

Defect Inspection of an Arc Welded Bead Using a Support Vector Machine and a Neural Network

Masaaki Kuwada, Koji Nakano, and Yasuaki Ito

Department of Information Engineering

Hiroshima University

Kagamiyama 1-4-1, Higashi Hiroshima, 739-8527 Japan

Youhei Ishihara

Y-TEC CORPORATION

Akigun Kaitacho Soda 3-74, Hiroshima, 736-0003 Japan

Abstract—This paper presents a method for a defect inspection of an arc welded bead using a support vector machine (SVM) and a neural network (NN). In our approach, these classifiers are trained to classify arc welded beads as a non-defect class or a defect class. We use intensity, frequency and edge features extracted from arc welded bead images. After extracting these features, principal component analysis (PCA) is used to reduce the number of dimensions of the extracted features. PCA is a statistical tool, which is useful to extract dominant features from a set of multivariate data. Experiments show that both the SVM and the NN have over 91% detection rate for the non-defect and over 82% detection rate for the defect.

Index Terms—Support vector machine, neural network, arc welding, defect inspection

I. はじめに

近年、サポートベクターマシン [1] やニューラルネットワークなどの機械学習アルゴリズムを物体認識や分類などに適用する研究が盛んに行われている。これらの機械学習アルゴリズムは、教師あり学習によって多クラス分類を行う識別器を構成する学習手法である。ニューラルネットワークの1つに3層パーセプトロンがあり、これは入力層、中間層、出力層の3層から構成される。それぞれの層は複数のノードから構成され、ノード間は重み付きの辺で接続されている。3層パーセプトロンでは、分類したいクラスのデータを入力層に入力し、得られた出力層の値と教師の値を比較する。そして、出力層の値が教師の値と一致するように3層のネットワークを構成する辺の重みやノードが持つ値を調整することで学習を行う。一方、サポートベクターマシンは教師あり学習によって2クラス分類を行う識別器を構成する学習手法で、2クラスを線形もしくは非線形に分離可能な識別超平面を最適化問題を解くことで求める。サポートベクターマシンでは識別超平面を求めるとき、マージン最大化やカーネルトリックと呼ばれる識別性能を高める処理を行っており、他の機械学習アルゴリズムよりも識別性能が高いということが知られている。

アーク溶接とは、電気の放電現象で発生する熱を利用して金属を溶接する手法であり、自動車の部品製造などの幅広い分野で一般的に使用されている。このアーク溶接された部品として、図1に示すようなT字溶接と重ね溶接がある。T字溶接は、溶接する2枚の鉄板をT字のように配置し、図1の左図の赤枠部分に対してアーク溶接が行われたものである。重ね溶接は、溶接する2枚の鉄板が互いに重なり合うように配置し、図1の右図の赤枠部分に対してアーク溶接が行われたものである。




Fig. 1. T字溶接 (左) と重ね溶接 (右)

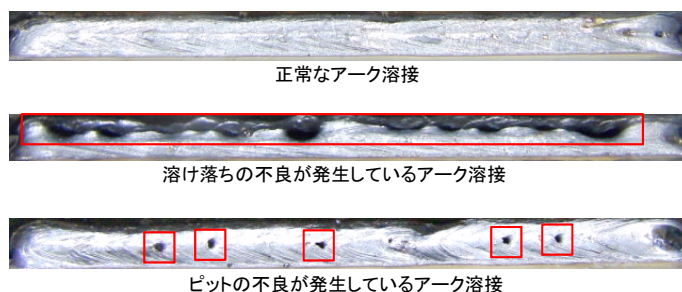


Fig. 2. 正常なアーク溶接 (上) と不良が発生したアーク溶接 (中と下)

T字溶接と重ね溶接では溶接する鉄板の配置が異なっているが、撮影画像においてアーク溶接部は同じように写る。よって、本研究ではT字溶接と重ね溶接のアーク溶接部を同じものとして扱う。図2に正常なアーク溶接とアーク溶接が正常に行われず不良が発生したアーク溶接を示す。アーク溶接に発生する不良として、溶け落ちとピットが存在する。溶け落ちは、溶接時の熱が溶接する鉄板を反対側まで溶かすことで発生する窪みや穴のことである。ピットは、アーク溶接時に溶接内部に閉じ込められた気体が抜けることで発生する小さな穴のことである。

本研究では、正常なアーク溶接画像と不良が発生したアーク溶接画像から抽出した特徴量をサポートベクターマシンと3層パーセプトロンのそれぞれで学習させて判別を行い、比較した。アーク溶接画像から抽出する特徴量は、画像の輝度値や周波数、エッジ勾配情報である。また、画像の輝度値や周波数に対して主成分分析 [2] を行い特徴量の次元の縮約を行う。主成分分析は、多変量で表現されたデータから特徴 (主成分) を抽出し、データの縮約を行う統計学的手法である。

本研究の他にも様々な手法を用いた溶接の不良検査の研究がなされている．機械学習を用いた溶接の不良検査の研究では [3], [4], [5] がある．文献 [3] では，溶接部の X 線画像から抽出した特徴量をサポートベクターマシンとニューラルネットワークで学習させ，欠陥ごとの分類を行っている．X 線画像からテクスチャ特徴と形状特徴を計 43 個抽出し判別したところ，サポートベクターマシンとニューラルネットワークともに 90% 以上の判別率を達成している．

画像処理を用いた溶接の不良検査として，溶接部の X 線画像に対してヒストグラム均一化や二値化を行い欠陥を抽出し，欠陥の形状や面積などから検査を行うシステムの開発 [6] や燃料タンクのような曲面の溶接において，溶接箇所サーマル画像と温度分布を用いて検査を行うものが提案されている [7] ．

II. サポートベクターマシン

サポートベクターマシンは，教師あり学習によって 2 クラスの識別を行う識別器を構成する手法である．サポートベクターマシンでは図 3 に示すように，与えられた複数の入力データを 2 つのクラスに識別する識別超平面を求めます．




Fig. 3. サポートベクターマシンによる 2 クラスの識別

まず， n 次元の入力特徴量を持つ N 個の学習データ $x_i \in \mathbb{R}^n$, $1 \leq i \leq N$ と各学習データ x_i の属するクラスのラベル $y_i \in \{+1, -1\}$ があるとする．もし，学習データを 2 クラスに識別可能であれば，識別超平面 $w \cdot x - h = 0$ が存在する．ここで， w は識別超平面を構成する係数， h は定数である．また，識別超平面に最も近い学習データをサポートベクターと呼び，サポートベクター間の距離をマージンと呼ぶ．サポートベクターマシンでは，このマージンが最大となるような識別超平面のパラメータ w と h を次の最適化問題を解くことで求めている．

$$\text{Minimize} \quad L(w) = \frac{1}{2} \|w\|^2 \quad (1)$$

$$\text{Subject to} \quad y_i(w^T x_i - h) \geq 1 \quad (2)$$

この最適化問題を解くことで，式 (3) の識別関数を得ることができる．ここで S はサポートベクターの集合である．

$$y = \text{sign}\left(\sum_{i \in S} w_i x_i^T x - h\right) \quad (3)$$

ここで，関数 $\text{sign}(u)$ は $u > 0$ のとき 1 をとり， $u \leq 0$ のとき -1 をとる符号関数である．また，式 (3) の識別関数は学習データを線形に分離するものである．しかし，現実世界では学習データを線形に分離可能なものは少ない．そこで，サポートベクターマシンではカーネルトリックと呼ばれる手法を用いて学習データを非線形に分離する識別超平面を求めます．カーネルトリックでは学習データ x をカーネル関数 $K(x_1, x_2)$ を用いて非線形空間に写像し，写像先の空間で線形識別を行う．このカーネルトリックによって，学習データを非線形に分離する識別超平面を求めることが可能になっている．一般的に使用されるカーネル関数として，式 (4) で表されるガウスカーネルが存在する．

$$K(x_1, x_2) = \exp\left(\frac{-\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (4)$$

カーネルトリックによる非線形の識別関数を式 (5) に示す．

$$y = \text{sign}\left(\sum_{i \in S} w_i K(x_i, x) - h\right) \quad (5)$$

III. 3 層パーセプトロン

3 層パーセプトロンはニューラルネットワークのうちの 1 つで，教師あり学習によって多クラスの識別を行う識別器を構成する手法である．3 層パーセプトロンは図 4 に示すような入力層，中間層，出力層の 3 層構造となっている．また，各層のノード数をそれぞれ N_x, N_h, N_o とし， $x_i \in \mathbb{R}$ を入力層のノード X_i ($1 \leq i \leq N_x$) のノード値 (入力層に与えられた入力)， $h_j \in \mathbb{R}$ を中間層のノード H_j ($1 \leq j \leq N_h$) のノード値 (中間層の出力)， $o_k \in \mathbb{R}$ を出力層のノード O_k ($1 \leq k \leq N_o$) のノード値 (3 層パーセプトロンの出力) とする．そして，入力層のノードと中間層のノード間の各重みを $v_{i,j} \in \mathbb{R}$ ，中間層のノードと出力層のノード間の各重みを $w_{j,k} \in \mathbb{R}$ とする．3 層パーセプトロンの演算において，未学習の入力データに対して，3 層パーセプトロンを適用し出力を得ることを前向き演算と呼ぶ．

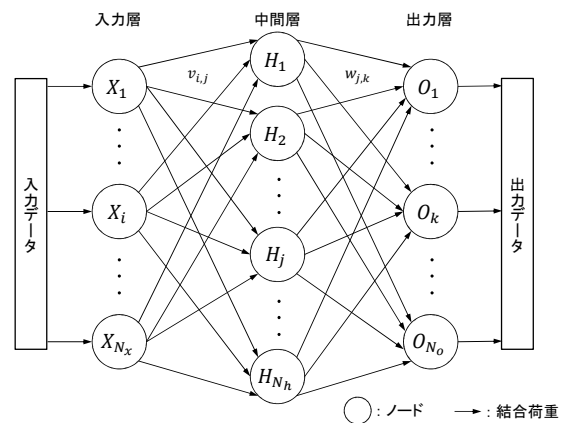


Fig. 4. 3 層パーセプトロンのネットワーク

3 層パーセプトロンの前向き演算では，まず入力層に与えられたデータ x_i と中間層のノードで，式 (6)，式 (7) の演算を行う．

$$h_j = f(h'_j) \quad (6)$$

$$h'_j = c_j + \sum_{i=1}^{N_x} v_{ij} x_i \quad (7)$$

ここで、 c_j は中間層のノード H_j が持つしきい値である。また、関数 $f(x)$ はシグモイド関数のことであり、式 (8) で表される。シグモイド関数の出力は $[0, 1]$ となるので、入力層と中間層の間の演算結果は $[0, 1]$ に正規化される。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

次に中間層のノードと出力層のノードで、式 (9)、式 (10) の演算を行う。

$$o_k = f(o'_k) \quad (9)$$

$$o'_k = d_k + \sum_{j=1}^{N_j} w_{jk} h_j \quad (10)$$

ここで、 d_k は出力層のノード O_k が持つしきい値である。中間層のノードと出力層のノード間の演算は、入力層のノードと中間層のノード間の演算と同じである。

前向き演算を行うときに必要となる各ノード間の重み $v_{i,j}$ 、 $w_{j,k}$ としきい値 c_j 、 d_k を求める手法として、誤差逆伝搬法 [8] がある。この誤差逆伝搬法では、学習前の 3 層パーセプトロンに学習データを入力し、前向き演算により出力された値と、学習データのクラスに対応した出力値との差から、各ノード間の重みとしきい値を前向き演算の逆順に計算していくアルゴリズムである。このアルゴリズムを繰り返し適用することで、最終的に学習データの識別を実現するネットワークを形成することが出来る。

IV. 提案手法

この章では本研究で提案するアーク溶接検査手法について説明する。本研究では、正常なアーク溶接と溶け落ちやピットの不良が発生したアーク溶接の 2 クラスの識別を行うサポートベクターマシンと 3 層パーセプトロンの識別器を作成した。図 2 に示すようなアーク溶接部分の撮影画像に対して、 32×32 ピクセルのウィンドウを 1 ピクセルずつずらしながら適用させることで、 32×32 ピクセルに分割した画像を作成し、分割した画像から特徴量を抽出し学習を行った。アーク溶接部分の画像を分割することで、小さな溶け落ちやピットのような局所的な不良の特徴を見つけやすくなる。

A. 特徴量の抽出

正常なアーク溶接と溶け落ちやピットの不良が発生したアーク溶接を識別するために、画像の輝度値と周波数、エッジの勾配を画像から抽出する。

輝度値を抽出するときに、そのままの値を使用するのではなく、ヒストグラム均一化を行い溶け落ちやピット部分をより強調する。ヒストグラム均一化は、ヒストグラムの累積度数のグラフの傾きが一定になるように変換する処理のことである。この処理を行うことで、コントラストを上げる

ことが可能である。そして、ヒストグラム均一化後の画像から周波数を抽出するためにフーリエ変換を用いる。フーリエ変換を行うことで画像中に低周波や高周波がどれほど含まれているかを知ることができる。

図 5 に正常なアーク溶接と溶け落ちやピットの不良が発生したアーク溶接に対して、ヒストグラム均一化とフーリエ変換を行った結果を示す。図 5 から、不良が発生したアーク溶接は黒い領域が画像の大半を占めているので正常なアーク溶接に比べて、高周波が少ないことが分かる。

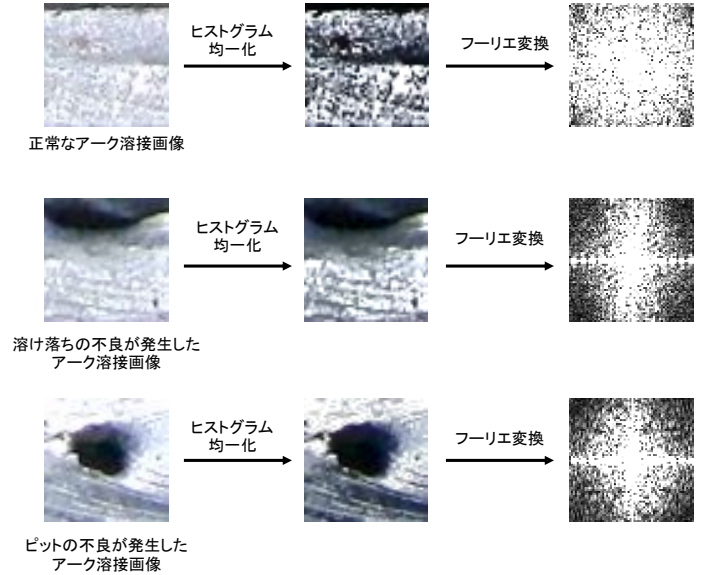


Fig. 5. 正常なアーク溶接 (上) と不良が発生したアーク溶接 (中と下) に対するヒストグラム均一化とフーリエ変換適用

また、画像の輝度値と周波数の他にエッジ勾配方向のヒストグラムも特徴量として利用する。具体的には図 6 に示すように、まずアーク溶接画像にソーベルフィルタを適用することで、エッジ勾配方向を得る。そして、得られたエッジ勾配方向を 4 方向 (0 度, 45 度, 90 度, 135 度) に量子化し、エッジ勾配方向のヒストグラムを作成する。




Fig. 6. エッジ勾配方向のヒストグラム

B. 特徴量の次元数の削減

主成分分析は、多くの変数で表現されたデータから変数間の相関関係を排除し、少数の無相関な合成変数に変換して分析を行う手法である。具体的には、元のデータの情報の損失ができるだけ小さくなるような軸を探すために、データの分散が最大となる軸を新たな軸として採用する。ここで、データの分散が最大となる軸を第 1 主成分と呼ぶ。次に、第 1 主成分と直交する軸の中で、データの分散が最大となる軸を第 2 主成分とする。この操作を続けていくこと

で各主成分を得ることができる。本研究では、輝度値と周波数に主成分分析を行い、それぞれで得られた主成分でのデータの値(主成分スコア)を利用した。

V. 性能評価

本研究で用いたサポートベクターマシンと3層パーセプトロンの学習と識別結果について説明する。

まず、サポートベクターマシンの学習設定について説明する。ヒストグラム均一化後の輝度値の1024次元の特徴量と周波数の1024次元の特徴量を主成分分析によりそれぞれ18次元の特徴量(第1~18主成分)と25次元の特徴量(第1~25主成分)にし、エッジ勾配方向のヒストグラムの4次元の特徴量を合わせた計47次元の特徴量を使用した場合の識別精度が最も高かったので、これらの特徴量を使用した。また、サポートベクターマシンのカーネル関数は、ガウスカーネルを使用した。

次に、3層パーセプトロンの学習設定について説明する。ヒストグラム均一化後の輝度値の1024次元の特徴量と周波数の1024次元の特徴量を主成分分析によりそれぞれ22次元の特徴量(第1~22主成分)と29次元の特徴量(第1~29主成分)にし、エッジ勾配方向のヒストグラムの4次元の特徴量を合わせた計55次元の特徴量を使用した場合の識別精度が最も高かったので、これらの特徴量を使用した。よって、入力層のノード数は55個、中間層のノード数は80個、出力層のノード数は1個となる。出力層のノードの値が0に近いか1に近いかで、入力されたアーク溶接画像が正常なものなのか不良なのかを識別する。

次にサポートベクターマシンと3層パーセプトロンに学習させるデータ数とテストデータ数について説明する。学習データは、正常なアーク溶接画像数を8239枚、不良が発生したアーク溶接画像数を1227枚(溶け落ちが586枚、ピットが641枚)を使用した。また、テストデータは、正常なアーク溶接画像数を1387枚、不良が発生したアーク溶接画像数を478枚(溶け落ちが344枚、ピットが134枚)を使用した。そして、表I, IIにサポートベクターマシンと3層パーセプトロンの識別精度をそれぞれ示す。

TABLE I
サポートベクターマシンの識別精度 [%]

正常なアーク溶接	92.8
溶け落ちが発生したアーク溶接	95.3
ピットが発生したアーク溶接	83.6

TABLE II
3層パーセプトロンの識別精度 [%]

正常なアーク溶接	91.3
溶け落ちが発生したアーク溶接	94.8
ピットが発生したアーク溶接	82.1

表I, IIから、サポートベクターマシンと3層パーセプトロンの両方において、高い識別精度となっていることが分かる。正常なアーク溶接において正しく識別できなかったものは、図7に示すようなスラグと呼ばれる非金属物質がアーク溶接部に付着しているものである。このスラグは不良ではないがピットに似た特徴を持っているので、正しく識別できなかった。また、溶け落ちやピットが発生したアーク

溶接において正しく識別できなかったのは、小さな溶け落ちやピットである。



Fig. 7. スラグ

VI. まとめ

本研究では、アーク溶接の不良検査を行う手法としてサポートベクターマシンと3層パーセプトロンによる学習手法を用いた。アーク溶接画像から抽出する特徴量では、画像の輝度値や周波数に対して主成分分析を行い次元の削減を行ったものとエッジ勾配情報を特徴量として使用した。サポートベクターマシンと3層パーセプトロンの両方において、正常なアーク溶接に対する識別精度は91%以上で、溶け落ちやピットの不良が発生した溶接に対する識別精度は82%以上であった。

REFERENCES

- [1] Corinna Cortes and Vladimir Vapnik, Support vector networks, *Machine Learning*, Vol. 20, No. 3, pp. 273–297, 1995.
- [2] H. Hotelling, Analysis of a Complex of Statistical Variables into Principal Components, *Journal of Educational Psychology*, Volume 24, pp. 417–441, 498–520, 1933.
- [3] Ioannis Valavanis, Dimitrios Kosmopoulos, Multiclass defect detection and classification in weld radiographic images using geometric and texture features, *Expert Systems with Applications*, Volume 37, Issue 12, pp. 7606–7614, 2010.
- [4] Sandip Bhattacharya, Kamal Pal, Surjya K. Pal, Multi-sensor based prediction of metal deposition in pulsed gas metal arc welding using various soft computing models, *Applied Soft Computing*, Volume 12, Issue 1, pp. 498–505, 2012.
- [5] Hsuan-Liang Lin, The use of the Taguchi method with grey relational analysis and a neural network to optimize a novel GMA welding process, *Journal of Intelligent Manufacturing*, Volume 23, Issue 5, pp. 1671–1680, 2012.
- [6] H. I. Shafeek, E. S. Gadelmawla, A. A. Abdel-Shafy, I. M. Elewa, Automatic inspection of gas pipeline welding defects using an expert vision system, *NDT & E International*, Volume 37, Issue 4, pp. 301–307, 2004.
- [7] U. Sreedhar, C. V. Krishnamurthy, Krishnan Balasubramaniam, V. D. Raghupathy, S. Ravisankar, Automatic defect identification using thermal image analysis for online weld quality monitoring, *Journal of Materials Processing Technology*, Volume 212, Issue 7, pp. 1557–1566, 2012.
- [8] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams, Learning representations by back-propagating errors, *Nature*, Vol. 323, No. 6088, pp. 533–536, 1989.