

解 説

境界学習型ニューラルネットワークによる 検査・診断

五感による検査・診断の自動化装置

三井造船株 坪井 桂一

◆はじめに

機械の製造工程における検査や設備の保守作業では、人間の五感がしばしば利用されている。例えば、自動車用エンジンなどは組み立て後に試運転を行ない、検査員がその発生音を聞いてエンジンの良否を判断している。また、半導体部品や機械部品などでは目視検査が多用されている。一方、設備診断の例としては、コンクリート構造物の打音検査などがあげられる⁽¹⁾。しかしながら、人間の五感に頼る方法には、検査基準にばらつきがあることや検査基準に客観性がないこと、検査員の養成に時間がかかるなどの問題もあり、五感による検査・診断の自動化が求められている。

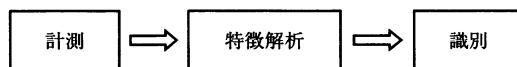
このため、これまで目視検査や聴音検査の自動化システムが数多く開発されているが、信頼性の点で十分とはいえない。すなわち、良品であるにもかかわらず不良品であると判定する間違い（第1種エラー）や不良品であるにもかかわらず良品であると判定する間違い（第2種エラー）の発生頻度が比較的高く、実用化の妨げとなっている。

そこで、三井造船株では第1種エラー率と第2種エラー率を共に低くすることができるニューラルネットワークである、境界学習型ニューラルネットワークを開発し、各種製品の検査・

診断に応用してきた。具体的には、聴音検査の自動化システムである振動・音響診断システムでは、ソナグラム（声紋）解析と境界学習型ニューラルネットワークを適用する自動化システムを、また目視検査の自動化システムである画像診断システムでは境界学習型ニューラルネットワークによる自動化システムを開発し、応用した。ここでは、その技術と適用事例を紹介する。

◆検査・診断の自動化技術について

人間の五感に頼る検査・診断を自動化する技術は、パターン認識技術の一種である⁽²⁾。一般に、パターン認識は、音声認識や画像認識に代表されるように、①計測、②特徴解析、③識別の順に行われる（第1図）。



第1図 パターン認識手順

計測には、振動・音響診断システムではマイクや加速度ピックアップ、レーザードップラー振動計などが使用され、画像診断システムでは主にカメラが使用される。また、データはコン

(2)…境界学習型ニューラルネットワークによる検査・診断

ピュータに蓄積され、必要に応じて雑音の低減などの前処理がなされる。

特徴解析は、生の計測信号をそのまま使用して診断すると精度が低くなるため、診断精度向上を目的として行われる。振動・音響診断システムでは、信号の振幅値やスペクトル、ソナグラムなどが特徴量として使用される。画像診断システムでは、画像の縦横比や画像の特異点などが特徴量として使用される。対象の特徴を解析するための汎用的な方法がないために、対象の特徴解析を行うには問題に応じて適正な特徴解析方法を適用する必要がある。

識別は、得られた特徴量を基に良否を診断するものである。多くの場合、特徴量はベクトル量となるため、特徴量は検査・診断対象に依存しない。このため、一般に、識別方法は汎用性が高く、多くの問題に適用できる。識別方法には、マハラノビス距離やテンプレートマッチング法などの解析的な方法、ニューラルネットワークなどの人工知能的な方法がある。

以下、特徴解析方法と識別方法を概説する。

(1) 特徴解析方法

ここでは、振動・音響診断システムで適用できる特徴解析方法について述べる。第1表に代表的な特徴解析方法とその特徴を示す。振動・音響信号は、その強度、スペクトル、時間的な変化で特徴付けられるため、これらの特徴を分析できる方法が有効である。

振幅を解析する方法は強度に関する特徴のみを分析するため、簡便ではあるが適用可能範囲

第1表 代表的な特徴解析方法とその特徴

	振幅	スペクトル	ソナグラム
特徴解析性能	△	○	◎
スペクトル安定度	—	◎	○
周波数分解能	—	○	○
定常現象解析性能	△	○	○
非定常現象解析性能	△	△	○

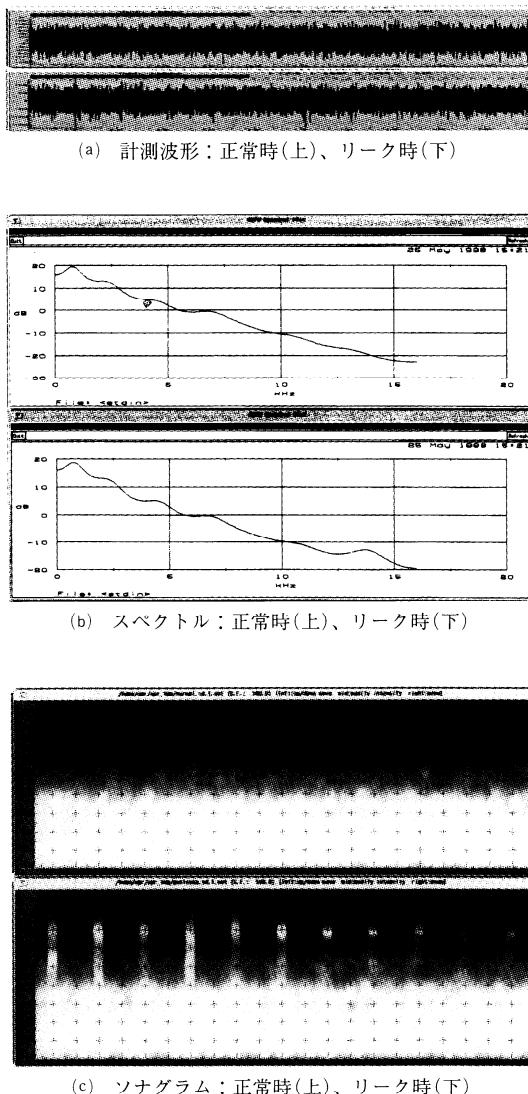
は限定される。

スペクトル解析方法は信号の強度とスペクトルに関する特徴を分析することができ、振幅解析と比較すると有効である。代表的な方法としては、FFT、線形予測解析などがある。しかし、突発的であるとか断続的であるなどの時間的な特徴を分析することができない点で特徴解析性能に限界がある。

ソナグラム解析方法は、信号の振幅、スペクトル、時間的な変化を分析することができるため特徴解析性能は最も高い。ソナグラム解析方法としては、短時間FFTや線形予測解析などがある。

第2図に、これらの方針の性能を比較した例を示す。この例は、ディーゼルエンジンの排気弁から、熟練した保守要員でなければ検知できない程度の微小リーキ音を発生させ、それを各解析方法で解析し、正常時とリーキ時で比較した例である。第2図(a)に示すように計測波形の振幅には正常時とリーキ時で明瞭な違いは見られない。第2図(b)にスペクトル解析結果を示す。周波数は20kHzまで分析しているが、スペクトルには正常時とリーキ時で大きな違いは見られない。第2図(c)にソナグラム解析結果を示す。第2図(c)の横軸は時刻を示しており、その時刻は波形の時刻と一致している。縦軸は周波数を示し、下が0Hz、上が20kHzである。任意の時刻における任意の周波数の強度を明度で示しており、白いほど強度が強いことを示している。第2図(c)から、正常時と比較して、リーキ時には10kHz以上で周期的に強度が強くなっていることが明瞭にわかる。また、この周期はエンジンの回転周期と一致している。この例からもわかるように、ソナグラム解析は信号の特徴解析性能が非常に高い。

ところが、スペクトル、ソナグラム共にデータ量が多く、診断精度を向上させるためには何らかのデータ圧縮が必要である。これまで周波数帯域幅を広くすることでデータを圧縮する



第2図 振動・音響信号の特徴解析方法の比較

方法などが適用されているが、この方法では特徴解析性能に劣化が見られるため、より精度の高いデータ圧縮方法が望まれる。

三井造船(株)では、上記状況に鑑み特徴解析方法として最大エントロピー法を用いたソナグラム解析を適用する⁽³⁾。最大エントロピー法においては、(1)式に示すように、時刻 $n\Delta t$ における計測データ $x(n)$ は、それ以前のデータの重み付

け加算値として表現できると仮定する。そして、重み係数 α_k を線形予測係数 (LPC) と呼ぶ。なお、 $\epsilon(n)$ は誤差を示す。

$$x(n) = \sum_{k=1}^m \alpha_k x(n-k) + \epsilon(n) \quad \dots(1)$$

(1)式を基にして、計測データからLPCを求め、求めたLPCからスペクトル $P(j\omega)$ を(2)式により求める。この計算を時々刻々行うことによりソナグラムが得られる。

$$P(j\omega) = \frac{E_p}{2\pi} \left| \frac{1}{1 + \sum_{k=1}^p \alpha_k z^{-k}} \right|^2 \Big|_{z=e^{j\omega}} \quad \dots(2)$$

ここで、(2)式はスペクトルがLPCから算出することができることを示しているため、特微量としてスペクトルを選択することとLPCを選択することはほぼ同等であると考えることができる。また、一般にスペクトルは少数のLPCで計算できるため、LPCを特微量とすることはスペクトルの詳細を大幅に損なうことなくデータ圧縮できることを意味する。そこで、本法では特微量としてLPCを使用する。

一例として、第3図に上記リーク音のLPCを示す。第3図において、小リーク音に対する低次のLPCが周期的に小さくなっていること（矢印）、また正常との違いが大きいことなどから、LPCによりリーク音の特徴を解析することが可能であるといえる。

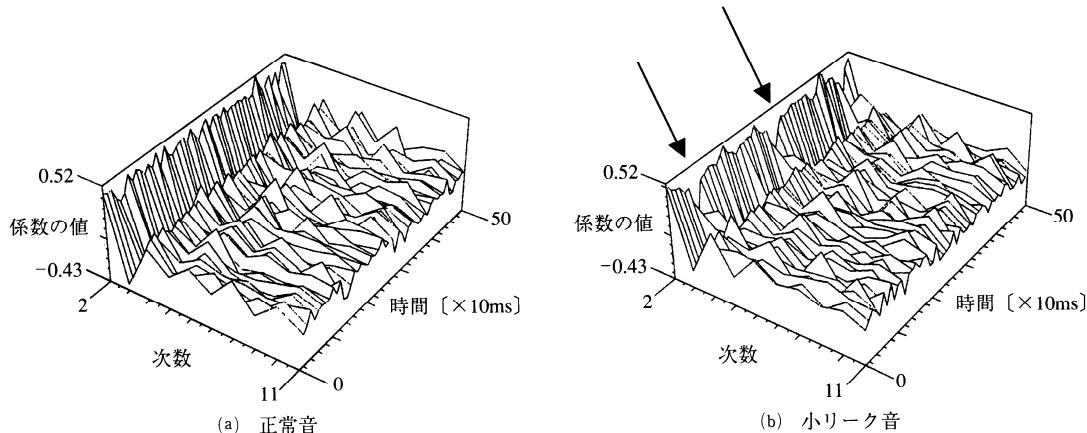
これまでの適用実績から、LPCを特微量として使用する利点として次のことが挙げられる。

- ① 低次の係数に信号の特徴が集約されるため少数のLPCで信号の特徴を表現できる。
- ② ソナグラムよりもばらつきが小さいため、検査・診断上有利な場合が多い。

(2) 識別方法

第2表に代表的な識別方法とその識別性能を示す。識別方法の性能を評価する指標として、上述の第1種エラー率と第2種エラー率があり、共に低いことが求められる。第4図に識別精度に関する模式図を示すが、この図は良品であれば1に近い値を出力し、不良品であれば0

(4)…境界学習型ニューラルネットワークによる検査・診断



第3図 リーク音のLPC

に近い値を出力する診断システムの、良品に対するシステムの出力値の発生頻度と不良品に対するシステムの出力値の発生頻度を概念的に示している。現状では、良品に対する出力値の発生頻度曲線と不良品に対する出力値の発生頻度曲線が交差する場合が多く、適正な閾値を設定

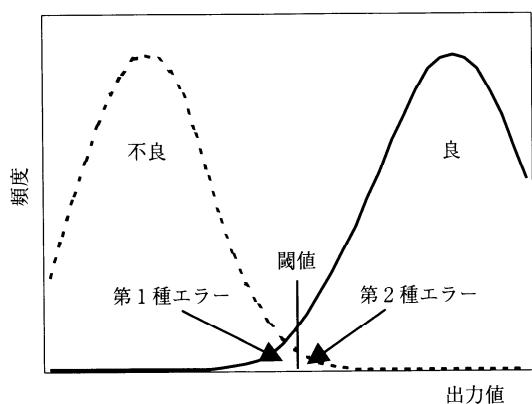
することである程度の誤りを許容して使用することになる。例えば、製造ラインにおける検査では診断精度として99.99~99.9999%程度が求められる。

解析的な識別方法は良品の境界線と不良品の境界線を直線でしか表現できないため、第1種エラー率、第2種エラー率には一定の限界が存在する。

ニューラルネットワークは良品と不良品の境界線を曲線で表現できるため、第1種エラー率は非常に低い。ところが、ニューラルネットワークは良品と不良品の境界線を学習するため、学習していない未知データに対しては一般に診断精度が劣る、すなわち第2種エラー率が高い。このため、現状ではニューラルネットワークの適用可能範囲は限定されている。

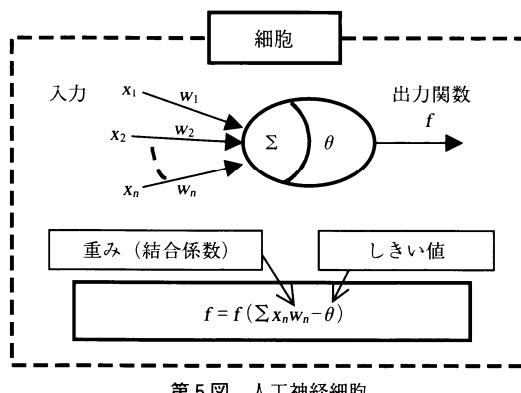
境界学習型ニューラルネットワークは、曲線状の良品の境界線と不良品の境界線を学習するため、学習済みのグループに属するデータに対する診断精度は非常に高い、すなわち第1種エラー率は非常に低い。一方、未知のグループに属するデータに対しては小さな値を出力するため、第2種エラー率も低い。

以下、ニューラルネットワーク及び境界学習型ニューラルネットワークについて概説する。



第4図 識別技術の精度

ニューラルネットワークとは、第5図に示すように脳の神経回路網の働きをコンピュータ上で再現することで、脳の情報処理機構をシミュレートするものである⁽⁴⁾。まず、神経回路網を構成するそれぞれの細胞は、その他の細胞からの出力を重みが掛かった形で入力する。そして、入力和と細胞内部のしきい値の差を独立変数とする関数の出力値を他の細胞に伝える。

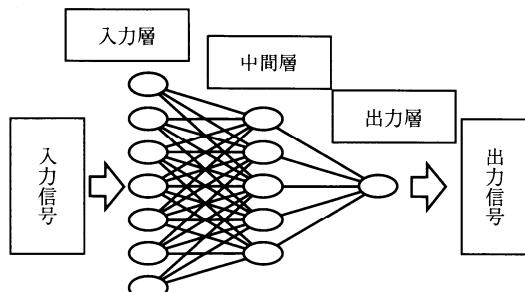


第5図 人工神経細胞

出力関数には、シグモイド関数を使用する場合が多い。シグモイド関数は単調増加関数であり、入力値が閾値より小さい場合は0から0.5の値を、閾値より大きい場合は0.5から1の値を出力する。境界学習型ニューラルネットワークでは、新規に開発した限局型の出力関数を使用して精度の向上を図っている^{(5)～(7)}。

ニューラルネットワークが有用な情報処理を行うためには、多数の細胞で構成されるネットワークが必要である。第6図に示すように、細胞群を階層型に構成したものを階層型ニューラルネットワークと呼ぶ。外からの信号を受け取る入力層と、診断結果を出力する出力層、そして中間層が1層の3層階層型がよく用いられる。

次に、ニューラルネットワークを利用するためには、結合係数としきい値を調整して望ましい入出力関係を得る、学習を行う必要がある。



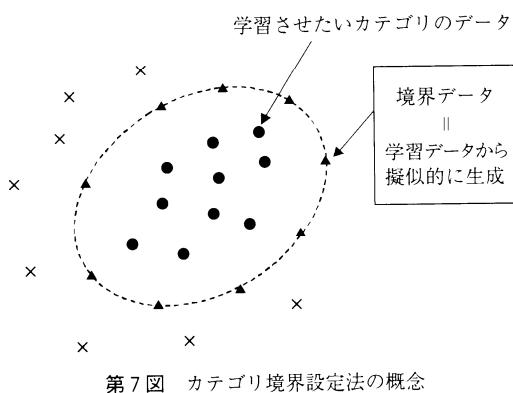
第6図 階層型ニューラルネットワークの構造

通常、学習には誤差逆伝播（バックプロパゲーション）法を用いる。境界学習型ニューラルネットワークにおいても学習には、誤差逆伝播法を用いる。

ところで、従来のニューラルネットワークを使用した診断システムでは、学習に用いるデータを多数用意しなければならない。例えば、ある機械の良・不良を診断する場合、その機械の正常音と異常音のサンプルを多数用意し、そのサンプルデータのうちいくつかを学習データとしてニューラルネットワークに学習させなければならない。構築したニューラルネットワークが妥当であるかどうかを確認するには、学習データに使用した以外のサンプルデータを検定データとしてニューラルネットワークに入力して、その出力結果を望ましい出力値と比較する必要がある。機械の異常音のようなサンプルは、サンプル自体の収集が難しい場合もあり、実用上の妨げとなっている。また、上述したように第2種エラー率が高いという問題も存在する。

そこで、境界学習型ニューラルネットワークでは、任意のカテゴリに属するサンプルは統計的に似通ったデータになることに着目してニューラルネットワークを構築する。カテゴリ境界設定法^{(5)～(7)}と呼んでいるこの方法は、あるカテゴリに属する学習データの統計的性質を利用してカテゴリの境界データを擬似的に作成し、学習データと境界データを同時に学習させる方法である。概念図を第7図に示す。具体的には、

あるカテゴリに属する学習データの分布が正規分布に従うと仮定して、平均値と標準偏差を利用して擬似的にそのカテゴリの境界データを作成する。そして、学習データであれば1を出力し、境界データであれば0を出力するように学習させる。



第7図 カテゴリ境界設定法の概念

この方法を適用すれば、境界データの作成の仕方によって近似的にカテゴリの境界を学習することができ、第1種、第2種エラー率の低減に繋がる。

境界学習型ニューラルネットワークの特長は以下の通りである。

- ① 第1種、第2種エラー率が共に低い。
- ② 良・不良を診断するシステムを構築する場合、不良データは多数必要としない。

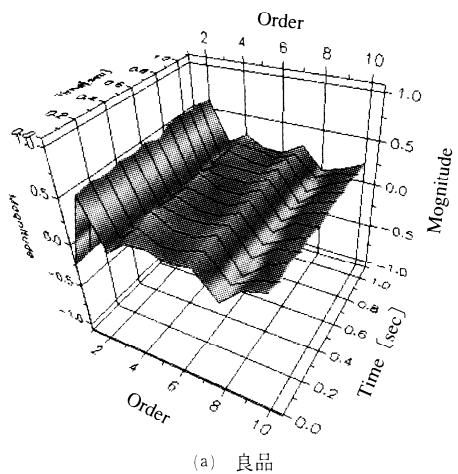
ただし、境界学習型ニューラルネットワークの構築は、従来のニューラルネットワークと比較すると難易度が高い。

◆ 適用事例

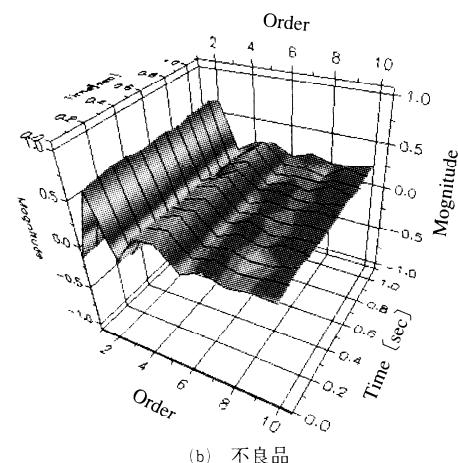
(1) 自動車用エンジンの音響による検査

ここでは、開発した振動・音響診断方法を自動車エンジンの検査に適用した例を示す。良品101データと1種類の不良品22データを収集し、本法の性能を検定した。

第8図に自動車エンジン音のLPCを示す。第



(a) 良品

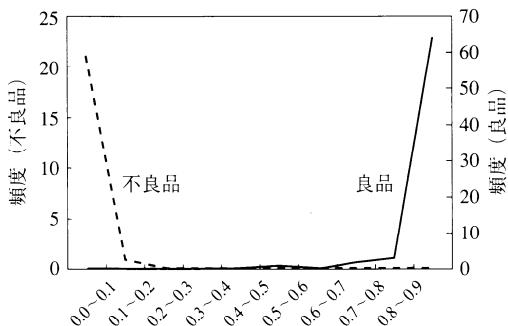


(b) 不良品

第8図 自動車エンジン音のLPC

8図は10次までのLPCを示しているが、良品と不良品でLPCに違いが見られる。

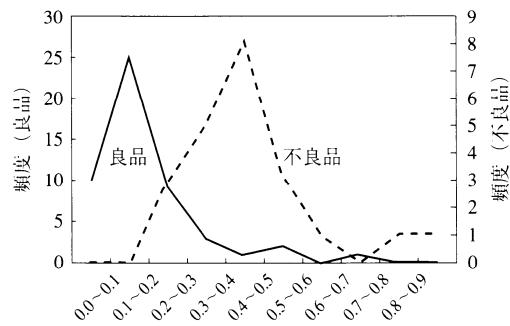
第9図に、次数方向1から10次まで、時間方向5時刻の合計50個のLPCを特徴量として選定し、良品30個の特徴量を境界学習型ニューラルネットワークに学習させ、残りの良品と不良品を診断したときのニューラルネットワーク出力値の頻度分布を示す。横軸は、出力値で0から1の値を示す。縦軸は、それぞれ良品と不良品の頻度値を示す。データ量が少ないが、第9図から良・不良の閾値を0.2から0.4の間に設定すれば、境界学習型ニューラルネットワークによ



第9図 頻度分布（境界学習型ニューラルネットワーク）

り、収集した自動車エンジンの良否を診断できる可能性があることがわかる。

一方、同一のLPCに対して、代表的な解析方法であるマハラノビス距離を適用した結果を第10図に示す。第10図から、誤診断のない閾値を正しく設定することができないことがわかる。



第10図 頻度分布（マハラノビス距離）

(2) ナット供給状態の画像による検査

ここでは、開発した画像診断方法の適用例を示す⁽⁸⁾。

自動車タイヤ締結用ナットの締結工程において、写真1に示すナットトレイに写真2(a)に示すようにナットが手作業で供給される。ところが、写真2(b)に示すように傾いて供給されたり、写真2(c)に示すように上下逆に供給されたり、また供給漏れとなるなど誤って供給される場合がある。このため、ナット供給状態を画像によ

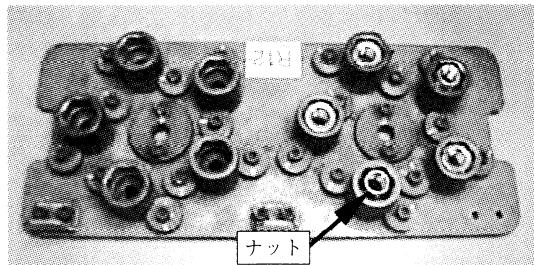


写真1 ナットトレイ

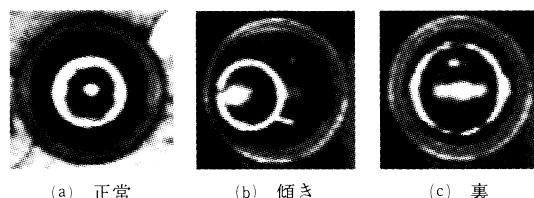
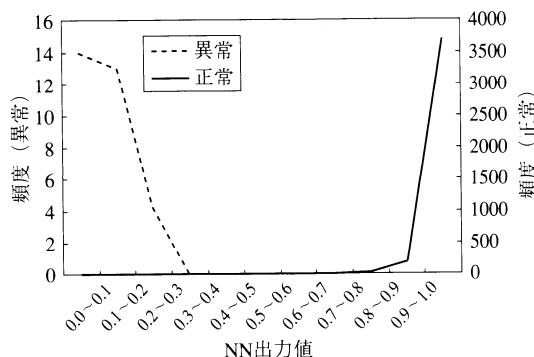


写真2 ナット供給状況

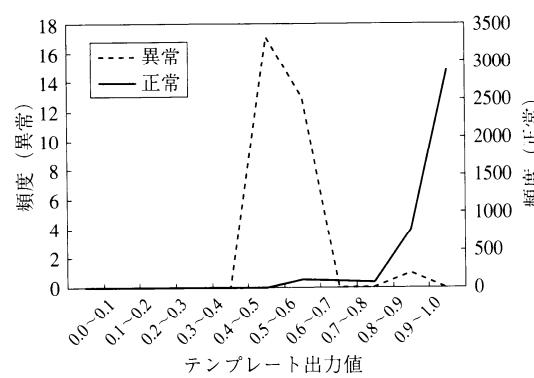
り検査することが必要となる。この検査は、製造ラインで行われるために照明条件が不安定となること、ナット形状にはらつきがあるためナット画像のはらつきが大きいこと、要求検査精度が99.99%と高いことから、比較的困難な検査であるといえる。

最初に、予め収集した3,958個のナット画像（正常3,927個、逆向き20個、傾き11個）を対象にして、正常ナット画像のみの学習により構築した境界学習型ニューラルネットワークを用いて、ナット供給状態を判定し精度の検定を行った。第11図に境界学習型ニューラルネットワークの出力値の頻度分布を示す。正常供給と異常供給でオーバーラップがなく、0.3～0.6の間に閾値を設定すれば良否を判定できることがわかる。

一方、同一画像に対してテンプレートマッチング法を適用した結果を第12図に示す。テンプレートとして正常供給状態の5画像を選択し、これらの出力の最大値を出力値とした。第12図から、異常供給であっても正常供給よりも大きい値が出力されることがあり、誤りのない閾値



第11図 頻度分布（境界学習型ニューラルネットワーク）



第12図 頻度分布（テンプレートマッチング）

を設定することができないことがわかる。

次に、ラインにおいて境界学習型ニューラルネットワークの検証を行ったところ、2,631個のナットトレイを検査して誤判定が生じなかつた。これをナット画像単位で考えれば、26,310個のナット画像を正しく判定しているため本システムは99.99%以上の判定精度を有していることがわかった。

◆おわりに

開発した境界学習型ニューラルネットワークを適用することにより、従来の方法と比較して、第1種エラー率及び第2種エラー率の低い検査・診断システムを開発できることを示した。これまででは主に製品検査分野を対象に開発を行

ってきたが、今後は設備診断分野も対象として技術開発を行う予定である。設備診断では機械の発生振動・発生音に対するニューラルネットワークの出力値をモニタリングすることにより、機械の劣化度、さらには余寿命が診断できるシステムの開発を目指す。

＜参考文献＞

- (1) 尾上守夫編：“非破壊検査の最前線”，日本非破壊検査協会、2002
- (2) 尾上監訳：“パターン識別”，新技術コミュニケーションズ、(2001)
- (3) 森下・小畑：“信号処理”，第6章、計測自動制御学会、1994
- (4) 中野：“ニューロコンピュータ”，p.38、技術評論社、1989
- (5) 辻・佐藤・竹田：SICE’94, p.467
- (6) 竹田・佐藤・辻：第38回自動制御連合講演会（平成7年）、講演番号3010
- (7) 桥・竹田・坪井：日本機械学会2001年度年次大会、講演番号F-1132
- (8) 竹田・木村・坪井：第46回自動制御連合講演会（平成15年）、講演番号TA1-08-2