ニューラルネットワークによる アーク溶接プロセスの最適化*

山 根 敏**

Optimization of Arc Welding Processes using Neural Network*

by YAMANE Satoshi**

キーワード

ニューラルネットワーク, 溶融池モデル, センサ, 溶込み制御, 突出し長さ推定, シグモイド関数, ラジアルベース関数, 自動化

1. 緒 言

近年, コンピュータ技術などの IT 技術の急速な進展により, ネットワークで接続された高速計算可能なパソコンが容易に手に入るようになった。これにより, 従来, 大型計算機により行われていた溶接溶融池の数値シミュレーションなど計算負荷の大きなものが個人で利用できるパソコンで行えるようになってきている。一方, アプリケーションソフトウェアにおいても, 様々なものが提供されており, 従来, 自作していたニューラルネットワークの学習などについても入手することができるようになり, データの入出力部を書くことにより, 誰でも学習が行える¹⁾。また, CPU 及び DSP の安価・高速化に伴い, これを溶接電源に採用し, デジタル化が行われている。溶接条件を溶接電源に記憶し, 必要なときに再現できる。さらに, 電源内部においてフィードバック制御を行い, アーク電圧・電流が制御される。このデジタル化に伴い, 気温などの変化に関わらず, 安定に溶接を再現できる²⁾。この技術により, 熟練溶接技術者の減少にも対応できる。一方, 溶接電源に用いられている DSP などの処理能力向上に伴い, フィードバック制御のみならず, 他の処理も行うことができる。この能力を用いることにより, ニューラルネットワークのオンライン学習などが可能となる。

ニューラルネットワーク (Neural Network 以下 NN と呼ぶ) は 1943 年に McCulloch-Pitts のニューロンモデルの研究から始まり³⁾, Rosenblatt により, これらを複数結合した NN による認識が行われた⁴⁾。これは線形分離可能な識別に使われていたが, 排他論理和などのように線形

分離ができない識別に適用できなかった。1984 年に Rumelhart らにより, シグモイド関数と教師付き学習方法としての誤差逆伝搬方法が提案された⁵⁾。これにより, 線形分離できない識別にも NN が適用できるようになった。この特徴は入力と出力の関係が不明な場合に, 入出力の写像関係を学習により表現できることである。このため, 溶接分野を含む様々な分野に NN が適用されるようになった⁶⁾。

アーク溶接の分野では, 溶接ビードの外観検査, TIG 溶接において溶接条件 (電流, 電圧, 溶接速度) からビード幅および溶込み深さの推定, TIG 溶接溶融池の溶込み深さ制御などに NN が適用されている⁷⁻⁹⁾。また, GMA 溶接においても, NN による溶接条件の推定, 溶融池制御などが行われている¹⁰⁾。このように NN を用いてアーク溶接プロセスの最適化が行われている。対象となるシステムの入出力関係を構築できるので, 溶融池の深さおよび突出し長さのように直接計測が困難な情報に対して, 計測可能な情報を用いて, 溶接状態を推定でき, これらの例について説明する。

2. ニューラルネットワーク (NN)

NN は人間の思考を表現するための技術として, 神経網に着目し, これを工学的にモデル化したものである。この特徴は入力と出力の関係を微分方程式などの数式を用いずに表現できることである。このため, 神経細胞 (ニューロン) にシナプス (重み) を通して入力を与えられ, これらの刺激がしきい値を超えると, つぎの神経細胞に信号を出力する。これを工学的に表現するために, 図 1 に示すニューロンモデルが考えられた。各ニューロンへ n 個の入力がある場合, その入力値を x_i , 重み ω_i とすると, 各ニューロンへの信号の総和 X は

*原稿受付 平成 19 年 12 月 14 日

**正 員 埼玉大学 Member, Saitama University

$$X = \omega_1 x_1 + \omega_2 x_2 + \cdots + \omega_{n-1} x_{n-1} + \omega_n x_n = \sum_{i=1}^n \omega_i x_i \quad (1)$$

となり、入出力関数 f により変換され、各ニューロンの出力 z は

$$z = f(X - \theta) \quad (2)$$

となる。ここで、重み ω_i およびしきい値 θ は学習により決まる値である。

一般にニューロンの入出力関数として、図2に示すシグモイド関数（SFと呼ぶ）：

$$f(X - \theta) = \frac{1}{1 + e^{-(X - \theta)}} \quad (3)$$

が用いられる。

NNは複数のニューロンを用いて構成される。一般によく用いられているフィードフォワード型のものを図3

図1 ニューロンのモデル

図2 シグモイド関数

図3 ニューラルネットワークと教師付き学習方法

に示す。

望ましい入出力関係を得るために、教師付き学習を行う。これは入力に対して、望ましい出力を決め、これらの組を教師データとする。このデータを図3に示すようにNNに与えて、その出力と望ましい出力の差 E が少なくなるように、最急降下法を用いて重み ω_i および、しきい値 θ を調整する。このように、同じアルゴリズムを用いて、入出力データの組を取り換えるだけで、NNは様々な用途に適用できる。

3. 溶融池モデルと溶込み深さの推定

NNのGMA溶接の溶融池のセンシングへの適用例について説明する。4.17 mm/sの溶接速度で溶接した場合の溶込み深さ、溶融池幅、溶接電流およびギャップの関係を図4に示す。ここで溶込み深さは母材表面から溶融池の底までの距離とする。裏波ビードが生じる場合は裏波ビードの高さと母材厚さ（3.2 mm）の和を溶込み深さとした。動的モデルの入出力には、溶込み深さの最大値である電極直下から4.17 mm後方の深さを用いた。また、溶融池のため、電極直下におけるギャップは直接計測できない。このためギャップはアーク光の影響を受けずに計測できる溶接進行方向25 mm前方で計測した。

NNを用いて溶融池の溶け込み深さをセンシングする場合、入力には溶込み深さに関する情報（ギャップ幅、溶融池幅、電流）が必要になる。また、望ましい出力は溶込み深さの定常状態および過渡応答から構成する。

まず、ギャップ G を設けずに母材を突き合わせて基礎実験を行った。定常状態における溶接電流と溶融池幅および溶込み深さの関係を図5に示す。溶融池の溶込み深さが約4.5 mm以下の場合、電流の増加と共に溶融池幅は大きくなり、溶込み深さも深くなる。その深さが約

図4 ギャップ、溶融池および溶込み深さの関係

4.5 mm を越えると、電流の増加に対し溶込み深さが急に大きくなり、137 A 以上で溶け落ちが生じる。このとき、多量の溶融金属が裏面に出るので、溶融池幅は急に狭くなる。このように溶融池幅は溶込み深さに対して非線形となる。つぎに、ギャップを 1 mm に設定し基礎実験を行い、溶接電流と溶融池幅および溶込み深さの関係を求めた。溶込み深さと溶融池幅の関係はギャップを設けない場合と同様である。しかし、同じ電流値において、ギャップ 1 mm の場合の方がギャップ 0 mm の場合よりも溶込みは深くなる。

溶接電流 130 A で突合わせ溶接を行ったとき、起動時において、池幅 W_0 の応答は 1 次遅れ系に、池幅 W_1 の応答は 2 次遅れ系に近似できる。これに対し溶込み深さの応答は 2 次以上の遅れ系でゆっくりと変化している。

3.1 溶込み深さのニューラルネットワークモデル (NNM) の構築

図 6 に示すように NNM は深さ D 、池幅 W_0 および W_1 毎に独立して 3 個とした。入力には溶込み深さ D 、池幅 W_0 、 W_1 、電流 I およびギャップ G であり、出力も同様に 1 サンプル周期後の推定値とした。すなわち、推定された値を入力として使い、時刻 0 における値（初期値） $D=0$ 、 $W_0=0$ 、 $W_1=0$ 、 I および G のみ入力すれば、NNM により順次時刻 kT の深さ D 、池幅 W_0 および W_1 を求める

図 5 突合わせ溶接における溶融池および溶込み深さの定常状態の応答

図 6 溶融池溶込み深さ推定のためのニューラルネットワーク

ことができる。定常状態および過渡状態での応答を用いて、誤差逆伝搬法により NNM の学習を行った。

NNM の性能を評価するために、教師データとして用いていない場合（溶接電流 115 A、ギャップ 0 mm）のときの出力を図 7 に示す。池幅 W_0 は 1 次遅れ系、 W_1 は 2 次遅れ系、深さ D は 2 次以上の遅れ系となっており、過渡応答と定性的に一致した。

3.2 溶込み深さのニューラルネットワークセンサ (NNS) の構築と溶込み深さ制御

NNM を用いて溶込み深さのセンシングを行う方法について説明する。計測した溶融池幅 W_0 、 W_1 およびギャップ G および 1 サンプル周期前に得た溶込み深さ D を NNM に入力し、溶接中の溶込み深さを推定し、このネットワークをセンサ (NNS) として用いる。

センサ出力がギャップ変動に関わらず一定となるように、溶接電流をファジィ推論により制御した。その結果を図 8 に示す。同図に示すように溶込み深さの定常偏差はな

図 7 テストデータを用いたニューラルネットワークモデルによる溶込み深さの推定結果

図 8 ニューラルネットワークセンサを用いた溶込み深さ制御

く、ギャップ変動に関わらず一定の溶込みが得られる¹⁰⁾。

4. 環境改善への技術・材料

溶接母材あるいは溶融池とトーチ間の位置変動に依らず常に安定した溶接品質を得るために、アーク長を計測することがアーク溶接プロセスの最適化において重要である。そこで、NNを応用し、電極ワイヤ溶融の数値モデルに基づいて、計測可能な情報から突出し長さの推定を行う。定常状態のみならず過渡状態における突出し長さのリアルタイムセンシングを可能とし、かつ汎用性の高いセンサを構築する。

4.1 突出し長さのニューラルネットワークモデル (NNM)

GMA 溶接における突出し部分の電極ワイヤ溶融現象において、電流とワイヤ突出し部での抵抗との積が電流供給点電圧 V_t に関係しており、突出し長さ y は電流供給点電圧 V_t に影響する¹¹⁻¹³⁾。ワイヤ溶融を数値的に解析するためにはワイヤ突出し長さの初期値が必要となり、容易でない。このため、ワイヤ溶融に関連するデータ（電流供給点電圧の実効値 V_t 、電流の実効値 i 、電流の実効値の2乗 i^2 、およびワイヤ送給速度 v_f ）を用いて、突出し長さ y をNNMにより推定する。

NNM は入出力関係を過渡状態および定常状態も含めて実験に合うように学習でき、その性能は入出関数に依存している。この関数として、図9に示すラジアルベース関数（以下 RBF とよぶ）：

$$f(X-\theta) = e^{-(X-\theta)^2} \quad (4)$$

を用いたものは、シグモイド関数より局所最小値に陥りにくい特徴をもっている。

図2のシグモイド関数を用いたものとラジアルベース関数を用いたものについて比較した。MIG 溶接における、定電圧特性、定電流特性およびパルス電流を対象としているため、10 ms 毎の平均の突出し長さを推定する。これを行うために、電流の実効値、その2乗、電圧の実効値およびワイヤ送給速度の平均値を1組とし、これらを10 ms 毎にサンプリングした。また、突出し部の過渡応答を40 ms で推定できると仮定し、現在の時刻でのサンプリングを含め、5組のデータを用いて突出し長さの推定を行った。すなわち、図10に示すように入力層は20ユ

図9 ラジアルベース関数

ニット、出力層は1ユニットとした。また、2種類のネットワークにおいて学習誤差が同じ程度になるように中間層のユニット数を決めた。具体的には、SF ネットワークでは4ユニット、RBF ネットワークにおいては2ユニットとした。突出し長さの過渡応答および定常状態の応答を学習させるために、電流パルス幅の変化（溶接電流の変化）、ワイヤ送給速度の変化を教師データとして用いた。

SF および RBF を用いた NNM を構築し、両モデルとも学習には Levenberg-Marquardt 法を用いた¹⁴⁾。学習を終えた後、突出し長さ y の平均値については溶接電流 i の実効値、その実効値の2乗、電圧 v_t の実効値およびワイヤ送給速度の40 ms 分を入力に与えることにより、各時点での突出し長さ y の平均値を順次推定する。315 A の一

図10 突出し長さ推定のためのニューラルネットワーク

図11 ワイヤ送給速度 74 mm/s、パルス幅 5.1 ms での溶接時のアーク起動時の学習結果

定電流で溶接を行ったときの溶接アークスタート時（0 s から 1 s までの 1 s 間）における電流 i の実効値、電圧 V_t の実効値、突出し長さ y の平均値および突出し長さの平均値の推定結果を図11に示す。SF および RBF のニューラルネットワークにより、学習結果の図に示すように良

(a) ワイヤ送給速度 74 mm/s から 100 mm/s、パルス幅が 4.7 ms から 6.0 ms に変化した場合

(b) 定電圧特性の電源において設定電圧が 33.1 V から 28.9 V に変化した場合

図12 テストデータにおけるニューラルネットワークによる突出し推定結果

好な推定が行えた。

4.2 テストデータによる妥当性の確認

NNM の学習の評価を行うため、教師データと異なるデータを NNM に入力し、突出し長さを推定した。ここでは、つぎの2種類の条件にて実験を行い、テストデータを構築した。

- ① 初期のパルス電流幅が 4.7 ms、3 s 後に 6.0 ms に変化、初期のワイヤ送給速度が 74 mm/s であり、3 s 後にワイヤ送給を 100 mm/s に変化させた場合
- ② 定電圧特性を持つ電源の設定電圧を 33.1V から 28.9V に引き下げた場合

これらの実験データを学習済みの NNM に入力し、突出し長 y を求めた。これと計測値を比較した。その結果をそれぞれ図12 (a) と (b) に示す。テストデータ①においては、SF および RBF ネットワークともに、アークスタート時の 0.2 s に誤差が多いが、過渡応答および定常状態に収束した後のいずれにおいても定常状態における出力データと計測値との誤差は 1 mm 以内であり、計測値と良い対応を示した。しかし、テストデータ②については、RBF ネットワークを用いた場合は過渡応答および定常状態とも計測値と良い対応を示したが、SF ネットワークを用いた場合、過渡応答に誤差が生じた。この要因として、過学習に陥った可能性が考えられる。2 種類の NNM (SF および RBF ネットワーク) を構築し、比較・検討をした結果、突出し部分の挙動を把握するモデルとして RBF ネットワークがより有効であることを確認した。

今回の学習したニューラルネットワークの適用範囲は教師データ（溶接電流（パルス電流幅）、電流供給点電圧、ワイヤ送給速度）の変動範囲内およびその近傍であると考えられる。これらを大きく外れる場合、同一のニューラルネットワークモデルで別の教師データによる学習が必要となる。また、溶接ワイヤの種類あるいはシールドガス組成の変更等により電極溶融現象が変化する場合には、同様な学習を行い、別のニューラルネットワークを用意することで対応できる。すなわち、溶接条件に従ってニューラルネットワークを選択することもできる。

5. 結 言

デジタル技術の急速な進展に伴い、パソコンレベルで様々なことが行えるようになってきており、さらにアプリケーションソフトウェアも充実してきた。これによりニューラルネットワークも使用しやすくなり、ユーザが入出力データを用意することにより、従来、計測が困難な情報についても計測することができるようになった。これによりアーク溶接プロセスにおける最適化が図れる。

参考文献

- 1) D. Hanselman, B. Littlefield, Mastering MATLAB, Prentice-Hall, Englewood Cliffs, NJ, 1996.
- 2) 三田, 溶接電源・機器, 溶接プロセスの高効率化, ガイドブック 5, 溶接法研究委員会, 2003, I-13-I-22.
- 3) W. S. McCulloch and W. H. Pitts. A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical

- Biophysics, 5 (1943), 115-133.
- 4) Rosenblatt F: The Perception: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65 (1958), 386-408.
 - 5) D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning internal representations by error propagation. In J. L. McClelland, D. E. Rumelhart, and the PDP research group, editors, *Parallel Distributed Processing*, 1 (1986), MIT Press, Cambridge, MA.
 - 6) L. H. Tsoukalas, R. E. Uhrig, *Fuzzy and Neural Approaches in Engineering*, Wiley-Interscience, 1997.
 - 7) K. Inoue, N.Yi, Application of Neural network to Visual Inspection of Weld Bead, *Quar. J. JWS*, 11-2 (1993), 288-293.
 - 8) P. D. Wasserman, *Advanced Methods in Neural Computing*, Van Nostrand Reinhold, 1993.
 - 9) Y. Suga, T. Shimamura, S. Usui, K. Aoki, Measurement of Molten Pool Shape and Penetration Control Applied Neural Network in TIG Welding of Thin Steel Plates, *The Iron and Steel Institute of Japan International (ISIJ International)*, 39-10 (1999), 1075-1080.
 - 10) A. Hirai, Y. Kaneko, K. Nagasawa, S. Yamane and K. Oshima, Neural Network Model of Weld Pool in Pulsed MIG Welding, *Quar. J. JWS*, 23-2 (2003), 227-233. (in Japanese)
 - 11) T. Nakamura and K. Hiraoka, Characteristics of Bead Formation Phenomena in Narrower Gap Welding and Proposal of New Welding Process at Ultra-Narrow Gap Joint, *Quar. J. JWS*, 19-1 (2001), 44-53. (in Japanese)
 - 12) Y. Sugitani and W. Mao: Automatic Simultaneous Control of Bead Height and Back Bead Shape Utilizing Arc Sensor in One Side Welding with Backing Plate, *Quar. J. JWS*, 12-4 (1994), 468-476. (in Japanese)
 - 13) E. Halmøy: Wire melting rate, droplet temperature and effective anode heating potential, *Conference on Arc Physics and Weld Pool Behavior* (1979), 49-59.
 - 14) K. Levenberg, A Method for the Solution of Certain Problems in Least Squares, *Quart. Appl. Math.*, 2 (1944), 164-168.
- ~~~~~