

ニューラルネットと多変量解析による
レーザ溶接の知的監視*穂坂重孝*¹, 名倉保身*², 石出孝*²
長島是*³, 赤羽崇*³, 松本俊英*³Intelligent Monitoring of Laser Welding by Neural Network Model
and Multivariate AnalysisShigetaka HOSAKA, Yasumi NAGURA, Takashi ISHIDE,
Tadashi NAGASHIMA, Takashi AKABA and Toshihide MATSUMOTO

An intelligent monitoring device for laser welding in small-size pipes is described. It monitors the reflected laser light and the welding speed, etc, learns the normal criteria and the anomalous criteria of welding, and discriminates between normal and anomalous welding. Using the learned criteria, it categorizes the anomaly as one of several types. As a result of evaluation tests, the degree of correspondence between this device and an expert is about 90%. This paper describes the new methods, the multivariate analysis for discriminating between normal and anomalous welding, and a neural network model for distinguishing the types of anomalies.

Key Words: Monitoring, Laser Welding, Neural Network Model, Multivariate Analysis, Learning

1. はじめに

YAG (Yttrium Aluminium Garnet) レーザは狭い空間における溶接に応用されている⁽¹⁾⁽²⁾。そして、溶接欠陥の発生を未然に防止するため、レーザの反射光の強さや溶接速度などのモニタ信号を用いて熟練者による監視が行われている。このような熟練者の監視と同等な性能を有する監視法を開発した。開発した監視法は二つの方法からなる。一つは正常規範の学習に基づく正常か異常かの判別、もう一つは異常規範の学習に基づく異常の種類識別である。

この監視法は、次の特徴を有する。

① 施工前に、正常な溶接時のモニタ信号を正常規範として監視装置に入力する。そして、監視装置はその正常規範に基づいて施工中の溶接が正常か異常かの判別を行う。また、その判別したモニタ信号を正常規範として監視装置に入力することができる。

② テストデータおよび知見によって作成された異

常規範を監視装置に入力する。そして、監視装置は異常と判別したものについて異常の種類を識別する。また、その識別された異常データを異常規範として監視装置に入力することができる。

③ 以上の判別および識別の成績は熟練者並みである。

本論文では、まず、レーザ溶接の概要と監視の流れについて述べ、次に多変量解析⁽³⁾を用いた正常規範の学習、および正常・異常判別、また、ニューラルネットワーク⁽⁴⁾を用いた異常規範の学習と異常の識別について述べる。そして、評価試験の結果、熟練者の判定との比較、工具・監視系の特性のばらつきの影響、2段階の有意水準の採用による識別成績の改善について述べる。

また、多変量解析を用いた異常診断⁽⁵⁾やニューラルネットワークによる故障予知の報告⁽⁶⁾があるが、2段階の有意水準の使い分けや、情報の圧縮や、多変量解析による正常規範の学習と判別およびニューラルネットワークによる異常規範の学習と識別を組合せた方法についてはほとんど例がない。

なお、本論文で使用する記号を示す。

$X_{d,i}$: 規範モニタデータ

$Y_{d,i}$: 被判別モニタデータ

* 平成3年10月25日 第1回FANシンポジウムにおいて講演、原稿受付 平成3年12月26日。

^{*1} 正員、三菱重工業高砂研究所 (〒676 高砂市荒井町新浜2-1-1)。

^{*2} 三菱重工業高砂研究所。

^{*3} 三菱重工業神戸造船所 (〒652 神戸市兵庫区和田崎町1-1-1)。

- i : モニタ信号のチャンネル番号
- a : 1回の溶接ごとに付番されるシーケンス番号
- s : セクション番号 $1 \sim (i+1) \cdot j$
- j : モニタデータをサンプリングするごとに付番されるシーケンス番号
- μ_i^a : a に関する $X_{i,s}^a$ の平均値
- Σ : a に関する $X_{i,s}^a$ の分散, 共分散行列
- D_s^2 : マハラノビスはん距離
- $SH(D^2)$: マハラノビスはん距離のしきい値
- α : チェビシェフの不等式の基準値に関する値

2. YAG レーザ溶接の監視

YAG レーザは狭い空間における溶接に使用される場合, 溶接工具にスパッタが付着したり, 溶接速度が変動したり, 溶接工具の光学系が損傷したり, レーザのパワーが低下したりする不具合 (以後, 異常の種類 A_i と称す.) が生じる可能性がある.

そこで, 図1に示すように溶接状況の監視は, レーザ伝送用の光ファイバの周辺に細径の複数本の光ファ




図1 レーザ溶接の概要

光ファイバにより YAG レーザを伝熱管内に導き, 光学系でスリーブの内部に照射し, スパイラル状に溶接する.

イバを設け, 溶接部からの特定の波長に注目した発光やレーザの反射光などを検出して監視する⁽⁷⁾. 具体的には, 6個のモニタ信号を用いている. すなわち第零チャンネルは, 発振器のレーザ出力, 第1および第2チャンネルは, 溶接中の溶接部から発生する光の発光強度, 第3チャンネルは, レーザ反射光の強度, 第4チャンネルは, 溶接速度, 第5チャンネルは, 溶接工具を回転させるモータの負荷比である.

3. 知的監視

3.1 知的監視 図2に, 新しい監視の流れを示す. すなわち,

- ① 溶接中の六つのチャンネルのモニタ信号を処理してモニタデータを得る.
- ② 熟練者が判定する正常な溶接のモニタデータを用いて正常規範を学習する.
- ③ 後続の溶接の被判別モニタデータと正常規範を比較し, ある有意水準で正常か異常かの判別を行う.
- ④ 異常と判別された場合, 同じ被判別モニタデータを別なる有意水準で再判別し, 異常の識別パターンを得る.
- ⑤ その識別パターンと異常規範のパターンを比較し, 異常の種類を識別する.
- ⑥ 知見あるいはテストデータから, ⑤で用いる異常規範を作成し, 異常規範を学習する.

なお, これらの実現方法として, モニタデータの正規分布性の χ^2 検定法, マハラノビスはん距離⁽⁹⁾による判別法, チェビシェフの不等式⁽⁹⁾による判別法を用いる. また, ニューラルネットワークモデルによる異常規範の学習 (BP 法) および異常の識別法を用いる.

3.2 多変量解析による正常・異常判別

- (1) 正常規範の学習 [図3(a)参照] 1回の溶接ごとに各チャンネルの約200個のモニタ信号を平均化

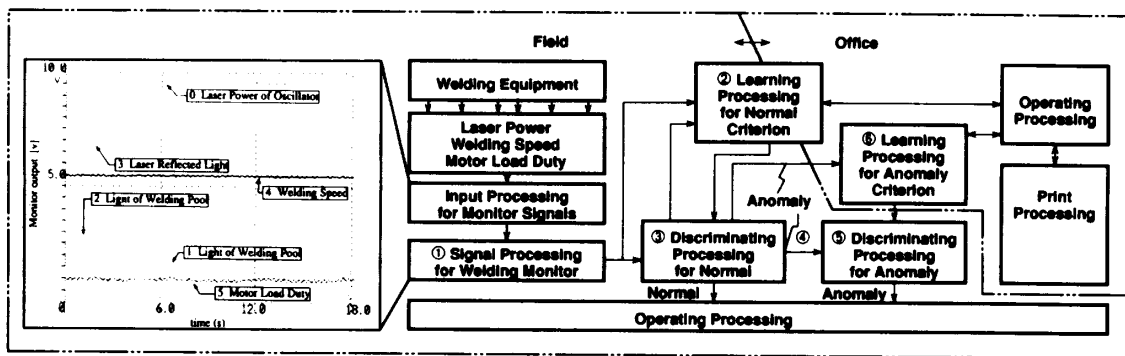


図2 知的監視の処理の流れ
正常規範の登録そして学習は, 現場および事務所の両方で行える.

処理によって 38 個のモニタデータに圧縮する。38 個のモニタデータはパラメータ (溶接条件) とともに、データファイルに記録する。このような方法で、熟練者が判定した正常な溶接時の a 個のモニタデータを得る。ここで、 $i=0\sim 5$, $j=1\sim 38$ の判別セクション $s(i, j)$ を定義する。その判別セクションについて、モニタデータ $X_{a,i}^j$ の正規分布性を調べる。すなわち、チャンネル番号 i のある j の $X_{a,i}^j$ において、 χ^2 検定 (検定の有意水準は 5%) を用いて a による分布が正規分布であるか調べる。

その結果、正規分布であれば、そのセクションを「マハラノビスはん距離⁽⁶⁾による判別」を行う M 判別セクションとする。正規分布でなければ、「基準値比較判別」を行う K 判別セクションとする。

M 判別セクションでは、二つのベクトルが属する分布の分散あるいは共分散で重み付けられたベクトル間の距離ともいうべきマハラノビスはん距離の大きさでデータの類似度を判別し、K 判別セクションではデー

タの絶対的な値の大きさで判別する。というのは、光ファイバで集めた発光信号では光の散乱程度の類似度を比較量とし、一定値に制御される溶接速度やレーザー出力の信号では、値の大きさを比較量として扱うものである。

M 判別の前処理として、各判別セクションにおいて、ある j のすべて判別セクションが M 判別の場合、次の $X_{a,i}^j$ の分散・共分散行列 Σ の計算を行う。

$$\Sigma = \begin{pmatrix} \sigma_{00} & \sigma_{10} & \cdots & \sigma_{50} \\ \sigma_{01} & \sigma_{11} & \cdots & \sigma_{51} \\ \cdot & \cdot & \sigma_{uv} & \cdot \\ \sigma_{05} & \sigma_{15} & \cdots & \sigma_{55} \end{pmatrix}$$

$$\sigma_{uv} = \frac{1}{n-1} \sum_{a=1}^n (X_{a,u}^i - \mu_u^i)(X_{a,v}^i - \mu_v^i), \quad n=80$$

..... (1)

なお、判別セクション $s(i, j)$ の $i=0\sim 5$ の任意の組が M 判別であれば、それらの判別セクション $s(i, j)$ では同様な前処理が行われる。

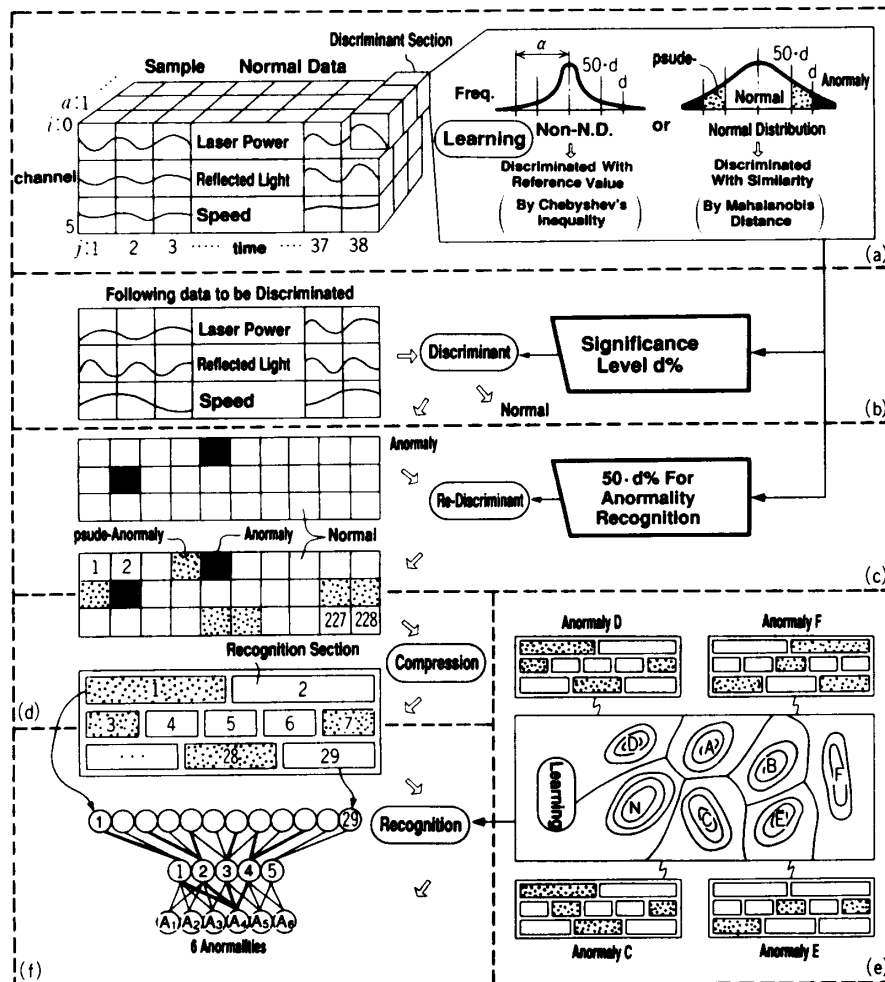


図 3 知的監視の原理

また、K 判別の前処理として、各判別セクションにおいて、 $X_{d,i}$ の一つでもその基準値 ($\mu_i \pm \alpha$) を超える確率が $d\%$ となる値 $\alpha = d \cdot \sigma$ をチェビシェフの不等式 $P(|X_{d,i} - \mu_i| \geq d \cdot \sigma) \leq 1/d^2$ を用いて求めておく。ただし、 σ^2 は $X_{d,i}$ の分散である。

(2) 正常か異常かの判別[図3(b)参照] 後続する溶接の被判別モニターデータ $Y_{i,i} (j=1 \sim 38, i=0 \sim 5)$ を取込む。

M 判別では、判別セクション s において、

if $D_s^2 > SH(D^2)$ then その判別セクションは異常,
 else その判別セクションは正常.
 ただし、 $D_s^2 = (Y_{i,i} - \mu_i)^T \Sigma^{-1} (Y_{i,i} - \mu_i), j=1 \sim 38$
(2)

$SH(D^2)$ は、

$$\int_{SH(D^2)}^{\infty} \frac{1}{2\Gamma(\nu/2)} (x/2)^{\nu/2-1} e^{-x/2} \cdot dx = d$$

で決る χ^2 分布のパーセント点であり、ここで $\Gamma(\nu/2)$ はガンマ関数、 ν は自由度である。

K 判別では、判別セクション s において、

if $(\mu_i - \alpha) < Y_i < (\mu_i + \alpha)$,
 then その判別セクションは正常, else その判別セクションは異常.
(3)

そして、 $1 \sim (i+1) \cdot j$ の判別セクションのうち一つあるいはある個数の判別セクションが異常ならば、その被判別モニターデータの溶接は異常と判別する。そうでなければ、正常と判別する。

(3) 正常か異常かの再判別[図3(c)参照] 異常と判別された場合、異常の識別のために、しきい値を変えて再判別を行う。再判別は式(2)、(3)において、今度は $50 \cdot d\%$ に相当する比較的小さいしきい値 $SH(D^2)$ 、および α を用いる。異常な判別セクションの

数を比較的多く得て、識別成績を向上させるためである。この効果については4章で述べる。

3.3 ニューラルネットワークによる異常識別

(1) 識別セクションの作成[図3(d)参照] 判別セクションを比較的少ない識別セクション (例えば29個) に圧縮する。圧縮する理由は、ニューラルネットワークモデルの入力層のニューロンの数を適当な数にして、処理時間を短くするためである。以下の溶接に関する四つの知見から圧縮する。例えば、図4に示す①枠内の11個を1個に圧縮する場合、11個の判別セクションにおいて、正常ならば零、異常ならば1の論理値を与え、その論理和をとって、①の識別セクションの論理値とする。

(a) 発振器のレーザ出力 ($i=0$) およびレーザ反射光 ($i=3$) は、溶接の溶込み深さに影響し、溶接の品質を左右する。

(b) 溶接部の二つの波長の発光強度 ($i=1, 2$) は、ともに溶接の溶込み深さと密接な関係がある。

(c) 1回の溶接は3パス ($j=1 \sim 11, 12 \sim 22, 23 \sim 34$) からなるため、各パスにまとめて監視する。

(d) 溶接速度 ($i=4$) とモータの負荷比 ($i=5$) は、溶接長の善し悪しを決める。

(2) 異常規範の学習[図3(e)参照] 知見あるいは前述したようにテストデータを用いて識別セクションの異常規範パターン (六つの異常各三つのパターン) を作成して、学習する。すなわち、図5に示すニューラルネットワークモデルにおいて、18個の異常規範パターンについて、それぞれ29個の識別セクションの零または1の値を入力層の29個のニューロンへ入力し、そのときの出力層の出力において、その異常規範パターンに対応した出力が1の値でほかの異常の出力が零の値となるように学習する。学習はBP法⁽⁴⁾を




図4 識別セクション
 ①～㉙の論理値は異常とき1, 正常のとき零である。




図5 異常の種類識別用ニューラルネットワークモデル

用いる。なお、ニューロンの数は出力層に異常の種類と同数の6個、中間層には、モニタ信号の独立性(第1, 2チャンネルは一つ)を考慮して⁽¹⁰⁾5個とした。

(3) 異常の識別[図3(f)参照] 異常の識別では、学習済のニューラルネットワークモデルにおいて、被識別パターンを入力層に入力し、出力層の活性化値零~1の値の最大値を有する出力に対応する異常をそのときの異常の種類と識別する。

4. 評価試験

開発した知的監視を装置化し、評価試験を行い、望ましい良好な結果を得た。

4.1 熟練者による判定との比較 熟練者と本装置による正常か異常かの判別成績の比較を表1に示す。表1より、一致度は90%以上である。熟練者と本装置による異常の識別成績の比較を表2に示す。表2より、一致度は80%以上である。両方の一致度はほぼ満足のいくものである。

なお、判別および識別の対象とした溶接は規範に用いた溶接を含んでいない。また、表中の数値は溶接の施工数で、異常Bは、A1, A2, A3以外の異常をま

表1 熟練者との比較例(その1)

Discriminate	Expert	This Device		Agreement %
		Normal	Anomaly	
Tool No.1 Data	Normal	19	2	94
	Anomaly	0	11	
Tool No.2 Data	Normal	18	1	93
	Anomaly	1	10	

表2 熟練者との比較例(その2)

Discriminate	This Device				Agreement %
	Anomaly				
Expert	A 1	A 2	A 3	B	83
Anomaly A 1	14	0	0	0	
Anomaly A 2	5	25	1	0	
Anomaly A 3	0	3	15	3	

とめて示している。

4.2 工具・監視系の違いの影響

(1) 正常か異常かの判別 工具・監視系の特性の違いが判別成績にどのくらい影響するか調べた。その結果、表3に示すように共通の規範を利用した場合は、工具ごとに作成した規範を利用した場合の判別と比べ、成績の一致度は42~73%である。これは、工具はどれも同じ部品から構成されているが、光ファイバの特性、光学系の組立て精度、モータ系の非線形特性などによって、工具・監視系の特性のばらつきが存在するためである。本監視装置では、工具・監視系の特性のばらつきに対して、先に述べたように溶接施工前に工具ごとに正常規範を学習する機能を実行してこの点に対処している。

(2) 異常の識別 では、異常の識別ではどうか。異常の種類に識別に用いる異常の規範は工具・監

表3 工具・監視系の違いによる正常・異常判別


Data	Criterion	Tool No.1 Criterion		Tool No.2 Criterion		Agreement %
		Normal	Anomaly	Normal	Anomaly	
Tool No.1 Data	Normal	78	42	34	73	
	Anomaly	74	7	67		
Tool No.2 Data	Normal	13	130	70	42	
	Anomaly	0	70	70		

表4 工具・監視系の違いによる異常識別

This Device	Tool No.1				Tool No.2			
	Anomaly				Anomaly			
Expert	A 1	A 2	A 3	B	A 1	A 2	A 3	B
Anomaly A1	14	0	0	0	12	2	0	0
Anomaly A2	5	25	1	0	1	15	0	0
Anomaly A3	0	3	15	3	1	0	15	0
Agreement %	82				91			

表5 異常識別成績と有意水準

Level of Significance	d% and d%				d% and 50-d%			
	Anomaly				Anomaly			
Expert	A 1	A 2	A 3	B	A 1	A 2	A 3	B
Anomaly A1	11	1	2	0	14	0	0	0
Anomaly A2	1	17	13	0	5	25	1	0
Anomaly A3	0	0	19	2	0	3	15	3
Agreement %	71				82			



(a) 異常識別画面例



(b) 正常規範学習画面例

図6 知的監視装置の表示画面例




図7 判別セクションとM判別の例

視系ごとに設ける必要のないことが表4に示す熟練者との比較結果からわかった。この例では、一致度は平均86%である。

4.3 2段階の有意水準の採用による識別成績の改善 異常の種類を識別成績を向上させるためには、正常か異常かの判別に用いる有意水準 $d\%$ とは別に、異常の種類を識別に用いる有意水準を $50 \cdot d\%$ にする方法が有効である。表5の例では、 $d=0.1\%$ としたとき一致度は、71%から82%に向上している。これは、3.2節で述べた $50 \cdot d\%$ を用いた再判別で新たに得た異常な判別セクションの数が増え、パターンの差異を拡大させ識別成績を向上させるためである。このような、2段階の有意水準の有効性は、これまで多くのデータで確認されている。なお、 d の値などは問題領域の特殊性から決定されるものである。

4.4 画面例と処理時間 図6に監視装置の表示画面例を示す。図6(a)は異常と判別されたことを示している。図中の「賢き」は装置の名前である。×印は異常と判別された識別セクションである。そして、図6(b)は正常規範を登録している画面を示す。

また、図7(a)にある工具の典型的な判別セクションの判別法の例を示している。この例では、第0, 4チャンネルではK判別セクションが、第1, 2, 3, 5チャンネルではM判別セクションが支配的である。図7(b)は、第3チャンネルのデータの判別例を示している。

そして、正常規範の学習時間、異常規範の学習時間はそれぞれ数分間で、正常か異常かの判別、異常の識別時間はともに数秒以内であることを確認した。

なお、ニューラルネットにおける異常規範の学習は、学習誤差(学習データと出力データの差)が1%以内となるまで、約10000回の学習を繰り返した。

レーザ溶接の欠陥の発生の兆候を高確度で自動判定

するため、レーザの反射光の強さなどの溶接モニターデータに対して多変量解析とニューラルネットワークを組合せた知的監視を適用して、異常か正常かの判定、異常の種類(数種)の識別を可能とする装置を開発し、評価試験を通じて実用の目処を得た。

また、今後の課題として、3.3節で述べた①情報圧縮の自動化、②学習時間の短縮、3.1節で述べた③監視装置の小形化、4.1節で述べた④工具・監視系の特性に対する簡易的な学習方法が挙げられる。

文 献

- (1) 横山・長島・松本・名倉・石出, 蒸気発生器伝熱管レーザ溶接スリーブ法の開発と実用化, 第23回レーザ熱加工研究会論文集, (1990), 203-210.
- (2) Yokoyama A., Nagashima T., Mastumoto O., Nagura Y. and Ishide T., YAG Laser Welded Sleeving Technology For Steam Generator Tubes In Nuclear Power Plants, 15th Int. Sympo. Jpn Welding Soc. Apr., Tokyo, (1990) 29-34.
- (3) 石原・長谷川・川口, Lotus 1-2-3活用多変量解析, (1990), 493, 共立出版.
- (4) Rumelhart, D.E., Hinton G.E. and William R.J., *Parallel Distributed Processing*, 1, (1986), 318-362, MIT Press.
- (5) 水谷・木村, 異常音の検出によるディーゼル機関の監視システムに関する研究, 日本音響学会誌, 45-2, (1989), 85-93.
- (6) 穂坂・前本, 半導体ガスセンサとニューラルネットワークによる故障予知, 機論, 58-550, C (1992), 17-23.
- (7) 石出・名倉・穂坂・長島・赤羽, レーザ溶接インプロセスモニタリング技術の開発とその実用化, 第27回レーザ熱加工研究会論文集, (1992), 123-133.
- (8) 奥野・久米・芳賀・吉澤, 多変量解析法, (1981), 日科技連.
- (9) 氏家・石井, 統計技術とその理論, (1978), 282, マグロウヒル好字社.
- (10) 船橋, 3層ニューラルネットワークによる恒等写像の近代的実現についての理論的考察, 電子情報通信学会論文誌, A, J73-A-1, (1990), 139-145.