ニューラルネットによる画像ノイズ除去の応用*

—溶接接合部開先形状画像の信号処理—

井上 勝敬**, 河南 茂孝***, 姜 文圭***

Application of Image Noise Elimination by Neural Network*

—Signal Processing for Image of Weld Joint Configuration—

by Katsunori Inoue**, Shigetaka Kannan*** and Bunkei Kyou***

On using the signal processing ability of Backpropagation Model of Neural Network, the noise elimination is performed on the image of a joint part of arc welding. The object image, which is obtained by the slit light slice method, is often used for the detection of joint configuration on the purpose of welding automation. The noise caused by the welding arc is superimposed on the image and disturbs the detection. Such noise is eliminated through the learning process of Neural Network which is carried out for the noise imposed input images and the noiseless teacher images. The structure of the network, the image input method, the selection of the teacher image and the method to recover the resolution of the processed result are investigated experimentally. It is shown that the noise elimination is successfully done as the results.

Key Words: Arc welding, Automation, Sensor, Joint configuration, Weld line detection, Light slice method, Noise elimination, Neural network, Back propagation

1. 緒 言

溶接, とりわけ, アーク溶接の完全自動化は高温工学の応用上の重要課題の一つである。この課題のうちには溶接線, 接合部開先形状のインプロセス計測も含まれる¹⁾。この課題に対しては, ここ二, 三十年来, 様々な議論がなされ, 種々の方式が提案されてきているが, 未だに決定的解決には至っていないようである。光スライス法の応用も有力な方法として提案され, 今まで多くの実用例がある²⁾。この方法は画像計測の一種であるが, その弱点の一つとして, 画像中にアーク光などのノイズが重畳することが挙げられる。これを効果的に除去するには, 何らかの信号処理法が必要となる。

一方, ニューラルネットはパーセプトロン³⁾の発表以来, その学習能力が注目されていたが, バックプロパゲーションアルゴリズムの提案以来⁴⁾, そのロバスト性から各所で注目され, 一時はブームの様相を呈した。現在はこのブームも去ったが, 基礎研究, 応用研究は着実に進んでいるようである。バックプロパゲーションアルゴリズムの応用としては, パターン認識などが多いが, 強調処理, データ圧縮, ノイズ除去など信号処理への応用も提案されている⁵⁾。

ここではそのノイズ除去性能に注目して, 光スライス法で得られた画像に重畳したノイズ(溶接時のアーク光を想定した)の除去を検討した。以下, この方法について記述する。

2. 対象画像の収録と処理

2.1 画像データの収録と前処理

始めに用いたシステムの構成を Fig. 1 に示す。図中左部のように, 半導体レーザ光(780 nm, 30 mW)を円柱レンズで直線状にし溶接試片接合部に照射し, 開先形状の光スライス像を得る。このとき別にスポット光などを接合部近辺のいろいろな箇所へ照射して疑似ノイズを重ねるようにする。これを画像入力装置で512×480画素, 8ビットにデジタル変換し, PC(パソコン, NEC PC9801XL, 10 MHz)に収録する。同時に画像信号はビデオフロッピーへアナログ記録しておき, 必要に応じて再生し, 処理を加えることができるようにしておく。PCではこの画像データを30×30画素(後段装置の制約による)に圧縮した後, 2値化して専用ニューラルネット装置(㈱マイテック, NEURO TURBO MAX SYSTEM)の入力とする。2値化の際の閾値は入力データの濃度ヒストグラムを基にして, 動的に自動決定するアルゴリズムを採用した。なお, 画像入力装置, 専用ニューラルネット装置はPCの後部スロットへ挿入して使用するタイプのもので, したがって, 画像データはメモリマップ形式で, PCの処理を加えたり, 各装置間の受け渡しができるようにになっている。すべての処理アルゴリズムはC言語(TURBO C (v.2.0))で記述した。

2.2 学習とノイズ除去処理の概要

学習とノイズ除去処理を行うニューラルネットはバックプロパゲーション型で中間層は1層の構成とした。この型では Fig. 1 にも見られるように, 各層の素子は別層の全素子と結合して, 後進型一般化デルタ則による学習を行う。そのアルゴリズムの概略を表す式(1)を示す。

$$\Delta w(n) = -\alpha E + \beta \Delta w(n-1) \quad (1)$$

式(1)中で $\Delta w(n)$ は n 回目の学習による素子間結合荷重値の修正量, E は誤差(出力データと教師データの差)から導かれる量である。従って, 式(1)は荷重値は誤差と学習率 α に比例する項と, 前回の修正量 $\Delta w(n-1)$ と慣性係数 β とに比例する項とによって修正されることを

*原稿受付 平成6年12月19日 平成6年6月軽構造接合加工研究委員会で発表

**正 員 大阪大学溶接工学研究所 Member, Welding Research Institute of Osaka University

*** 近畿大学理工学部 Faculty of Science and Engineering, Kinki University

Fig. 1 Schema of processing system.

表している。学習率と慣性係数を適切に設定することにより学習の速度と安定性のバランスをとることができる。ここでは前者は0.2, 後者は0.9とした。

中間層素子数は可変とし、出力層は入力層と同じ30×30素子とした。各素子の入出力値、素子間結合荷重値は指数部6ビット、仮数部18ビットの浮動小数点数で表され、各素子の出力はこれを0.1~1.0に正規化している。ニューロン関数として中間層、出力層素子では式(2)のようなシグモイド関数 $f(x)$ を用いた(入力層素子では正規化するのみ)。

$$f(x) = 1 / (1 + \exp(-\mu x)) \quad (2)$$

関数 $f(x)$ は式からも分かるように飽和型関数で助変数 μ の大小により、その変化は急峻、緩慢となる。ここでは $\mu=1$ とした(以上の詳細については参考文献6)を参照されたい)。学習過程では後掲3.2項のようにして教師データを与えた。学習結果は出力データと教師データの差により評価し、評価値が十分小さい値に収束した時点で学習を終了した。学習結果は入力層、中間層、出力層の各素子の結合荷重値として保存しておき、この値を用いて未学習画像データを入力し、その出力をノイズ除去処理結果とした。

2.3 処理結果の評価

処理結果は入、出力画像、教師画像データから次に示す式(3), (4)により、開先形状一致度、ノイズ除去率を求めて評価した。多数の画像に対してはこれらの平均値によった。

$$C = 100(2s - t) / s \quad (3)$$

$$R = 100(n - t + s) / n \quad (4)$$

ここに、

C : 開先形状一致度 (パーセント値)

R : ノイズ除去率 (パーセント値)

t : 出力層全素子出力の合計値

s : 教師画像全面素子に対応する正規化出力の合計値

n : 入力画像中でノイズとなる画素に対応する出力層素子出力の合計値

上式において $t=s$ (出力が教師画像と完全に一致)なら、 C, R とも100になるが、出力画像のノイズが完全に除去されないなどで、 $t>s$ であると、両値とも100以下になり、それぞれ、教師画像との不一致、ノイズ除去の不完全さを表す指標となる。

なお、 n を求める際のノイズ画素の特定は目視によった。

この他、必要な場合には、目視により入、出力画像を比較して、開先形状像中心(溶接線)位置、開先形状出力状態を判定した。

3. 学習方式の検討

3.1 対象物位置の変化と学習

Fig. 2(a)は学習に用いたノイズが重畳した接合部画像の例で、同図(b)はその画像に対する教師画像である。教師画像は学習画像からノイズと見られる部分を人為的に(目視により)取り除いて得ている。接合部中心が画面のほぼ中心にあるような画像40枚について、このような方法で学習が完了した後にその結果を用いて処理テストを行った。結果をFig. 3に示す。同図(a)はテストの際の入

Fig. 2 Examples of input images for learning and teaching. (a) Learning images, (b) Teacher images.

Fig. 3 Examples of input and output images for processing test. (a) Input image 1, (b) Output image 1, (c) Input image 2, (d) Output image 2.

Fig. 4 Position index of object in learning image.

Fig. 5 Examples of learning image and teacher image for learning method ②. (a) Learning image, (b) Teacher image.

力画像の例で、この例のように大きなノイズが重畳していても学習画像と同じような位置に接合中心部があれば、同図(b)のようにノイズが完全に除去された画像がネットワークから出力される。同図(c)は接合中心部が画面のやや上方にあるような入力画像の別の例であるが、学習時との対象物の位置変化により出力画像は同図(d)のように不完全なものになる。学習は検出対象物の位置変化も考慮して行わなければならないことが分かる。

そこで、Fig. 4のように画面をA～Iの9区画に分割し、学習画像としては接合中心部がこれらの区画に均等に分布するよう配慮して選定した。この結果後述するように入力画像の画面内での位置変化に対しても、良い応答が得られるようになった。

3.2 教師画像の検討

学習時の教師画像としては、次の①、②について比較

検討した。

① 前項で述べたように、学習画像からノイズと見られる部分を人為的に取り除いて得たもの。

② Fig. 5(a)の学習画像に対する(b)のように、接合部形状に拘わらず標準的形状（以下標準教師画像と呼ぶ。）のものとし、接合中心部位置のみが、学習画像と一致するようにしたもの。

前記A～I区画のいずれかに接合中心位置があるような40画像（それぞれ画面中にいろいろな程度のノイズがあるもの、これを以下学習時の標準画像とする）について、上記①、②の教師画像による学習を行い、その結果を未学習の90画像に適用してテストした。出力された接合部形状により判定した結果は①では79画像、②では80画像が良好であった。①、②の差を示す例をFig. 6に挙げる。この例のように、あまり良好でない出力（この例

Fig. 6 Example showing difference between learning method ① and ②. (a) Input, (b) Output image by learning method ①, (c) Output image by learning method ②.

では①の場合) が得られるのは、画像中でノイズ部分が多い場合である。式(2)で定義したノイズの平均除去率は①では88.0%，②では92.1%であった。これらから教師画像②による学習法が、若干、良い結果が得られると結論できる。しかしながら、教師画像①、②の選択は対象とする開先形状が検出処理過程に大きく変動するか否かで決定するのが良い。

4. ニューラルネットの構成検討

ニューラルネットの入・出力層の素子（ニューロン）数はハードウェアの制約上、前述のように $30 \times 30 = 900$ とせざるを得ない。これに対する中間層（1層）の素子数を検討する。中間層の素子数を10-100の間で変化させて標準画像について学習したとき、学習結果が収束するまでの時間は素子数に対して直線関係になることを確認した。この学習結果に対して、未学習90画像を入力した場合の平均開先形成一致度、平均ノイズ除去率（それぞれ式(1) C 、式(2) R の平均値）を求めた。これを Fig. 7 に示す。同図では学習画像に対する結果も併せて表示している。Fig. 8 には中間層素子数と誤認識画像数の関係も示した。これらの結果から、中間層素子数には適正值があり、本研究の条件では30とするのが妥当であると結論した。この値を用いてニューラルネットを構成すると、中間部がくびれた砂時計型の形状となる。本研究のノイズ除去法はノイズで乱された画像からノイズが重畳していない画像を復原することなので、連想記憶モデルの実現を意図していると思ふこともできる。このようなパターン変換的な問題に対しては上記くびれ型のネットワーク構成をとることが知られているので⁷⁾、実験結果と符合する。

中間層素子数が100以上になると、このモデル形成に何らかの支障が出るか否かは学習データの個数、その選定と併せて今後の課題としたい。

5. 学習と処理の結果

5.1 学習

3.2項で述べた標準学習画像による学習曲線を Fig. 9 に示す。これらは教師画像①、②にそれぞれ対応するものである。図中、縦軸には学習画像に対する出力層各素子の出力値と教師画像の対応する画素の値の差の2乗和を全学習画像について合計したものをトータル誤差と定義している。教師画像①の場合が収束性が良く、収束時のトータル誤差もやや小さい。なお、ここに示した学習例の条件で、学習回数1000回で約30 (min) の時間を要している。この時間は学習データを多くしても1時間程度までと推定される。

Fig. 7 Effect of number of neurons in hidden layer on coincidence ratio.

Fig. 8 Effect of number of neurons in hidden layer on mistrecognition.

5.2 ノイズ除去処理性能

これまで述べた方法によるノイズ除去性能は標準画像による学習結果を用いた場合、いろいろな状態の画像に対して、3.2で述べたものとほぼ同様の結果を得ている。

Fig. 9 Example of learning curves.

ここではノイズ除去状況の良い場合と、悪い場合の例を挙げる。以下 Fig. 10~12 において、(a)は入力画像(当然、学習画像とは異なるもの)、(b)は教師画像①による学習結果の(a)に対する出力、(c)は同②による出力のそれぞれの例である。Fig. 10 は入力画像中のノイズは大きい、それが接合部開先形状像より離れた位置に存在するので、(b)、(c)とも良好な結果が得られている例である。Fig. 11 は前例に比べてノイズは小さいものの、開先形状像の近くにあるので、(b)ではノイズの除去状態がやや悪い。一方(c)ではノイズ除去は良好と言える。Fig. 12 (a)のように大きなノイズが開先形状像にほぼ完全に接触している例では(b)、(c)ともノイズ除去は不完全なうえに開先形状像自体も不正確に出力される。光学フィルターの使用による原画像撮像方法の改善、学習方法の検討などが課題になる。ここに挙げた例では処理時間(ニューラルネットに画像データを入力してから出力画像データを得るまでの時間)は50 (msec)であった。

5.3 空間分解能向上処理

2.1項で述べたように、対象とする原画像は512×48画素、8ビットのデータとして処理系に取り込むが、その

Fig. 10 Example of noise elimination-ordinary (good) case. (a) Input image, (b) Output image by learning method ①, (c) Output image by learning method ②.

Fig. 11 Example of noise elimination-not so good case. (a) Input image, (b) Output image by learning method ①, (c) Output image by learning method ②.

Fig. 12 Example of noise elimination-worst case. (a) Input image, (b) Output image by learning method ①, (c) Output image by learning method ②.

Fig. 13 Resolution improving process for output image. (a) Original image, (b) Input image, (c) Output image, (d) Result of resolution improving process, (e) Result of more sophisticated processing.

後、前処理段階でこれを 30×30 画素に圧縮してしまう。これによって画像の空間分解能は約 3.5 (mm/画素)まで落ちてしまい、ニューラルネットの出力もこれと等しくなる。この値は実用上からしても低すぎる。そこで、以下の処理を施すことでこれに対処できる。

まず、出力画像を各素子のダイナミックレンジの半値を閾値として、1, 0に2値化する。この2値画像と原画像との論理積をとると、その出力画像は原画像の空間分解能と等しい値 (0.2 mm/画素)を持ったものになる。通常はこれだけで十分であるが、上記2値画像と標準教師画像 (これも2値画像) とのマッチング演算 (これについてはここでは詳細は省略するが、2値画像同士のマッチング演算は専用装置に依らなくても高速で実行可能)を行い、マッチング率が最大の位置に標準教師画像をシフトし、これと原画像との論理積をとると、さらに良い結果が得られる。

空間分解能向上処理の例を Fig. 13 に示す。同図(a)は原画像、(b)は入力画像である。ニューラルネットからの出力は(c)になる。この出力の例では開先形状像は一部不連続になっているので、(c)図による原画像の処理だけでは同図(d)のように不連続な部分が生じてしまう。しかし、標準教師画像を利用した処理では同図(e)のように、完全な開先形状像が得られる。後者の処理によるとき、スループット (原画像データの入力から処理出力が得られるまでの時間) は 300 (msec) 程度である。この時間はアルゴリズムの改良、前処理、後処理の一部の専用ハードウェア化で、 100 (msec) 程度まで低減することは容易と考える。

6. 開先位置検出性能

前章で述べ教師画像②による学習とノイズ除去処理は観点を変えると、開先位置の検出と見ることもできる。

それはこの方式の学習では、ニューラルネットは入力画像における開先形状像中心位置を学習により認識して、その位置に合わせて標準開先形状像を出力していると考えられるからである。従って、標準開先形状像の代わりに、その中心位置に適当な形状のマーカーを出力するように学習を行い、そのマーカーによって5.3の処理をすると、空間分解能 0.2 mm 程度で開先部中心位置検出が可能である。これは溶接線のトラッキングに利用するためには十分な精度値である。

7. 結 言

ニューラルネットのバックプロパゲーション法による信号処理の応用として、アーク溶接時に光スライス法で得られる接合部開先形状像に重畳するノイズを想定してその除去を検討した。結果として、以下の結論を得た。

(1) 重畳されるノイズがよほど大きいものでない限り、良好な結果が得られる。処理操作に要する時間は5.1, 5.3項で述べたような値であるので、実用的観点からもまずまずである。さらにノイズ除去処理時間は1/3程度に短縮の可能性がある。

(2) ノイズ除去処理結果が良くないのは、大きなノイズが開先像にほぼ完全に接触している場合に限られるが、このような画像に対する処理は課題として残されている。

(3) 後処理としてのフィルタリング処理により、ノイズ除去処理後の開先形状検出空間分解能は原画像と等しい程度にまで回復することができる。

(4) 学習方式①, ② (前掲3.2項) の選択は対象開先形状により決定する。

(5) 適切な中間層素子数の検討結果により、本文のノイズ処理法は連想記憶モデルの実現とも解釈できる。

(6) 本ノイズ処理法は十分な実用的精度の開先位置検出法と見ることもできる。

ニューラルネットの他のアルゴリズムとの比較、ファジ理論、カオス理論の導入、画像処理の他の手法 (例えば、パターンマッチング法など) との併用などは今後の課題である。

最後にこの研究は文部省科学研究費 (一般研究B) による研究の一環として行ったものであることを付記する。

参 考 文 献

- 1) 荒田, 井上: アーク溶接の自動制御, 本誌, 41-6 (1972), 613-648.
- 2) 河原: 画像処理による多機能型溶接検出法に関する研究, 大阪大学博士論文, (1986).
- 3) M.L. Minsky and S.S. Papert: Perceptrons, MIT Press (1969).
- 4) D.E. Rumelhart and J.L. McClelland: Parallel Distributed Processing, Explorations in the Microstructure of Cognition, Vol. 1 Foundations, MIT Press (1986).
- 5) A. Lapedes and R. Farber: On-Line Signal Processing Using Neural Networks, Prediction and System Modeling, Los Alamos National Laboratory Report, LA-UR-87-2662 (1987).
- 6) 例えば Neural Ware, Inc.: Neural Computing, Neural Ware, Inc., (1991).
- 7) 例えば麻生英樹: ニューラルネットワーク情報処理, 産業図書, (1989).