 Mill (inspection) certificate of test pieces



Fig. 2-3 Horizontal fillet weld test




Fig. 2-4 Definition of welding position.

Table 2-2 Welding condition of 1st welding test

No.	Arc current [A]	Arc voltage [V]	Travel speed [cm/min]	Distance of wire aiming point [mm]	Torch travel angle [deg.]	Torch work angle [deg.]	wire Extension [mm]	Gas flow [L/min]
1	200	35	20	0	0	40	25	30
2	200	25	20	3	0	40	25	30
3	200	35	40	0	0	40	25	30
4	350	35	40	0	0	40	25	30
5	350	35	40	0	-20	40	25	30

Table 2-3 Welding condition of 2nd welding test

No.	Arc current [A]	Arc voltage [V]	Travel speed [cm/min]	Distance of wire aiming point [mm]	Torch travel angle [deg.]	Torch work angle [deg.]	wire Extension [mm]	Gas flow [L/min]
1	250	25	20	0	0	40	25	30
2	350	25	20	0	0	40	25	30
3	250	35	20	0	0	40	25	30
4	350	35	20	0	0	40	25	30
5	250	25	40	0	0	40	25	30
6	350	25	40	0	0	40	25	30
7	250	25	20	3	0	40	25	30
8	350	25	20	3	0	40	25	30
9	250	35	40	0	0	40	25	30
10	350	35	40	0	0	40	25	30
11	250	35	20	3	0	40	25	30
12	350	35	20	3	0	40	25	30
13	250	25	40	3	0	40	25	30
14	350	25	40	3	0	40	25	30
15	250	35	40	3	0	40	25	30
16	350	35	40	3	0	40	25	30
17	350	35	20	0	20	40	25	30
18	350	35	40	0	20	40	25	30
19	350	35	20	0	-20	40	25	30
20	350	35	40	0	-20	40	25	30
21	200	35	20	0	0	40	25	30
22	200	25	20	3	0	40	25	30
23	200	35	40	0	0	40	25	30
24	350	35	40	0	0	40	25	30
25	350	35	40	0	-20	40	25	30

26	220	25	28	0	-10	40	15	15
27	220	26	28	0	-10	30	15	10
28	220	26	38	0	0	40	20	20
29	220	26	54	1	10	50	40	35
30	220	30	28	0	0	40	40	35
31	220	30	38	0	10	50	15	10
32	220	30	54	1	-10	30	20	20
33	220	38	28	0	10	30	20	35
34	220	38	38	1	-10	40	40	10
35	220	38	38	1	-10	40	40	10
36	220	38	54	0	0	50	15	20
37	280	26	28	1	0	50	20	10
38	280	26	38	0	10	30	40	35
39	280	26	38	0	10	30	40	20
40	280	26	54	0	-10	40	15	35
41	280	30	28	0	-10	50	40	20
42	280	30	38	1	0	30	15	35
43	280	30	54	0	10	40	20	10
44	280	38	28	1	10	40	15	20
45	280	38	38	0	-10	50	20	35
46	280	38	54	0	0	30	40	10
47	150	25	42	0	5	40	20	20
48	180	25	50	0	5	40	20	20
49	200	25	55	0	5	40	20	20
50	200	25	55	0	-5	40	20	20
51	230	26	60	0	5	40	20	20
52	270	27	75	0	5	40	20	20
53	250	26	66	0	5	40	20	20
54	300	28	90	0	5	40	20	20
55	300	28	90	0	-5	40	20	20

56	180	24	45	0	5	40	20	20
57	200	26	50	0	5	40	20	20
58	230	26	55	0	5	40	20	20
59	250	26	60	0	5	40	20	20
60	250	26	60	0	-5	40	20	20
61	270	27	65	0	5	40	20	20
62	270	27	65	0	-5	40	20	20
63	300	30	70	0	5	40	20	20
64	300	30	70	0	-5	40	20	20
65	330	32	75	0	5	40	20	20
66	180	24	35	0	5	40	20	20
67	200	25	40	0	5	40	20	20
68	230	26	43	0	5	40	20	20
69	250	26	46	0	5	40	20	20
70	270	27	48	0	5	40	20	20
71	270	27	48	0	0	40	20	20
72	300	30	50	0	5	40	20	20
73	300	30	50	0	0	40	20	20
74	330	32	60	0	5	40	20	20
75	330	32	60	0	0	40	20	20
76	180	24	25	0	5	40	20	20
77	200	25	3	0	5	40	20	20
78	230	26	34	0	5	40	20	20
79	250	26	38	0	5	40	20	20
80	270	27	42	0	5	40	20	20
81	270	27	42	0	0	40	20	20
82	300	30	45	0	5	40	20	20
83	300	30	45	0	0	40	20	20
84	330	32	50	0	5	40	20	20
85	330	32	50	0	0	40	20	20

2.2 溶接ビード外観形状データの取得

2.2.1 二次元レーザ変位計を用いた測定

本研究の対象である T 継手のビード外観を測定するにあたり、測定精度は ISO5817:2023 や日本鋼船工作法精度標準(JSQS)³⁵のアンダカットの許容値を参照し、0.1 mm より高精度の測定精度が必要であると考えた。測定範囲に関しては継手位置を中心として主板、縦板側へそれぞれ 20 mm の範囲に溶接ビードがあることを想定した。

そこで本研究では、上記の測定仕様を満足するキーエンス社製の二次元レーザ変位計(LJ-V7200³⁶)のレーザヘッド Fig. 2-5, RENISHAW の Tonic T100xRGSZ リニアエンコーダシステムおよび RGSZ20 スケール³⁷Fig. 2-6 を組み合わせ溶接進行方向に対して均一な座標間隔(0.2 mm)を持つ溶接ビード断面のプロファイルの、三次元座標データ(CSV 形式)を取得した。Fig. 2-7 に測定時の様子を示す。測定結果は PSS 形式でも保存することができ、KEYENCE のソフト LJ-Navigator2 または LJ-Observer にて三次元画像(Fig. 2-8)を確認する事ができる。



Fig. 2-5 KEYENCE sensor head LJ-V7200³⁶



Fig. 2-6 RENISHAW T100x RGSZ linear encoder system³⁷




Fig. 2-7 View of 3D coordinate measurement of weld bead shape




Fig. 2-8 3D image of measured data by LJ-Navigator2

2.2.2 ロバスト推定法を用いた溶接ビード外観形状データの抽出

本研究では、溶接脚長とアンダカット (Fig. 2-9) の溶接線に沿った分布を溶接ビード外観形状データとして抽出した。溶接脚長不足は構造物の強度を低下させ、アンダカットは応力集中が発生し亀裂発生 の要因となる欠陥であるとともに設計強度を担保する上で重要な項目として、JSQS や ISO 5817 などに許容値が規定されている項目であり、造船現場においてもよく発生する欠陥である。




Fig. 2-9 Definition of weld bead shape

2.2.2.1 で取得した溶接ビード形状の三次元座標データを脚長やアンダカット深さなどの溶接ビード外観形状データに変換するプログラムを作成した。溶接継手に存在するスパッタなどのデータ処理上の外乱に強いプログラムとする必要がある。以下本研究で作成したプログラムのデータ処理手法について述べる。なお、主板側の手法について述べているが、縦板側も同様の手法で行う。

概略の流れは、二次元レーザ変位計で取得した 0.2 mm 間隔の溶接ビードに対して垂直方向の断面 2 次元データから主板近似直線、溶接止端、溶接ビード外観形状 (脚長、アンダカット) の順番で求め、溶接方向の座標は取得した断面データの順番に従い 0.2 mm 間隔で加算した値とした。

主板近似直線を求める

1. 2.2.2.1 で述べた二次元レーザ変位計で測定した溶接ビードの断面上の点群を取得する.
2. 測定点の端部から 10 点を選択し最小二乗法を用いて近似直線と近似直線の x 軸に対する角度を計算する. (Fig. 2-10 参照).





Fig. 2-10 Calculation of the angle between the approximate straight line and the x-axis at 10 points.

3. 一点ずつ点をずらしながら最後の点まで繰り返し、各近似直線と x 軸に対する角度を求める. (Fig. 2-11 参照)



➡ Repeat until the last point, shifting one point at a time, finding each approximate curve and its angle with respect to the x-axis.

Fig. 2-11 Sequentially calculate the angle between the approximate straight line and the x-axis at 10 points, shifting one point at a time.

4. 求めた全ての角度のうち、縦板側の半分の点群データで構成される角度データの頻度分布を計算し、最頻値の区間を抽出する。(Fig. 2-12 参照)




Fig. 2-12 Frequency distribution and mode of angular data consisting of half of the point cloud data on the vertical plate side.

5. さらに最頻値の区間のデータの中央値を計算し、縦板のおおよその角度と見做し、これを「縦板の基準角度」とする。(Fig. 2-13 参照)




Fig. 2-13 Definition of 'reference angle of the vertical plate'.

6. 「縦板の基準角度」に対して、 90 ± 10 deg.の範囲に入る近似直線を構成する全ての測定点を主板候補点として抽出する。(Fig. 2-14 参照)




Fig. 2-14 Candidate points of main plate

7. 抽出された測定点に対してロバスト推定法(Turkey の Biweight 法³⁸⁾)を用いて、主板の近似直線を求める。このとき最小二乗法で求める各点と近似直線の距離は y 軸方向の距離とした。また重み付けは 2 mm 以内の点を対象として、2 mm を超える点は重みを 0 として除外する。(Fig. 2-15 参照)




Fig. 2-15 Thresholds and weights for the distance between each point and the approximate line used in the robust estimation method.

8. 縦板も同様の手順を行い縦板の近似直線を求める.

以上の手順で, 断面の主板と縦板の近似曲線を求めた.

次に, Fig. 2-16 に例示する「母材の面と溶接ビードの表面が交わる点 (JISZ3001)」である溶接止端を次の手順で求める.




Fig. 2-16 Weld toe

1. 縦板から最も遠い主板の測定点から点群を 10 点ずつピックアップし, ピックアップされた点群の近似直線を最小二乗法により求める.
2. 求めた近似直線について, 以下を求める.
 - ① 近似直線と 11 点目の点との距離 d_1 (Fig. 2-17 参照)




Fig. 2-17 Distance d_1 between the approximate straight line and the 11th point.

②4 点離れた近似直線(5 点目から 13 点目で作られた近似直線)との角度 θ_2 (Fig. 2-18 参照)




Fig. 2-18 Angle θ_2 with the approximate straight line 4 points away (points 11 to 14).

③各点の主板と縦板との距離 d_{n_mp} , d_{n_vp} (Fig. 2-19 参照)




Fig. 2-19 Distance between the main plate and the vertical plate at each point

d_{n_mp} , d_{n_vp} .

④ 主板の近似直線となす角度 θ_4 [deg] (Fig. 2-20 参照)




Fig. 2-20 Angle θ_4 with the approximate straight line of the main plate.

3. 以下を満たす点を溶接止端部候補点とする

- ① $d_1 > 0.1$ mm かつ,
- ② $\theta_2 > 1^\circ$ かつ,
- ③ $1 < d_{n_vp} < 20$ mm かつ, $-1 < d_{n_mp} < 1$ mm (Fig. 2-21 参照)




Fig. 2-21 Search area of the welding toe.

かつ,

- ④ $\text{abs}(\theta_4) < 10$ [deg.]

4. 3.で求めた溶接止端部候補点の中で主板との距離が最も小さい点を溶接止端とする.
上記手順により溶接止端位置を探索した.

次に各断面の溶接ビード外観形状データであるアンダカット深さ, 脚長を求める.

アンダカット深さは溶接止端から 4 mm 以内の点群をアンダカット候補点とした. そして, アンダカット候補と主板または縦板の近似直線からの距離を算出し, 最小値をアンダカット深さとした (Fig. 2-22 参照).




Fig. 2-22 Definition of undercut depth for main plate.

脚長は主板の場合, 縦板の近似直線と主板の溶接止端の距離とした (Fig. 2-23 参照).




Fig. 2-23 Definition of leg length for main plate.

以上により, 二次元レーザ変位計にて測定した各断面の溶接ビードと主板, 縦板を含む点群の座標から深層学習に使用する脚長とアンダカット深さを求めた.

第3章 深層学習モデルの開発手法

3.1 深層学習の概要

深層学習 (Deep Learning) は、人間の脳の神経細胞の仕組みを模倣した多層構造を持つニューラルネットワークを用いて、入力データから複雑なパターンや特徴を自動的に学習する技術である。近年、特に画像認識や音声認識、自然言語処理といった分野で、従来の機械学習手法を凌ぐ性能を示しており、産業界でも広く応用されている。

ニューラルネットワークは、入力層、中間層 (隠れ層)、および出力層からなる層構造で構成されており、各層には複数のニューロンが含まれる。入力層はモデルに与えられるデータを受け取る役割を担い、隠れ層と出力層はそのデータを処理・変換していく。隠れ層と出力層にある各ニューロンは入力値に重みを乗じ、さらにバイアスを加えた値に非線形の活性化関数を適用することで出力値を計算し、それを次の層へ伝達する。この層の積み重ねにより、複雑な関係性の学習や高度な特徴の抽出が可能となる。

溶接実験における固定条件や変動条件、溶接ビード外観形状などの生データを深層学習モデルの学習や予測に使用するために加工したデータのことを「特徴量」と称する。予測や出力の対象としたい特徴量を「目的変数」と称し、目的変数に影響を与える特徴量を「説明変数」と称する。本研究においては、溶接機出力ログから抽出した各種特徴量を説明変数とし、溶接脚長またはアンダカット深さを目的変数とする深層学習モデルの開発を行う。深層学習の主な利点は、自動的に特徴抽出を行い、データ量が多い場合でも高い予測性能を発揮できる点である。特に本研究では、溶接機出力ログから抽出した多次元の特徴量を扱うため、従来の手法では難しい特徴の抽出や欠陥検知の精度をさらに向上させることを狙っている。

ここでは、使用した深層学習モデルの設定と特徴量の作成方法について説明する。

3.1.1 深層学習モデルの設定

本研究での数値解析には汎用数値解析ソフトウェア MATLAB (R2022a version) の Deep Learning Toolbox³⁹⁾ に実装されている `fitnet` を利用し、基本的な誤差逆伝播型ニューラルネットワークを構築した。また、以下に述べる深層学習モデル設定は、基本的に MATLAB の初期設定を使用した。

`fitnet` を使用したネットワークは全結合ネットワークであり、ネットワークの各層のすべてのニューロンが、次の層のすべてのニューロンと結合されているネットワークである。ネットワークによっては

各層のニューロン数は異なるケースもあるが、本研究では各層あたりのニューロン数は同じとしている。

活性化関数には、隠れ層で双曲線正接シグモイド伝達関数 (tanh 関数)、出力層で線形伝達関数を採用し、過学習を防ぐための正則化手法の一つである Dropout や各層の出力を正規化し学習を安定化させる Batch Normalization は使用せず、Nguyen-Widrow 層初期化アルゴリズム⁴⁰⁾を採用してネットワークを初期化した。また損失関数には半平均二乗誤差を使用した。

重みの更新計算手法である学習関数は MATLAB にデフォルトで実装されている 12 種類の最適化アルゴリズム⁴¹⁾を使用した。

これらの MATLAB における具体的な使用方法などは、MATLAB マニュアルなどを参照のこと。

Table 3-1 Optimization algorithm in MATLAB deep learning toolbox.

No.	English name	Japanese name	Function name
1	Levenberg-Marquardt backpropagation	レーベンバーグ・マルカート法	trainlm
2	Bayesian regularization backpropagation	ベイズ正則化	trainbr
3	BFGS quasi-Newton method	BFGS 準ニュートン法	trainbfg
4	Resilient backpropagation	弾性逆伝播法	trainrp
5	Scaled conjugate gradient backpropagation	スケーリング共役勾配法	trainsecg
6	Conjugate gradient backpropagation with Powell- Beale restarts collapse	Powell・Beale リスタート付き共 役勾配法	traincgb
7	Conjugate gradient backpropagation with Fletcher- Reeves updates	Fletcher・Powell 共役勾配法	traincgf
8	Conjugate gradient backpropagation with Polak- Ribière updates	Polak・Ribière 共役勾配法	traincgp
9	One-step secant backpropagation	1 ステップ割線法	trainoss

10	Gradient descent with momentum backpropagation	モーメント項付き勾配降下法	traingdm
11	Gradient descent with momentum and adaptive learning rate backpropagation	可変学習率勾配降下法 適応学習率を使用したモーメント項付き勾配降下法の逆伝播	traingdx
12	Gradient descent backpropagation	勾配降下法	traingd

12 種類の最適化アルゴリズムの正則化関数, 学習率, 学習スケジュール, Epoch 打ち切りなどの設定は `fitnet` の既定値を使用している. それぞれのアルゴリズムの既定値を以下に示す.

Table 3-2 Levenberg-Marquardt backpropagation⁴²

Function name in MATLAB	trainlm	
Item	Default value	Explanation
<code>net.trainParam.epochs</code>	1000	Maximum number of epochs to train
<code>net.trainParam.goal</code>	0	Performance goal.
<code>net.trainParam.max_fail</code>	6	Maximum validation failures.
<code>net.trainParam.min_grad</code>	1.00E-07	Minimum performance gradient.
<code>net.trainParam.mu</code>	0.001	Initial mu.
<code>net.trainParam.mu_dec</code>	0.1	Decrease factor for mu.
<code>net.trainParam.mu_inc</code>	10	Increase factor for mu.
<code>net.trainParam.mu_max</code>	1.00E+10	Maximum value for mu.
<code>net.trainParam.show</code>	25	Epochs between displays (NaN for no displays).
<code>net.trainParam.showCommandLine</code>	FALSE	Generate command-line output.
<code>net.trainParam.showWindow</code>	TRUE	Show training GUI.
<code>net.trainParam.time</code>	inf	Maximum time to train in seconds.

Table 3-3 Bayesian regularization backpropagation⁴³

Function name in MATLAB	trainbr	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.goal	0	Performance goal.
net.trainParam.mu	0.005	Marquardt adjustment parameter.
net.trainParam.mu_dec	0.1	Decrease factor for mu.
net.trainParam.mu_inc	10	Increase factor for mu.
net.trainParam.mu_max	1.00E+10	Maximum value for mu.
net.trainParam.max_fail	inf	Maximum validation failures.
net.trainParam.min_grad	1.00E-07	Minimum performance gradient.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.time	inf	Maximum time to train in seconds.

Table 3-4 BFGS quasi-Newton method⁴⁴

Function name in MATLAB	trainbfg	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.goal	0	Performance goal.
net.trainParam.time	inf	Maximum time to train in seconds.
net.trainParam.min_grad	1.00E-06	Minimum performance gradient.
net.trainParam.max_fail	6	Maximum validation failures.
net.trainParam.searchFcn	'srchbac'	Name of line search routine to use.
net.trainParam.scal_tol	20	Divide into delta to determine tolerance for linear search.
net.trainParam.alpha	0.001	Scale factor that determines sufficient reduction in perf.
net.trainParam.beta	0.1	Scale factor that determines sufficiently large step size.
net.trainParam.delta	0.01	Initial step size in interval location step.
net.trainParam.gama	0.1	Parameter to avoid small reductions in performance, usually set to 0.1 (see srch_cha).
net.trainParam.low_lim	0.1	Lower limit on change in step size.
net.trainParam.up_lim	0.5	Upper limit on change in step size.
net.trainParam.maxstep	100	Maximum step length.
net.trainParam.minstep	1.00E-06	Minimum step length.
net.trainParam.bmax	26	Maximum step size.

net.trainParam.batch_frag	0	In case of multiple batches, they are considered independent. Any nonzero value implies a fragmented batch, so the final layer's conditions of a previous trained epoch are used as initial conditions for the next epoch.
---------------------------	---	--

Table 3-5 Resilient backpropagation⁴⁵

Function name in MATLAB	trainrp	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.goal	0	Performance goal.
net.trainParam.time	inf	Maximum time to train in seconds.
net.trainParam.min_grad	1.00E-05	Minimum performance gradient.
net.trainParam.max_fail	6	Maximum validation failures.
net.trainParam.lr	0.01	Learning rate. T
net.trainParam.delt_inc	1.2	Increment to weight change.
net.trainParam.delt_dec	0.5	Decrement to weight change.
net.trainParam.delta0	0.07	Initial weight change.
net.trainParam.deltamax	50	Maximum weight change.

Table 3-6 Scaled conjugate gradient backpropagation⁴⁶

Function name in MATLAB	trainscg	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.goal	0	Performance goal.
net.trainParam.time	inf	Maximum time to train in seconds.
net.trainParam.min_grad	1.00E-06	Minimum performance gradient.
net.trainParam.max_fail	6	Maximum validation failures.
net.trainParam.mu	0.005	Marquardt adjustment parameter. T
net.trainParam.sigma	5.00E-05	Determine change in weight for second derivative approximation.
net.trainParam.lambda	5.00E-07	Parameter for regulating the indefiniteness of the Hessian.

Table 3-7 Conjugate gradient backpropagation with Powell-Beale restarts collapse⁴⁷

Function name in MATLAB	traincgb	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	FALSE	Generate command-line output
net.trainParam.showWindow	TRUE	Show training GUI
net.trainParam.goal	0	Performance goal
net.trainParam.time	inf	Maximum time to train in seconds
net.trainParam.min_grad	1.00E-10	Minimum performance gradient
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.searchFcn	'srchcha'	Name of line search routine to use
net.trainParam.scal_tol	20	Divide into delta to determine tolerance for linearsrch.
net.trainParam.alpha	0.001	Scale factor that determines sufficient reduction inperf
net.trainParam.beta	0.1	Scale factor that determines sufficiently large step size
net.trainParam.delta	0.01	Initial step size in interval location step
net.trainParam.gama	0.1	Parameter to avoid small reductions in performance, usually set to 0.1(see srch_cha)
net.trainParam.low_lim	0.1	Lower limit on change in step size
net.trainParam.up_lim	0.5	Upper limit on change in step size
net.trainParam.maxstep	100	Maximum step length
net.trainParam.minstep	1.00E-06	Minimum step length
net.trainParam.bmax	26	Maximum step size

Table 3-8 Conjugate gradient backpropagation with Fletcher-Reeves updates⁴⁸

Function name in MATLAB	traincgf	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	FALSE	Generate command-line output
net.trainParam.showWindow	TRUE	Show training GUI
net.trainParam.goal	0	Performance goal
net.trainParam.time	inf	Maximum time to train in seconds
net.trainParam.min_grad	1.00E-10	Minimum performance gradient
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.searchFcn	'srchcha'	Name of line search routine to use
net.trainParam.scal_tol	20	Divide into delta to determine tolerance for linearsrch.
net.trainParam.alpha	0.001	Scale factor that determines sufficient reduction in perf
net.trainParam.beta	0.1	Scale factor that determines sufficiently large step size
net.trainParam.delta	0.01	Initial step size in interval location step
net.trainParam.gama	0.1	Parameter to avoid small reductions in performance, usually set to 0.1 (see srch_cha)
net.trainParam.low_lim	0.1	Lower limit on change in step size
net.trainParam.up_lim	0.5	Upper limit on change in step size
net.trainParam.maxstep	100	Maximum step length
net.trainParam.minstep	1.00E-06	Minimum step length
net.trainParam.bmax	26	Maximum step size

Table 3-9 Conjugate gradient backpropagation with Polak-Ribière updates⁴⁹

Function name in MATLAB	traincgp	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	FALSE	Generate command-line output
net.trainParam.showWindow	TRUE	Show training GUI
net.trainParam.goal	0	Performance goal
net.trainParam.time	inf	Maximum time to train in seconds
net.trainParam.min_grad	1.00E-10	Minimum performance gradient
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.searchFcn	'srchcha'	Name of line search routine to use
net.trainParam.scal_tol	20	Divide into delta to determine tolerance for linearsrch.
net.trainParam.alpha	0.001	Scale factor that determines sufficient reduction inperf
net.trainParam.beta	0.1	Scale factor that determines sufficiently large step size
net.trainParam.delta	0.01	Initial step size in interval location step
net.trainParam.gama	0.1	Parameter to avoid small reductions in performance, usually set to 0.1(see srch_cha)
net.trainParam.low_lim	0.1	Lower limit on change in step size
net.trainParam.up_lim	0.5	Upper limit on change in step size
net.trainParam.maxstep	100	Maximum step length
net.trainParam.minstep	1.00E-06	Minimum step length
net.trainParam.bmax	26	Maximum step size

Table 3-10 One-step secant backpropagation⁵⁰

Function name in MATLAB	trainoss	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.min_grad	1.00E-10	Minimum performance gradient
net.trainParam.searchFcn	'srchbac'	Name of line search routine to use
net.trainParam.show	25	Epochs between displays (NaN for no displays)
net.trainParam.showCommandLine	FALSE	Generate command-line output
net.trainParam.showWindow	TRUE	Show training GUI
net.trainParam.time	inf	Maximum time to train in seconds
net.trainParam.scal_tol	20	Divide into delta to determine tolerance for linearsrch.
net.trainParam.alpha	0.001	Scale factor that determines sufficient reduction in perf
net.trainParam.beta	0.1	Scale factor that determines sufficiently large step size
net.trainParam.delta	0.01	Initial step size in interval location step
net.trainParam.gama	0.1	Parameter to avoid small reductions in performance, usually set to 0.1 (see srch_cha)
net.trainParam.low_lim	0.1	Lower limit on change in step size
net.trainParam.up_lim	0.5	Upper limit on change in step size
net.trainParam.maxstep	100	Maximum step length
net.trainParam.minstep	1.00E-06	Minimum step length
net.trainParam.bmax	26	Maximum step size

Table 3-11 Gradient descent with momentum backpropagation⁵¹

Function name in MATLAB	traingdm	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.lr	0.01	Learning rate
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.mc	0.9	Momentum constant
net.trainParam.min_grad	1.00E-05	Minimum performance gradient
net.trainParam.show	25	Epochs between showing progress
net.trainParam.showCommandLine	FALSE	Generate command-line output
net.trainParam.showWindow	TRUE	Show training GUI
net.trainParam.time	inf	Maximum time to train in seconds

Table 3-12 Gradient descent with momentum and adaptive learning rate backpropagation⁵²

Function name in MATLAB	traingdx	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.goal	0	Performance goal.
net.trainParam.lr	0.01	Learning rate.
net.trainParam.lr_inc	1.05	Ratio to increase learning rate.
net.trainParam.lr_dec	0.7	Ratio to decrease learning rate.
net.trainParam.max_fail	6	Maximum validation failures.
net.trainParam.max_perf_inc	1.04	Maximum performance increase.
net.trainParam.mc	0.9	Momentum constant.
net.trainParam.min_grad	1.00E-05	Minimum performance gradient.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.time	inf	Maximum time to train in seconds.

Table 3-13 Gradient descent backpropagation⁵³

Function name in MATLAB	traingd	
Item	Default value	Explanation
net.trainParam.epochs	1000	Maximum number of epochs to train.
net.trainParam.goal	0	Performance goal.
net.trainParam.showCommandLine	FALSE	Generate command-line output.
net.trainParam.showWindow	TRUE	Show training GUI.
net.trainParam.lr	0.01	Learning rate.
net.trainParam.max_fail	6	Maximum validation failures.
net.trainParam.min_grad	1.00E-05	Minimum performance gradient.
net.trainParam.show	25	Epochs between displays (NaN for no displays).
net.trainParam.time	inf	Maximum time to train in seconds.

3.1.2 特徴量の作成

3.2 節で説明する手法に従って区切られた窓データを用いて、特徴量の抽出を行った。初めに、変動条件とした溶接機から得られる 3 つの時系列データ(電流, 電圧, ワイヤ送給速度)ごとに, 平均値, 標準偏差, 尖度, 歪度, 中央値, 最大値, 最小値, 微分値の平均値, 微分値の標準偏差, 微分値の尖度, 微分値の歪度, 微分値の中央値, 微分値の最大値, 微分値の最小値, 短絡回数, アーク消失回数の 16 種類の統計量を計算し, これによって 48 次元の特徴量ベクトルを構成する (Table 3-14). 加えて, 固定条件として溶接速度, 狙い位置, トーチ角, 狙い角(仰角), ワイヤ突き出し量, シールドガス流量 (Table 3-15)を含め, 合わせて 54 次元の特徴量ベクトルを形成する。

深層学習においては, 入力値が変化しない特徴量は無視されることが知られているが, 本研究における固定条件は 1 つの試験体の中では固定値であるものの, Table 2-2, Table 2-3 に示すように試験体毎に条件を数点選択し変化させているため, 目的変数に影響があると判断し特徴量として採用した。また, 目的変数の特徴量である脚長は窓データ内の平均値, アンダカットは窓データ内の最大値を使用した。

Table 3-14 Statistics within the frame of the monitored variable conditions
(current, voltage and wire feed rate)

1	Mean value
2	Standard deviation
3	kurtosis
4	Skewness
5	Median value
6	Maximum value
7	Minimum value
8	Mean value of the derivative
9	Standard deviation of the derivative value
10	Peak value of the derivative value
11	Skewness of the derivative value
12	Median value of the derivative
13	Maximum value of the derivative
14	Minimum value of the derivative

15	Percentage of short-circuits
16	Percentage of arc loss

Table 3-15 Set values for each test piece of fixed conditions

1	Travel speed [cm/min]
2	Distance of wire aiming point [mm]
3	Torch travel angle [deg.]
4	Torch work angle [deg.]
5	wire Extension [mm]
6	Gas flow [L/min]

3.2 深層学習モデルの学習および評価に使用するデータセットの作成方法

本研究では、溶接機出力ログに含まれる電流や電圧、ワイヤ送給速度などの時系列データを用いて、目的変数となる溶接欠陥特徴量である脚長とアンダカットを推定する。

例えば株価予想など、過去の時系列データから未来の株価を推測する場合、深層学習モデルの学習に使用される学習データは全時系列データのうち始めから約 70%までのデータで、学習したモデルに対して見たことのない残り(約 30%)のデータを使用して推定精度を評価することが一般的である。つまり、一つの大きな時系列データを学習データとテストデータに分割する手法を取る。

一方で、本研究では水平すみ肉溶接試験から溶接機出力ログデータを取得するために、長さ 1 m の試験体への溶接を 90 回繰り返して多くのデータを取得している。データの総量としては多いものの、時系列データとして見たとき、各試験体の時系列データは全く異なる時間に測定されたものであるため、90 回分の時系列データをそのまま時間軸方向に連結して大きな一つの時系列データとみなすことには問題がある。例えば、各試験体のデータには溶接開始時の過渡状態を示す電流、電圧値が記録されている。もし各試験体の時系列データを時間軸方向に連結して大きな一つの時系列データとして取り扱った場合、「約 1 m の溶接毎に電流電圧が大きく変動するパターン

を持つ」という誤ったデータの特徴を学習してしまう恐れがある。現実では、1 m を超える溶接は造船所では当たり前であり、ラインウェルダのように 20 m を超える溶接もあるため、適切なデータセットを用意する必要がある。

水平すみ肉溶接に用いられるアーク溶接では局部的に大きな熱を加えることで母材を溶かしている。そのため、熔融池やその後の溶接ビードの形状に与える影響が大きいのは直近の電流や電圧の時系列データであると仮説を立てた。そのため、過去の長い時間の傾向などを学習する必要性は小さく、むしろ直近のデータを使って推定する深層学習モデルを作成するのが適切であると考えた。

時系列データの解析において、効率的かつ精度の高い特徴量の抽出を行うことは重要な課題である。特に、深層学習を用いた時系列データの分析では、長期間にわたる依存関係の取り扱いが困難となることが多い。この問題に対処するため、本研究では、複数の時系列データの処理方法を検討し、その中から時間窓に区切る手法を選択した。

一般的な時系列データの解析方法としては、リカレントニューラルネットワーク(RNN)⁵⁴や長期記憶(LSTM)⁵⁵などの再帰的モデルを使用する方法、さらに自己回帰モデル⁵⁶や移動平均モデル⁵⁷といった伝統的な統計的手法が挙げられる。RNN や LSTM は、データの時間的依存関係を捉えるのに優れているが、学習に多くの計算資源を要することが課題である。また、長期間のデータに対しては勾配消失問題が発生しやすく、モデルの安定性が損なわれることがある。自己回帰モデルや移動平均モデルはシンプルで解釈が容易だが、複雑な非線形関係を捉えるには限界がある。

本研究では、時系列データを固定された時間窓に区切り、各時間窓内で統計的特徴量を算出する手法を採用した。この手法は、ある期間のデータを小さな窓(領域)に分割し、それぞれの窓内で平均、分散、最大値、最小値といった統計量として深層学習モデルに入力する。RNN や LSTM と比較して、固定長のベクトルが入力され勾配が時間方向に伝播しない構造であるため、長期間の時系列データに対しても勾配消失問題が起きにくい。逆に言えば、窓に分割する方法は時系列データの長期的な傾向を学習することが難しくなるが、前述の通り熔融池やその後の溶接ビードに与える影響が大きいのは直近の溶接ログのデータであるという仮説からすると問題ないと考えた。

このように窓に分割して得られた統計量を深層学習モデルの説明変数として使用することで、時系列データの学習における勾配消失問題を抑えつつ、重要な特徴をモデルに提供することが可能となる。

3.2.1 窓の定義

窓とは, Fig. 3-1 に示すように「特徴量を溶接進行方向に沿って一定距離ごとに区切った範囲」と定義する. 窓大きさ F_L は窓の溶接進行方向の幅を, 窓移動量 F_S は隣接する 2 つの窓の左端同士の間隔をそれぞれ表す. 例えば, Fig. 3-1 の上図では $F_L = 20 \text{ mm}$, $F_S = 20 \text{ mm}$ を, 下図では $F_L = 20 \text{ mm}$, $F_S = 4 \text{ mm}$ を示している.




Fig. 3-1 Schematic diagram of frame length and frame shift.

溶接長 L を基にした場合, 生成される窓の数 F_N は以下の式で求められる.

$$F_N = (L - F_L) / F_S + 1 \quad (1)$$

例えば, 長さ $1,000 \text{ mm}$ の試験体を $F_L = 10 \text{ mm}$, $F_S = 1 \text{ mm}$ の条件で溶接した場合, 991 個の窓データが作成され, 実験室環境の場合では 90 体の溶接試験体から合計 $89,190$ 個の窓データが生成される. 本研究では, 欠損値を除いて正常に取得できたデータは $87,995$ 個であり, これらをサンプルデータとして用いた.

3.2.2 窓を用いた学習, 検証, テストデータへの分割方法

データセットを作成するにあたり, 学習, 検証, テストデータ間に同じ窓内のデータが漏洩することを防ぎ完全に分離するため次の手順でデータセットを作成した.

まず各試験体から窓大きさと窓移動量で決まる窓内の溶接機出力ログデータの統計量 (Table 3-14) と溶接速度, ワイヤ狙い位置等 6 つの固定値 (Table 3-15) を説明変数として計算する. 次に同じ窓の溶接ビード外観形状データの統計量 (脚長は平均値, アンダカットは最大値) を目的変数として計算する. その後, 窓データは試験体毎に区別したデータセットとして, このデータセットを学習, 検証, テストデータへ振り分けた (Fig. 3-2 参照).




Fig. 3-2 Convert test piece to frame data

次に, 説明変数の一部である電流・電圧・溶接速度の値の範囲と目的変数である縦板アンダカットの個数が学習, 検証, テストの各データセットへほぼ同比率含まれるように試験体を振り分けた.

電流・電圧・溶接速度に関しては脚長で代替できると考えた. しかし, 縦板側または主板側のみ脚長だけであると溶接条件の一つであるトーチの狙い位置の変化により発生する偏肉によりデータ配分に偏りが発生すると考え, 主板脚長と縦板脚長の平均値を計算し, これらが各データセットへ近い比率で含まれるように試験体を割り当てた. また, アンダカットに関しては 1 体の試験体の縦板に発生した, 実船建造工程で補修対象となる 0.5 mm を超えるアンダカット深さの個数が少なかったためこの個数が各データセットに近い比率で含まれるように試験体を割り当てた. 以下に具体的な計算手順を述べる.

【データセットの分配計算方法】

1. 全ての試験体に対して, 各試験体の溶接ビード断面の主板側脚長平均 A と縦板側平均

脚長 B を求める

2. 各試験体に対して主板側平均脚長 A と縦板側平均脚長 B の平均値 C を求める.
3. C をもとに試験体を降順にソートする
4. ソートしたデータセット群を四分位点(等間隔)で分けデータセットを4つのグループに分ける
5. 学習 70% : 検証 15% : テスト 15%の割合になるようにデータセットを分配するために各グループからデータセットを 70%, 15%, 15%に近い整数の数だけランダムにピックアップし学習データセットグループ, 検証データセットグループ, テストデータセットグループとする. なお実際にピックアップするデータセット数は整数のため学習データセット数と検証データセット数は小数点第一位を四捨五入, テストデータセット数は総データセット数から学習データセット数と検証データセット数を引いた数とした.
6. 学習, 検証, テストデータに含まれる各試験体の縦板アンダカット個数の平均値の差を最小にするためにばらつき D を計算する(D:学習, 検証, テストデータ毎に, 試験体あたりの「0.5 mm を超えるアンダカットの個数」の平均値を求め, 3 つの平均値の標準偏差と定義する)
7. 5, 6 を 50 万回繰り返し, 最小の D となるようなデータセットの分け方を最適解とする.




Fig. 3-3 Standard deviation of the mean of the number of undercut in each piece and number of calculation loop

その後、各データセットに含まれる複数の試験体のデータを 1 つの表データに結合した。Table 3-16 に合計 90 体の各データセットへの試験体数配分結果を示す。

Table 3-16 Data sets allocation.

Training	Data generated from 62 test pieces according to F_s/F_L settings.
Validation	Data generated from 12 test pieces according to F_s/F_L settings.
Test	Data generated from 16 test pieces according to F_s/F_L settings.

以上により、学習、検証、テストデータセットに含まれる目的変数が近い比率となる試験体の割り当てとした。Fig. 3-4 に窓大きさ 10 mm、窓移動量 1 mm のときの学習、検証、テストデータに含まれる 0.5 mm を超える縦板側アンダカット数の相対頻度分布を Fig. 3-5 に窓大きさ 100 mm、窓移動量 1 mm のときの縦板側脚長の相対頻度分布を示す。




Fig. 3-4 Relative frequency distribution of undercut in train, validation, test data for vertical plate




Fig. 3-5 Relative frequency distribution of leg length in train, validation, test data for vertical plate

3.3 深層学習モデルの予測精度の評価手法

溶接脚長とアンダカット深さの実測値を出力値として扱う際は、溶接脚長は各窓における平均値を、アンダカット深さは各窓における最大値を使用する。第4章にて説明するが、窓大きさを変化させる解析を行う。窓大きさが大きくなり窓内のサンプル数が増えると窓内の統計量が平均化され、深層学習モデルがデータの特徴を適切に抽出できない可能性がある。しかし、窓大きさに対する統計量の変化量が不明であるため本研究では窓内の統計量を削減せず全て特徴量として採用した。

3.2.2 で述べた手法に従って分割された学習データセットを用い、ネットワークの重みの学習を行う。続いて、検証データセットを使用してネットワークの重みを調整し、過学習を防ぐ。その後、学習と検証データセットで決定されたネットワークの重みを用いて、未使用のテストデータセットを入力し、未知データに対する推定精度を評価する。ニューラルネットワークの重みが最適な値に達するまで、この学習、検証、テストプロセスを繰り返す。乱数の影響を考慮し、ネットワークの重みの初期値は乱数を変えて3回の計算を実施し、その中で最も高い推定精度を示す乱数を選択する。

深層学習モデルの推定精度の評価指標として決定係数(R^2)がある。決定係数は回帰分析における実測値に対する推定値の説明力を表す指標であり、次式 (3.1)⁵⁸が複数の定義の中の一つであるが、本研究では、54次元という高次元の特徴量ベクトルを扱うにあたり、特徴量ベクトルの自由度の大きさを考慮するため自由度調整済み決定係数(adjusted R^2)⁵⁹を採用した。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

y_i : 実測値,

$\bar{y}$: 実測値の平均値,

$\hat{y}$: 推定値

自由度調整済み決定係数は、特徴量ベクトルのサンプル数 n と特徴量ベクトルの自由度(次元数: p)を用いて次式 (3.2) で与えられる。

$$adjusted R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \times \frac{n-1}{n-p-1} \quad (3.2)$$

y_i : 実測値,

$\bar{y}$: 実測値の平均値,

$\hat{y}$: 推定値

n : サンプル数

p : 特徴量ベクトルの自由度 (説明変数の次元数)

例として, $F_L = 100$ mm, $F_S = 20$ mm の条件で, 特徴量ベクトルの全サンプル数が 4140 個であったとする. 例えば検証, テストデータセットに分割すると全サンプル数の 15% に当たる 621 個が検証, テストデータセットの特徴量ベクトルのサンプル数となる. 仮に決定係数が 0.90 であった場合, 検証, テストデータセットにおける自由度調整済み決定係数は約 0.89 となる. データ数が少ない場合は 54 次元の自由度の影響を無視できないため, 本研究では自由度調整済み決定係数を用いて推定精度を評価する. 自由度調整済み決定係数の値域は 1 以下であり, 1 に近いほど精度が高く, 1 から離れるほど実測値と推定値が離れていることを意味する.

第4章 実験室環境における適正な深層学習モデルの探索

4.1 標準化処理とハイパーパラメータのグリッドサーチ

実用化に向けて、実験室環境での深層学習モデルの推定精度を向上させるため特徴量の標準化処理ならびにハイパーパラメータである各層あたりのニューロン数(N)、隠れ層の数(H)、および最適化アルゴリズム(A)のグリッドサーチを行った。

生の学習データ Fig. 4-1 のようにそのままの数値であると電流と電圧では 10 倍以上異なってしまう。一般的に、ニューラルネットワークにおいて分散が大きい特徴量ほど情報量が多いと判断され、ネットワークの重みに与える影響が大きくなるために、重要な情報を持つ特徴量であっても、データの分散が小さいだけで推定結果に与える影響が小さくなり埋もれてしまう危険性がある。これを避けるため特徴量ベクトルの平均値を 0 に、標準偏差を 1 に調整する標準化処理を施し、これにより特徴量ベクトルが推定結果へ与える影響を均一化した。この結果を Fig. 4-2 に示す。





Fig. 4-1 Raw training data for current and voltage statistics.

Training data before standardization



Training data after standardization




Fig. 4-2 Training data for current and voltage statistics before and after the standardization process.

さらに、深層学習モデルの重要なハイパーパラメータである各層あたりのニューロン数(N)、隠れ層の数(H)、および最適化アルゴリズム(A)は従来、手入力により適当な組み合わせを試行していたが、本研究では、ニューロン数(N)は1から10、隠れ層の数(H)は1から10、最適化アルゴリズム(A)は3.1.1で述べたMATLABに実装されている12種類の最適化アルゴリズムの中から選択し、グリッドサーチを使用して最良な設定値を探索した。ニューロン数(N)が6、隠れ層の数(H)が5、最適化アルゴリズム(A)が弾性逆伝播法 (Resilient backpropagation)⁶⁰の組み合わせでの自由度調整済み決定係数の計算結果の例を Fig. 4-3 に示す。




Fig. 4-3 Calculation results for the degree-of-freedom-adjusted coefficient of determination for a combination of number of neurons (N) of 6, number of hidden layers (H) of 5 and optimization algorithm (A) Resilient backpropagation.

1 つの窓大きさと窓移動量の組み合わせに対して、グリッドサーチを使って最良なハイパーパラメータの探索を行う計算には、おおよそ 4 日の時間を要した(使用した PC スペック; Intel Xeon Silver 4210R CPU 基本周波数 2.40 GHz 10 コア 20 スレッド, 96 GB メモリ, NVIDIA GeForce RTX 3080 GPU)。

標準化処理を施した特徴量ベクトルとグリッドサーチで探索した中で最良なハイパーパラメータを用いて深層学習モデルの学習を実施した. Fig. 4-4(a) に溶接脚長, Fig. 4-4(b) にアンダカット深さのテストデータにおける実測値と推定値の比較結果を示す. 溶接脚長の深層学習モデルでは、ニューロン数(N)を 4, 隠れ層の数(H)を 7, 最適化アルゴリズム(A)には MATLAB に実装されているスケーリング共役勾配法⁶¹を使用した. また、アンダカット深さの深層学習モデルでは、ニューロン数(N)を 4, 隠れ層の数(H)を 4, 最適化アルゴリズム(A)にはベイズ正則化 (Bayesian regularization backpropagation)⁶²を使用した. 窓の設定は脚長, アンダカット推定ともに窓大きさ(F_L) = 5 mm, 窓移動量(F_S) = 1 mm である(Table 4-1)。

自由度調整済み決定係数は、溶接脚長推定で約 0.68, アンダカット深さ推定で約 0.58 であり、テストデータにおける推定値と実測値の間にはばらつきが非常に大きく、溶接脚長とアンダカット深さの学習モデルのパラメータの選定には改善の余地があることを確認した。

Table 4-1 Best hyperparameters among those explored in the standardization process and grid search

Weld shape	Leg Length	Undercut Depth
Number of neurons	4	4
Number of hidden layers	7	4
Optimization algorithm	SCG (Scaled Conjugate Gradient method)	Bayesian Regularization
Frame length (fix)	5 mm	5 mm
Frame shift (fix)	1 mm	1 mm




Fig. 4-4 Result of standardized processing in addition to automatic search of neural network parameters. (a) Predicted leg length, (b) Predicted undercut

4.2 窓大きさと窓移動量に関する検討

溶接脚長推定とアンダカット深さ推定における窓大きさ(F_L)と自由度調整済み決定係数の関係を調べる為に窓大きさ(F_L)を 5, 10, 20, 30, 50, 75, 100, 150, および 200 mm の 9 点で計算した自由度調整済み決定係数の結果のプロットを Fig. 4-5 に示す. なお 3.2.2 で述べたデータ分割方法, 3.3 で述べた 3 回の乱数によるネットワークの重みの初期値の設定, 4.1 で述べた標準化ならびにグリッドサーチを用いた方法を適用した.

計算コストを考慮し, 窓移動量(F_S)は 1 mm の一点に固定した. これは, 窓移動量を小さく設定することで, 深層学習モデルが測定データの変動をより詳細に学習できるようになり, 推定精度の向上に寄与すると考えたためである.

Fig. 4-5 に示すように, 溶接脚長推定においては $F_L = 100$ mm の条件下で, アンダカット深さ推定では $F_L = 10$ mm の条件で自由度調整済み決定係数が最大値を示している.




Fig. 4-5 Adjusted R^2 versus frame length in leg length prediction and undercut prediction.




Fig. 4-6 Adjusted R^2 versus frame shift in leg length prediction and undercut prediction.

Fig. 4-6 には、溶接脚長推定とアンダカット深さ推定に関して、窓移動量 F_S と自由度調整済み決定係数の関係性を示している。窓大きさは、Fig. 4-5 の自由度調整済み決定係数が最大値を示す窓大きさを選択した結果から溶接脚長推定で窓大きさ $F_L = 100$ mm、アンダカット深さ推定で窓大きさ $F_L = 10$ mm に固定している。溶接脚長推定では窓移動量が 1, 10, 30, 40, 50, 75, 100 mm の点で計算した。アンダカット深さ推定では 1, 3, 5, 10 mm の点で計算した。溶接脚長の窓移動量を最大 100 mm、アンダカット深さの窓移動量を最大 10 mm としたのは、窓移動量が窓大きさを超える場合、窓データを作成する際に窓移動量と窓大きさの差に相当するデータが失われてしまうことを防ぐために窓移動量を窓大きさと等しいかそれ以下に保つ必要があるためである。

計算の結果、溶接脚長推定では $F_S = 50$ mm の条件下で、アンダカット深さ推定では $F_S = 1$ mm の条件下で自由度調整済み決定係数が最大値を示した。

溶接脚長推定では、窓移動量を大きくするに従い自由度調整済み決定係数が小さくなる傾向があるように見える、一方、 $F_S = 40$ mm では自由度調整済み決定係数が傾向より低く、 $F_S = 50$ mm

では傾向より高く見える。


脚長の $F_s = 40 \text{ mm}$, 50 mm での溶接脚長推定における横軸を脚長の実測値, 左側縦軸を脚長の推定値として各データをプロットし, 縦軸右側の数値で学習データの相対頻度とテストデータの相対頻度の差を紫の折れ線で表した図を Fig. 4-7 に示す。紫の折れ線が負の値を示す領域を薄い黄色の短冊状で表し, 青い丸で囲った領域はデータ数が多い領域, 赤い丸で囲った領域は実測値に対して推定値が乖離している, すなわちうまく推定できていない範囲を示している。


この図から, 学習データの相対頻度とテストデータの相対頻度の差が負の領域(紫のグラフが右軸のマイナス側)でかつデータ数が多い領域では, 実測値と予測値の乖離が起きやすい傾向が見られる。つまり, それぞれの脚長の値におけるテストデータに対して十分な学習データを用意できないと, 推定精度が下がると予想している。

今後の研究でより良い推定精度を実現するためには,

- (1) 溶接欠陥特徴量における学習データとテストデータの相対的な差が小さくなるようなデータセットの振り分けを行う。
- (2) 溶接欠陥特徴量における学習データとテストデータの相対的な差が多少あっても問題ない程度の量のデータを取得する。

といった対策が必要であると考えられるが, この妥当性は今後より多くのデータを取得し検証する必要がある。





- The relative difference between training data and test data is in the negative region
- Areas with a large amount of data
- Areas where the difference between the actual and predicted values is large

Fig. 4-7 The difference between the relative frequency of the training data and of the test data for the result of leg length at $F_S = 40$ mm and $F_S = 50$ mm.

今回は自由度調整済み決定係数が 0.9 を超えた点があり実用上許容できる学習モデルの探索ができたと考えられる。脚長の推定で $F_S = 50$ mm で自由度調整済み決定係数は最大値である 0.93 を示したが、 $F_S = 1$ mm の条件でもほぼ同じ数値である 0.91 を示した。 $F_S = 50$ mm の条件では窓データ数は 1,610 個であるが $F_S = 1$ mm の条件では窓データ数は約 50 倍の 79,895 個になる。学習データ数はモデルの精度向上のために有効であると考え、高い汎用性を持つ深層学習モデルの構築と高い自由度調整済み決定係数を実現するために、本研究では溶接脚長推定における適正な窓移動量を 1 mm と定めた。

以上の窓大きさと窓移動量に対する自由度調整済み決定係数の計算結果を踏まえ、溶接脚長推定においては $F_L = 100$ mm, $F_S = 1$ mm, アンダカット深さ推定においては $F_L = 10$ mm, $F_S = 1$ mm を探索した中での最良値とした。溶接脚長推定における前述の最良値での設定条件を Table 4-2 に実測値と推定値の比較を Fig. 4-8(a)に、アンダカット深さ推定における前述の最良値での実測値と推定値の比較を Fig. 4-8(b)に示す。

Table 4-2 Best hyperparameters among those explored in frame length and frame shift

Weld shape	Leg Length	Undercut Depth
Number of neurons	9	9
Number of hidden layers	7	8
Optimization algorithm	Polak-Ribière Conjugate Gradient ⁶³	Levenberg-Marquardt ⁶⁴
Frame length (fix)	100 mm	10 mm
Frame shift (fix)	1 mm	1 mm
Number of frame data	79,895	87,995




Fig. 4-8 Comparison of measured and predicted (a) weld leg length and (b) undercut.

これらの深層学習モデルを使用することで、テストデータの一部の窓番号に対する溶接脚長との実測値と推定値の比較を Fig. 4-9(a)に、アンダカット深さの実測値と推定値の比較を Fig. 4-9(b)に示す。溶接脚長では部分的に良好な一致が確認されたが、アンダカット深さに関しては、窓番号が 1,000 から 2,900 では急峻な変動を捉えられている一方で、窓番号が 3,000 から 4,000 の間では、実測値とのずれが大きい部分もある。

本研究では計算コストが高いため F_L と F_S の組み合わせは数点のみの探索となったが、より推定精度の高い学習モデルの作成のためには、自由度調整済み決定係数が高い領域でより詳細な最適な F_L と F_S の点数を増やした探索をする必要がある。




Fig. 4-9 Comparison of measured and predicted values for some frame numbers in the test data.
(a) weld leg length, (b) undercut

上記の溶接脚長の深層学習モデルの Epoch 進行に伴う学習, 検証, テストデータによる半平均二乗誤差(Half mean squared error)を比較したグラフを Fig. 4-10 に示す. 学習, 検証, テストの全てにおいて Epoch の進行に伴う半平均二乗誤差の減少が確認される. これは, 学習データのみで過剰に適合する過学習を回避し, 汎用的なネットワークを作成できていることを示唆している.




Fig. 4-10 Comparison for half mean squared error from training, validation, and test data as the learning model for estimating the weld leg length progresses through Epoch progression.

以上の結果から, 実験室環境での深層学習モデルの適正なハイパーパラメータと窓の探索を完了とし, 次章では実用化に向けて, 現場環境での適用実験を実施した.

第5章 現場環境における検証

5.1 現場環境における実験方法

現場環境での適用研究を進めるために、簡易溶接台車を使用した水平すみ肉溶接の施工試験を計 96 回実施し、施工中の溶接機出力ログ(電流, 電圧, ワイヤ送給速度等)を取得した. 本実験では, 溶接電源として YD-500VR1⁶⁵(500A), 溶接台車には Wel-Handy Multi II⁶⁶を, そして溶接ワイヤにはメタル系 FCAW MX-200⁶⁷(ワイヤ径 1.4 mm)を使用した. Fig. 5-1 に本実験における簡易溶接台車の写真で, 試験体サイズを Table 5-1 に示す, このサイズは Table 2-1 の 2 回目の溶接試験で用いたものと同様である.




Fig. 5-1 Welding carriage.




Fig. 5-2 illustration of test piece (unit in mm)

	Number of the weld test	Dimension of test piece					
		t1	t2	B1	B2	B3	L
3rd Welding Test	96	12	10	150	100	70	1000

Table 5-1 Dimension of test pieces simulated field environment (unit in mm)

2.2.1 の Table 2-2, Table 2-3 で示した溶接条件は意図的に溶接欠陥を誘発するために電流，電圧，ワイヤ送給速度などの溶接条件に正常値と異常値の両方を設定してデータを収集したが，本章では現場での実用性を前提として，簡易台車を扱う現場作業者の操作方法を踏襲するため，電流，電圧値は通常現場で設定される値に固定し，脚長は溶接速度を変更することで調整する方法を採用した．溶接速度データは溶接時間と溶接距離から導いた平均速度を用いた．


現場で発生する欠陥としては，鋼材の表面に重ね塗りされた Zn リッチプライマ，簡易溶接台車の脱線によるワイヤ狙い位置ずれ，シールドガス流量の減少などの外的要因による偏肉やアンダカットなどがある．

本実験では Fig. 5-2 ならびに Table 5-1 に示される試験体に全 96 回の溶接施工試験を実施し，上記の現場環境で発生しやすい欠陥を模倣するため，実験条件に欠陥を誘発する外部要因を含めた．なお，現場環境においてもこれらの欠陥は同じ溶接電流・溶接電圧・溶接速度の状態で同一溶接線上に異常状態を原因として発生することが多いため，試験体の開始時点は正常状態から始め途中から異常状態を発生させることで同一試験体の中に正常状態と異常状態が混在（完結）することで現場環境を模擬した．

溶接欠陥を誘発しない通常の条件で 24 回、試験体表面に Zn リッチプライマを重ね塗りした状態 (1000 mm の試験体の内, Fig. 5-3 溶接位置が 500 mm～1000 mm の区間に Zn リッチプライマを塗布) で 24 回、脱線させた状態 (Fig. 5-5 溶接位置が 500 mm～1000 mm の間、溶接トーチ先端を水平方向に 2.5 mm 程度ずらす) で 24 回、ガス流量を減少させた状態 (Fig. 5-6 溶接位置が 500 mm～1000 mm の間、ガス流量を約 20 L/min から 5～10 L/min に減らす) で 24 回の溶接試験を行った。

現場環境溶接実験での設定条件を Table 5-2 に示す。

Zinc painting




Zinc rich primer is painted from abt. 50cm
to 100cm
Current: fixed
Voltage: fixed

Fig. 5-3 illustration of a test piece applied zinc rich primer painting



Fig. 5-4 Zinc rich primer painting


Derailment



Shift the aiming position from abt. 50cm
to 100cm
Current: fixed
Voltage: fixed

Fig. 5-5 illustration of a test piece of derailment

Gas reduction



During the last 50 cm, the gas flow rate is
reduced from 20 L/min to about 10 L/min.
Current: fixed
Voltage: fixed

Fig. 5-6 illustration of a test piece of gas reduction

Table 5-2 Set-up conditions in field environmental weld test

No.	Arc current [A]	Arc voltage [V]	Travel speed [cm/min]	Distance of wire aiming point [mm]	Torch travel angle [deg.]	Torch work angle [deg.]	wire Extensio n [mm]	Gas flow [L/min]	zinc paintin g
1	260	28	33.90	0	0	40	25	20	N/A
2	260	28	34.09	0	0	40	25	20	A
3	260	28	33.90	0/2.5	0	40	25	20	N/A
4	260	28	33.90	0	0	40	25	20/10	N/A
5	260	28	34.29	0	0	40	25	20	N/A
6	260	28	33.90	0	0	40	25	20	A
7	260	28	34.09	0/2.5	0	40	25	20	N/A
8	260	28	34.09	0	0	40	25	20/10	N/A
9	260	28	37.74	0	0	40	25	20	N/A
10	260	28	37.04	0	0	40	25	20	A
11	260	28	37.27	0/2.5	0	40	25	20	N/A
12	260	28	37.04	0	0	40	25	20/10	N/A
13	260	28	36.81	0	0	40	25	20	N/A
14	260	28	37.27	0	0	40	25	20	A
15	260	28	37.27	0/2.5	0	40	25	20	N/A
16	260	28	37.04	0	0	40	25	20/8	N/A
17	260	28	30.77	0	0	40	25	20	N/A
18	260	28	30.93	0	0	40	25	20	A
19	260	28	31.09	0/2.5	0	40	25	20	N/A
20	260	28	30.93	0	0	40	25	20/5	N/A
21	260	28	31.25	0	0	40	25	20	N/A
22	260	28	30.93	0	0	40	25	20	A
23	260	28	30.93	0/2.5	0	40	25	20	N/A
24	260	28	30.93	0	0	40	25	20/5	N/A

25	260	28	40.00	0	0	40	25	20	N/A
26	260	28	41.38	0	0	40	25	20	A
27	260	28	41.38	0/2.5	0	40	25	20	N/A
28	260	28	41.96	0	0	40	25	20/5	N/A
29	260	28	41.38	0	0	40	25	20	N/A
30	260	28	41.38	0	0	40	25	20	A
31	260	28	41.96	0/2.5	0	40	25	20	N/A
32	260	28	41.67	0	0	40	25	20/5	N/A
33	260	28	44.44	0	0	40	25	20	N/A
34	260	28	44.78	0	0	40	25	20	A
35	260	28	44.78	0/2.5	0	40	25	20	N/A
36	260	28	44.78	0	0	40	25	20/5	N/A
37	260	28	44.78	0	0	40	25	20	N/A
38	260	28	44.78	0	0	40	25	20	A
39	260	28	44.78	0/2.5	0	40	25	20	N/A
40	260	28	44.78	0	0	40	25	20/5	N/A
41	260	28	38.22	0	0	40	25	20	N/A
42	260	28	38.46	0	0	40	25	20	A
43	260	28	38.71	0/2.5	0	40	25	20	N/A
44	260	28	38.46	0	0	40	25	20/5	N/A
45	260	28	38.96	0	0	40	25	20	N/A
46	260	28	38.22	0	0	40	25	20	A
47	260	28	38.46	0/2.5	0	40	25	20	N/A
48	260	28	38.71	0	0	40	25	20/5	N/A
49	260	28	51.72	0	0	40	25	20	N/A
50	260	28	52.17	0	0	40	25	20	A
51	260	28	51.72	0/2.5	0	40	25	20	N/A
52	260	28	50.85	0	0	40	25	20/5	N/A
53	260	28	53.10	0	0	40	25	20	N/A
54	260	28	53.57	0	0	40	25	20	A

55	260	28	52.63	0/2.5	0	40	25	20	N/A
56	260	28	52.17	0	0	40	25	20/5	N/A
57	260	28	48.78	0	0	40	25	20	N/A
58	260	28	50.42	0	0	40	25	20	A
59	260	28	53.57	0/2.5	0	40	25	20	N/A
60	260	28	53.57	0	0	40	25	20/5	N/A
61	260	28	53.10	0	0	40	25	20	N/A
62	260	28	49.18	0	0	40	25	20	A
63	260	28	53.57	0/2.5	0	40	25	20	N/A
64	260	28	53.57	0	0	40	25	20/5	N/A
65	260	28	48.39	0	0	40	25	20	N/A
66	260	28	48.39	0	0	40	25	20	A
67	260	28	48.00	0/2.5	0	40	25	20	N/A
68	260	28	48.39	0	0	40	25	20/5	N/A
69	260	28	48.00	0	0	40	25	20	N/A
70	260	28	48.00	0	0	40	25	20	A
71	260	28	48.39	0/2.5	0	40	25	20	N/A
72	260	28	48.39	0	0	40	25	20/5	N/A
73	260	28	61.22	0	0	40	25	20	N/A
74	260	28	65.22	0	0	40	25	20	A
75	260	28	65.22	0/2.5	0	40	25	20	N/A
76	260	28	65.93	0	0	40	25	20/5	N/A
77	260	28	65.22	0	0	40	25	20	N/A
78	260	28	65.93	0	0	40	25	20	A
79	260	28	65.22	0/2.5	0	40	25	20	N/A
80	260	28	65.93	0	0	40	25	20/5	N/A
81	260	28	68.18	0	0	40	25	20	N/A
82	260	28	68.18	0	0	40	25	20	A
83	260	28	68.18	0/2.5	0	40	25	20	N/A
84	260	28	67.42	0	0	40	25	20/5	N/A

85	260	28	66.67	0	0	40	25	20	N/A
86	260	28	68.97	0	0	40	25	20	A
87	260	28	68.18	0/2.5	0	40	25	20	N/A
88	260	28	65.93	0	0	40	25	20/5	N/A
89	260	28	62.50	0	0	40	25	20	N/A
90	260	28	63.83	0	0	40	25	20	A
91	260	28	63.16	0/2.5	0	40	25	20	N/A
92	260	28	63.16	0/2.5	0	40	25	20/5	N/A
93	260	28	62.50	0	0	40	25	20	N/A
94	260	28	63.83	0	0	40	25	20	A
95	260	28	63.16	0/2.5	0	40	25	20	N/A
96	260	28	63.16	0	0	40	25	20/5	N/A

Fig. 5-7, Fig. 5-8, Fig. 5-9, Fig. 5-10 に溶接試験結果の溶接ビード外観例を示す.

Fig. 5-7 は通常条件でのビード外観, Fig. 5-8 は Zn リッチプライマを塗布した場合で, Fig. 5-9 は簡易溶接台車を脱線させた場合, Fig. 5-10 はガス流量を減少させた場合である.



Fig. 5-7 Photograph of weld bead appearance of normal condition



Fig. 5-8 Photograph of weld bead appearance of zinc rich primer painting



Fig. 5-9 Photograph of weld bead appearance of gas reduction



Fig. 5-10 Photograph of weld bead appearance of derailment

溶接実験後の二次元レーザ変位計による測定と解析手法は 2.2.2.1 と同様である。また、窓を用いた学習、検証、テストデータセットへの分割については、3.2.2 と同様の手法を用いた。

5.2 簡易溶接台車から取得した溶接機出力ログデータを用いた溶接欠陥の推定

本研究では、ハイパーパラメータの探索条件に第4章で採用した手法を適用した。特徴量には標準化処理を施した、ハイパーパラメータのグリッドサーチは各層あたりのニューロン数(N)を1から10, 隠れ層数(H)を1から10の範囲で設定し, 深層学習モデルのネットワーク重みの更新アルゴリズム(A)は, 3.1.1 で述べた MATLAB に実装されている12種類の最適化アルゴリズムの範囲で行った。窓大きさ(F_L)と窓移動量(F_S)については, 4.2 節で得られた結果を基に, 溶接脚長推定に対しては $F_L = 100$ mm, $F_S = 1$ mm, アンダカット深さに対しては $F_L = 10$ mm, 窓移動量 $F_S = 1$ mm に固定して計算を行った。

まず, テストデータの特定の窓番号における溶接脚長の実測値と推定値の比較を Fig. 5-11 に示す。脚長に関しては 4 mm 以下, 7 mm 以上の箇所を除き近い推定ができていていることがわかる。




Fig. 5-11 Comparison of measured values and predicted values of leg length for some frame numbers in simulated field environment.

同様に, アンダカット深さの実測値と推定値の比較を Fig. 5-12 に示す。アンダカット深さについては, 5,400 番目, 6,300 番目, 7,200 番目の窓番号近辺のピークに対してほとんど追従できていないことが観察される。




Fig. 5-12 Comparison of measured values and predicted values of undercut for some frame numbers in simulated field environment.

そこでアンダカット深さに関する窓の条件を、 $F_L = 10 \text{ mm}$, $F_S = 5 \text{ mm}$ へ変更してさらに検討した。テストデータの窓番号に対するアンダカット深さの実測値と推定値の比較を Fig. 5-13 に示す。この条件下では、アンダカット深さのピークに対して部分的な追従が確認できる。




Fig. 5-13 Comparison of measured values and predicted values of undercut for some frame numbers in simulated field environment. (Calculation conditions: $F_L = 10$, $F_S = 5$).

現場環境を模擬した条件にて、脚長とアンダカットの推定において最良の自由度調整済み決定係数を示したモデルのハイパーパラメータを Table 5-3 に示す。

溶接脚長に関しては、 $F_L = 100 \text{ mm}$, $F_S = 1 \text{ mm}$ とし、ハイパーパラメータの組み合わせはグリッド

サーチの結果ニューロン数(N) = 10, 隠れ層の数(H) = 10, 最適化アルゴリズム(A)はBFGS 準ニュートン法逆伝播である. アンダカット深さについては, $F_L=10$ mm, $F_S=5$ mm とし, ハイパーパラメータの組み合わせは $N=1$, $H=6$, 最適化アルゴリズム(A)は弾性逆伝播法である.

また全てのテストデータに対する溶接脚長推定における実測値と推定値の比較を Fig. 5-14 に, アンダカット深さ推定における実測値と推定値の比較を Fig. 5-15 にそれぞれ示す.

自由度調整済み決定係数は溶接脚長推定で 0.69, アンダカット深さ推定で 0.45 と, 4.2 節で述べた実験室環境と比較して低い推定精度が示された.

Fig. 5-14 の脚長推定グラフから実測値が 4 mm 以下と 7 mm 以上の領域で推定値との乖離が見受けられる. Fig. 5-15 のアンダカット推定グラフからは実測値が 0.5 mm 以下では推定値が 0 mm 近辺と 0.5 mm 近辺に 2 分されており, 実測値が 0.5 mm を超えるデータは推定値では 0.5 mm 近辺に集約されている.

Table 5-3 Parameter for weld defect estimation of simulated field environment in shipyard.

Weld shape	Leg Length	Undercut Depth
Number of neurons	10	1
Number of hidden layers	10	6
Optimization algorithm	BFGS Quasi-Newton ⁶⁸	Resilient Backpropagation ⁶⁰
Frame length (fix)	100 mm	10 mm
Frame shift (fix)	1 mm	5 mm
Number of frame data	79,383	17,633




Fig. 5-14 Comparison between prediction and experiment of leg length on vertical plate side.




Fig. 5-15 Comparison between prediction and experiment of undercut on vertical plate side.

5.3 考察

脚長の推定については、今後さらに学習データを積み上げていくことで推定精度が向上する見込みがあり、施工条件のみを用いて推定することが可能であると考えられる。一方で、アンダカット深さの推定に関しては、施工条件だけでは局所的な形状の説明が難しく、感度が低いと思われる。

本研究では、自由度調整済み決定係数が低くなった原因として、主に以下の要因が考えられる。

第一に、溶接ロボットと溶接台車の溶接条件の精度に差がある点が挙げられる。溶接ロボットは正確な設定により、狙い位置の溶接を高精度で実行できる。しかし、溶接台車は人手で狙い位置を調整する必要がある、これが狙い位置のばらつきの原因となりうる。そのため狙い位置のずれを検知できるセンサ導入が必要であると考ええる。

第二に、適用したモデルは実際の現場環境において発生しうる溶接欠陥発生に影響を与える外部要因への追従が不十分なモデルであった可能性がある。今回現場で発生しうる欠陥を誘発する要因として鋼材の表面に重ね塗りされた Zn リッチプライマ、簡易溶接台車の脱線によるワイヤ狙い位置ずれ、シールドガス流量の減少を溶接条件に追加したが、データ数はそれぞれ 24 回と少ないデータ数であったこと、Zn リッチプライマの塗り重ねとシールドガス流量に関しては入力データとしていなかったことがあり、溶接ビード外観形状の特徴量である説明変数へ十分反映することができなかった可能性がある。そのため外部要因の影響の検証を行い、寄与度の高い外部要因を用いた実験データを追加し、より多くの学習をおこなったモデルとする必要があると考える。

第三に、二次元レーザ変位計の測定が挙げられる。スラグ除去後の溶接ビード表面に鏡面のよう金属光沢が見られる場合があるが、レーザ変位計は一般に鏡面での反射光を検出器で捉えることが難しいため、正確な表面情報の取得が困難である。実際に、測定データには欠損値が含まれている場合があった。今後は鏡面測定に強い測定器の導入を検討する必要がある。

第四に、溶接欠陥特徴量抽出アルゴリズムの課題がある。レーザ変位計により取得した三次元形状データから溶接脚長やアンダカット深さなどの溶接欠陥特徴量を算出しているが、アンダカットが発生した時または溶接止端周辺でスパッタが発生した時にまれに溶接止端部を誤った位置に判定する問題がある。ロバスト推定法等を利用した点群処理に加えて、溶接止端部の判定を改善することで欠損値の少ない、より質の高い目的変数を生成できると考えられる。

第五に、造船所で補修対象となるアンダカット深さを持つデータの割合が少ないことがある。全ての形状データ中で、補修対象となるアンダカット深さの閾値である 0.5 mm を超えるデータの割合は、主板側で 0.03 %、縦板側で 0.27 % に過ぎなかった。回帰分析では、検出したい欠陥データが不足していると、モデルは正常状態のデータに重きを置いた学習を行い、欠陥データを正確に推定できない問題が生じる。より汎用的な深層学習モデルを現場に適用するためには、より多くの欠

陥データを学習させることが重要である。

第六に、より精度の高い推定モデル構築がある。今回は第 3 章、第 4 章で述べたように深層学習モデルの構築にあたり MATLAB の Deep Learning Toolbox に実装されている fitnet を利用したが各種設定は初期設定を用い特別なテクニックは使用せず、基本的な誤差逆伝播型ニューラルネットワークを構築した。またハイパーパラメータや窓大きさ(F_L)と窓移動量(F_S)の組み合わせの探索においても計算コストを考慮し可能な範囲に絞った検討を行った。今後は計算コストが許す範囲でより多くの範囲を探索することにより、より溶接ビード外観推定に適したモデルの構築も検討する必要がある。

また、実用化を目指し、造船現場での施工条件における高い推定精度を達成するためには、上記の課題に加えて深層学習モデルに鋼板の開先面の粗度や形状、状態(酸化皮膜やノロ付着)などの情報、さらに溶接時の鋼板温度や湿度、風速などの多様な環境要因も組み込むことも必要であると考えられる。

第6章 結論

造船所の現場に適用可能な溶接検査工程自動化システムの構築を目指し、T 継手の水平すみ肉溶接を対象とし溶接電源から取得出来るモニタリング情報と設定された溶接条件から自動で溶接ビード外観形状を推定する深層学習モデルの構築のため以下の二つの主要な課題に取り組んだ。

第一に、実験室環境での適正な深層学習モデルの構築のため、特徴量の標準化処理、ハイパーパラメータである各層あたりのニューロン数(N)、隠れ層の数(H)、および最適化アルゴリズム(A)のグリッドサーチを行いさらに推定精度の高い深層学習モデルの構築の為に窓大きさ(F_L)と窓移動量(F_S)の組み合わせの検討を行い、縦板の脚長推定において $F_L=100\text{ mm}$, $F_S=1\text{ mm}$ のときに自由度調整済み決定係数 0.91、縦板のアンダカット深さ推定において $F_L=10\text{ mm}$, $F_S=1\text{ mm}$ のときに自由度調整済み決定係数 0.72 へと向上した探索した中での最良値を求めた。これにより、現場適用可能性があることを確認した。

第二に、造船現場環境を模擬した条件を検証するために、造船所で広く使用される簡易溶接台車を用い、現場で発生する欠陥を誘引する要因である鋼材の表面に重ね塗りされた Zn リッチプライマ、簡易溶接台車の脱線によるワイヤ狙い位置ずれ、シールドガス流量の減少などの外的要因を実験条件に取り込み、実験室環境で検討した手法を用い水平すみ肉溶接中の縦板の溶接脚長およびアンダカット深さの推定モデルを構築した結果、自由度調整済み決定係数で脚長推定が 0.69、アンダカット深さ推定が 0.45 であった。

今後の課題として、学習データの充実、環境データの追加、より推定精度の高い学習モデルの作成のための各種計算設定のパラメータや最適な窓大きさ(F_L)と窓移動量(F_S)の組み合わせの探索がある。

また本研究では溶接ビード外観形状を脚長とアンダカットに絞ったが、オーバーラップやピット等、その他の溶接ビード外観形状の推定、突合せ継手など他の継手形状や多層盛り溶接継手に関する検討などが挙げられる。

造船業は労働集約型でありながら自動車製造のような完全なライン生産は困難であるため、作業者の裁量が広く、経験に基づいた個人の技量や判断を必要とする産業である。一方、日本における生産年齢人口の減少や労働観の多様化に伴い外国人作業者や多様なバックグラウンドを持つ従業員が増えている。また IMO で合意された 2050 年の GHG 排出削減目標 50%達成のために、LNG 燃料船や風力利用の実船竣工、次世代のアンモニア、水素などの新燃料適用の実設計や検証、海洋構造物では浮体式洋上風力発電の開発も始まっており今後より高度な技能や技術

が必要とされている。

こうした環境下で、顧客が求める品質の船舶や海洋構造物を提供するためには、デジタル技術を利用した管理体制の構築が重要であると考えている。

特に検査工程に関しては現在行われている、船級検査員、船主監督による溶接外観検査から、社内検査員の外観検査と自動溶接機器や作業者が扱う溶接トーチの溶接電流や電圧をはじめとする加工条件のモニタリング情報とその判定結果を記録し、手直し記録や管理統計量を船級、船主と共有する事で船級検査員や船主監督の立ち会い不要な品質保証体制、すなわち「検査レス体制」を実現することができないかと考えている。また加工条件モニタリング情報による欠陥の推定結果を製造規格と対比し良否判定をリアルタイムで作業員、機器オペレーター、管理者へフィードバックすることで加工条件が良好な状態で維持されるだけでなく、作業員の早期技能向上や個人品質ばらつきの減少につながり、品質の維持向上だけでなく手直しなどの無駄な作業の削減につながった結果コストダウンにも貢献すると考える。

また、将来的な造船環境自体の改善も求められるが、デジタル技術を斬新的に造船現場へ適用するためには、現在の環境でも適用可能な装置構成や運用方法も考慮することが重要であると考えられる。

そこで本研究では、画像を使用せずデジタル溶接電源や溶接トーチ周辺装置から取得出来る設定値、実測値の情報を基にした溶接ビード外観検査手法の開発に取り組み、造船環境における「検査レス」工程の実現の可能性に寄与したと考えている。

謝辞

本研究は九州大学大学院工学研究院海洋システム工学部門教授 後藤浩二 博士の御指導の下に行われたものである。研究を遂行するにあたって、終始懇切丁寧な御指導と御鞭撻を頂きましたことに心より感謝申し上げます。

本研究の実施に際しては当時九州大学大学院の森平尚樹氏、原武蔵氏、馮永益氏、使用した入力データの採取を協力してくれた当時九州大学の溝口稜太氏、株式会社大島造船所の出口純一氏、山本祥司氏、ディカスタデザイン海虎氏にご協力いただきましたことに感謝申し上げます。特に山寄賢人氏には本研究の中心となる実験の遂行、深層学習モデルの構築において多大なる支援をいただき、ここに深甚な謝意を表する次第です。

最後に本研究の機会を与えて頂いた株式会社大島造船所常務取締役 中尾洋一氏、人位康弘氏、金田尚造氏に感謝の意を表します。また、本研究遂行に当たり暖かい激励と御支援を頂いた株式会社大島造船所生産技術課の同僚をはじめとする工作部の皆様に深く感謝の意を表します。

参考文献

- ¹ 内閣府(2024)「令和 6 年版高齢社会白書」
https://www8.cao.go.jp/kourei/whitepaper/w-2024/html/zenbun/sl_1_1.html (accessed on December 11, 2024).
- ² 浅井 知; “アーク溶接におけるセンシング技術”, 溶接学会誌, 第 66 巻, 第 8 号, pp11-15, 1997.
- ³ 笠野 和輝, 荻野 陽輔, 福本 智, 浅井 知; “可視および赤外線波長領域におけるアーク・溶融池発光特性に基づいた 溶接現象観察手法の研究”, 溶接学会論文集, 第 38 巻, 第 2 号, pp103-113, 2020.
- ⁴ 山根 敏, 湯澤 弘樹, 金子 裕良, 山本 光, 平川 学, 大嶋 健司; “バックングレス V 開先溶接における ギャップセンシングと溶融池の制御”, 溶接学会論文集, 第 23 巻, 第 1 号, pp65-70, 2005.
- ⁵ 山根 敏, 神戸 孝博, 細谷 和道, 中嶋 徹, 山本 光; “プラズマ溶接における画像処理による溶接線検出と微い制御”, 溶接学会論文集, 第 31 巻, 第 3 号, pp175-180, 2013.
- ⁶ 浅井 知; “視覚センサによる溶接自動化システムの高機能化と実用化に関する研究”, 大阪大学 博士論文, 2014.
- ⁷ 山崎 洋輔, 阿部 洋平, 日置 幸男, 中谷 光良, 北側 彰一, 中田 一博; “狭開先レーザ溶接のための開先認識システムの開発”, 溶接学会論文数, 第 32 巻, 第 3 号, pp122-129, 2014.
- ⁸ X.F. Liu, C.S. Wu, C.B. Jia a, G.K. Zhang; “Visual sensing of the weld pool geometry from the topside view in keyhole plasma arc welding”, Journal of Manufacturing Processes, Vol.26, , pp74-83, 2017.
- ⁹ Yuxiang Hong, Baohua Chang, Guodong Peng, Zhang Yuan, Xiangchun Hou, Boce Xue, Dong Du; “In-Process Monitoring of Lack of Fusion in Ultra-Thin Sheets Edge Welding Using Machine Vision, Sensors”, 18(8), pp2411, 2018.
- ¹⁰ 笠野 和輝, 荻野 陽輔, 浅井 知; “オンラインアーク溶接画像センシング手法の基礎検証”, 溶接学会論文集, 第 37 巻, 第 3 号, pp108-114, 2019.
- ¹¹ Shun Izutani, Kei Yamazaki, Reiichi Suzuki, Yuji Ueda, Kazuki Nakamura, Toshiro Uezono; “Blowhole Generation Phenomenon and Quality Improvement in GMAW of Galvanized Steel Sheet”, QUARTERLY JOURNAL OF THE JAPAN WELDING SOCIETY, Vol.38, Issue 3, pp173-182, 2020.
- ¹² 新田 誠也, 荻野 陽輔, 浅井 知; “画像センシングによる薄板重ねすみ肉溶接のインプロセス溶接品質モニタリング”, 溶接学会論文集, 第 38 巻, 第 2 号, pp114-124, 2020.
- ¹³ 笠野 和輝, 荻野 陽輔, 福本 智, 浅井 知, 佐野 智一; “ブローホール発生に伴う溶接現象の観察とその発生検知に向けた検証”, 溶接学会論文集, 第 38 巻, 第 3 号, pp173-182, 2020.
- ¹⁴ C. S. WU, T. POLTE, D. REHFELDT; “A Fuzzy Logic System for Process Monitoring and Quality Evaluation in GMAW”, WELDING JOURNAL, Sponsored by The American Welding

Society and the Welding Reserch Council , pp33-38, FEBRUARY 2001.

- ¹⁵ Jie Zhu, Jiayou Wang, Na Su, Guoxiang Xu, Maosen Yang; “An infrared visual sensing detection approach for swing arc narrow gap weld deviation”, Journal of Materials Processing Technology, Vol.243, pp258-268, May 2017.
- ¹⁶ Wen Jun Shao, Yu Huang, Yong Zhang ; “A novel weld seam detection method for space weld seam of narrow butt joint in laser welding”, Optics and Laser Technology, Vol.99, pp39-51, 1 Feb.2018.
- ¹⁷ 金子康義, 伊佐賀達也, 山根聡, 大島健二; “MIG 溶接溶融池のニューロ・ファジイ制御”, 溶接学会論文集, 第 12 巻, 第 3 号, pp374-378, 1994.
- ¹⁸ Yasuo Suga, Takahiro Shimamura, Shigeaki Usui, Kimiya Aoki; “Measurement of Molten Pool Shape and Penetration Control Applying Neural Network in TIG Welding of Thin Steel Plates”, ISIJ International, Vol.39, No.10, pp1075-1080, 1999.
- ¹⁹ Zhifen Zhang, Guangrui Wena, Shanben Chenb; “Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding, Journal of Manufacturing Processes”, 45, ,pp208-216, 2019.
- ²⁰ 竹中 良太, 青山 和浩, 大泉 和也; “溶接ビード品質の画像判定における機械学習の適用”, 日本船舶海洋工学会講演会論文集, , 第 28 号, pp253-257, 2019S-GS7-1, 2019.
- ²¹ Junfen Huang, Long Xue*, Jiqiang Huang, Yong Zou, Ke Ma; “Penetration Estimation of GMA Backing welding based on weld pool geometry parameters”, Chinese Journal of Mechanical Engineering, 32, :55, pp, 2019.
- ²² Satoshi YAMANE* and Kouki MATSUO; “Adaptive Control by Convolutional Neural Network in Plasma Arc Welding System”, ISIJ International, Vol. 60, No. 5, pp998-1005, 2020.
- ²³ Chunyang Xia, Zengxi Pan*, Zhenyu Fei, Shiyu Zhang, Huijun Li; “Vision based defects detection for Keyhole TIG welding using deep learning with visual explanation”, Journal of Manufacturing Processes, 56, pp845-855, 2020.
- ²⁴ Yanling Xu, Ziheng Wang, ; “Visual sensing technologies in robotic welding”, Sensors and Actuators A: Physical, Vol.320, 1 Apr 2021.
- ²⁵ 山根 敏, 王 伝智, 張格 イ; “深層学習によるパルス MAG 溶接の開先ルート部の溶融状態推定”, 溶接学会論文集, 第 39 巻, 第 4 号, pp322-333, 2021.
- ²⁶ 中島 美也, 齊藤 隆宏, 加藤 剛志; “レーザー超音波可視化試験における欠陥検出のための深層 CNN 構造の検討”, AI・データサイエンス論文集, 3 巻, J2 号, 2022.
- ²⁷ 劉 子甄, 瀬渡直樹, 栗田恒雄, 松本光崇, 三島 望; “深層学習を用いたアーク溶接過程における溶接挙動の良否認識に関する研究”, 精密工学会春季大会学術講演会講演論文集, pp628-629, 2022.
- ²⁸ M. Amarnath, N. Sudharshan, P. Srinivas; “Automatic detection of defects in welding using deep learning - a systematic review”, Materials Today: Proceedings, 31 Mar 2023.

-
- ²⁹ 佐藤 裕太, 丸本 啓太, 山本 元道, 藤永 晃, 高橋 毅, 山本 光; “ホットワイヤ・レーザ狭開先多層溶接時のモニタリング手法の開発 -2- 高出力半導体レーザとホットワイヤ法を用いた鋳鋼狭開先多層溶接技術の開発(第5報)”, 溶接学会全国大会講演会概要, 第113集, pp216-217, 2023.
- ³⁰ 貝原 正一郎, 今村 和久; “インプロセス・アシュアランス(IPA)溶接システムの開発”, 圧力技術, 33 巻, 6 号, pp322-331, 1995.
- ³¹ 手島 秋雄; “溶接品質リアルタイム診断システムの考え方と応用事例”, 溶接学会誌, 第69巻, 第4号, pp75-78, 2000.
- ³² Zhifen Zhang, Xizhang Chen, Huabin Chen, Jiyong Zhong, Shanben Chen ; “Online welding quality monitoring based on feature extraction of arc voltage signal”, The International Journal of Advanced Manufacturing Technology, Vol.70, , pp1661-1671, 2014.
- ³³ LV Na, Fang Gu, Xu Yan-ling, Zhao Hui, Chen Shan-ben, Zou Ju-jia; “Real-time monitoring of welding path in pulse metal-inert gas robotic welding using a dual-microphone array”, The International Journal of Advanced Manufacturing Technology, Vol.90, , pp2955-2968, 2017.
- ³⁴ M. F. M. Yusof, M. A. Kamaruzaman, M. Ishak, M. F. Ghazali; “Porosity detection by analyzing arc sound signal acquired during the welding process of gas pipeline steel”, The International Journal of Advanced Manufacturing Technology, Vol.89, , pp3661-3670, 2017.
- ³⁵ 日本船舶海洋工学会工作分野研究企画部会: 日本鋼船工作法精度標準(JSQS)2023 年度版(船殻編), 2024.
- ³⁶ <https://www.keyence.co.jp/products/measure/laser-2d/lj-v/models/lj-v7200/>. (accessed on November 4, 2024).
- ³⁷ https://jp.misumi-ec.com/maker/misumi/mech/product/linear_encoder/linear_encoder_guide.pdf (accessed on November 4, 2024).
- ³⁸ Beaton, A.E. Tukey, J.W.: “The fitting of power series, meaning polynomials, illustrated on band-spectroscopic data”, Technometrics, Vol.16, 1974, pp.147-185.
- ³⁹ <https://jp.mathworks.com/products/deep-learning.html>, (accessed on November 4, 2024).
- ⁴⁰ <https://jp.mathworks.com/help/deeplearning/ref/initnw.html>, (accessed on November 4, 2024).
- ⁴¹ <https://www.mathworks.com/help/deeplearning/ref/fitnet.html>, (accessed on November 4, 2024).
- ⁴² <https://www.mathworks.com/help/deeplearning/ref/trainlm.html?lang=en>, (accessed on November 4, 2024).
- ⁴³ <https://www.mathworks.com/help/deeplearning/ref/trainbr.html?lang=en>, (accessed on November 4, 2024).
- ⁴⁴ <https://www.mathworks.com/help/deeplearning/ref/trainbfg.html?lang=en>, (accessed on November 4, 2024).
- ⁴⁵ <https://www.mathworks.com/help/deeplearning/ref/trainrp.html?lang=en>, (accessed on November 4, 2024).

4, 2026).

- ⁴⁶ <https://www.mathworks.com/help/deeplearning/ref/trainscg.html?lang=en>, (accessed on November 4, 2024).
- ⁴⁷ <https://www.mathworks.com/help/deeplearning/ref/traincgb.html>, (accessed on November 4, 2024).
- ⁴⁸ <https://www.mathworks.com/help/deeplearning/ref/traincgf.html>, (accessed on November 4, 2024).
- ⁴⁹ <https://www.mathworks.com/help/deeplearning/ref/traincgp.html>, (accessed on November 4, 2024).
- ⁵⁰ <https://www.mathworks.com/help/deeplearning/ref/trainoss.html>, (accessed on November 4, 2024).
- ⁵¹ <https://www.mathworks.com/help/deeplearning/ref/traingdm.html?lang=en>, (accessed on November 4, 2024).
- ⁵² <https://www.mathworks.com/help/deeplearning/ref/traingdx.html>, (accessed on November 4, 2024).
- ⁵³ <https://www.mathworks.com/help/deeplearning/ref/traingd.html>, (accessed on November 4, 2024).
- ⁵⁴ Elman, Jeffrey L; “Finding structure in time”, Cognitive science, 14.2, pp179-211, 1990. .
- ⁵⁵ Hochreiter, Sepp, and Jurgen Schmidhuber; “Long short-term memory” ., Neural computation, 9.8, , pp1735-1780, 1997.
- ⁵⁶ Yule, George Udny. ; “VII. On a method of investigating periodicities disturbed series, with special reference to Wolfer's sunspot numbers”, Philosophical Transactions of the Royal Society of London, Series A, Containing Papers of a Mathematical or Physical Character 226.636-646, pp267-298, 1927.
- ⁵⁷ Zhang, G. Peter; Time series forecasting using a hybrid ARIMA and neural network model, Neurocomputing, 50, , pp159-175, 2003.
- ⁵⁸ Kvålseth, O. T.: Cautionary Note about R², The American Statistician, Vol.39, No.4, 1985.
- ⁵⁹ <https://jp.mathworks.com/help/stats/coefficient-of-determination-r-squared.html>, (accessed on November 4, 2024).
- ⁶⁰ Riedmiller, M., and H. Braun; A direct adaptive method for faster backpropagation learning: The RPROP algorithm,”, Proceedings of the IEEE International Conference on Neural Networks,, , pp586-591, 1993.
- ⁶¹ Moller, M.F.; A Scaled Conjugate Gradient Algorithm For Fast Supervised Learning, Neural Networks, Vol.6, pp523-533, 1993.

-
- ⁶² MacKay, David J. C; Bayesian interpolation., Neural computation, Vol.4, No.3, pp415-447, 1992.
- ⁶³ Scales, L.E; “Introduction to Non-Linear Optimization”, New York, Springer-Verlag, 1985.
- ⁶⁴ Marquardt, D; “An Algorithm for Least-Squares Estimation of Nonlinear Parameters”, SIAM Journal on Applied Mathematics, Vol. 11, No. 2, pp431-441, June 1963.
- ⁶⁵ <https://content.connect.panasonic.com/jp-ja/fai/file/6825>, (accessed on November 4, 2024).
- ⁶⁶ https://www.koike-asia.com/Home/portable_machines/Wel-Handy_Multi_II?QUERYSTRING=WEL+Handy+multi+II, (accessed on November 4, 2024).
- ⁶⁷ <https://www.kobelco.co.jp/english/welding/files/handbook.pdf>, (accessed on November 4, 2024).
- ⁶⁸ Dennis, J.E., and R.B. Schnabel; “Numerical Methods for Unconstrained Optimization and Nonlinear Equations”, NJ: Prentice-Hall, 1983.