

# 境界学習型ニューラルネットワークによる タイヤナット画像検査装置

坪井桂一\* 木村剛士\*  
竹田博\*\* 木村陵介\*\*

## Inspection Equipment for Car Tire Hub Nut By Category Boundary Data Method with Learning Neural Network

Keiichi TSUBOI, Tsuyoshi KIMURA, Hiroshi TAKEDA, Ryousuke KIMURA

Mitsui Engineering & Shipbuilding Co., Ltd. has developed and commercialized an inspection equipment which inspects and judges automatically the smooth supply of tire hub nuts on the car manufacturer's assembly line.

This system has a neural network with four cameras, each of which plays brain function and human eye function respectively. The neural network has two special features for pattern recognition: bounded output function and category boundary data method for learning. By this pattern recognition, this inspection equipment will have the same performance as that of human experts of skilled labor establishing an inspection accuracy of 99.99%, which is much higher than in the conventional template matching.

The paper describes the methods of the neural network learning and the equipment specification with its performance.

自動車組み立てラインにおけるタイヤナットが正しく供給されているかどうかを4台のカメラで撮り、自動判定する装置を製品化した。

本装置は、当社独自の境界学習型ニューラルネットワークでナット画像をパターンマッチングし、インラインの検査精度が99.99%と、従来のテンプレートマッチングに比べて優れた性能を実現した。カメラ照明が工場照明、時刻、天候に影響されないなど高いロバスト性がある。

本報では、画像処理、境界学習型ニューラルネットワーク、学習法、テンプレートマッチングとの性能比較を紹介する。

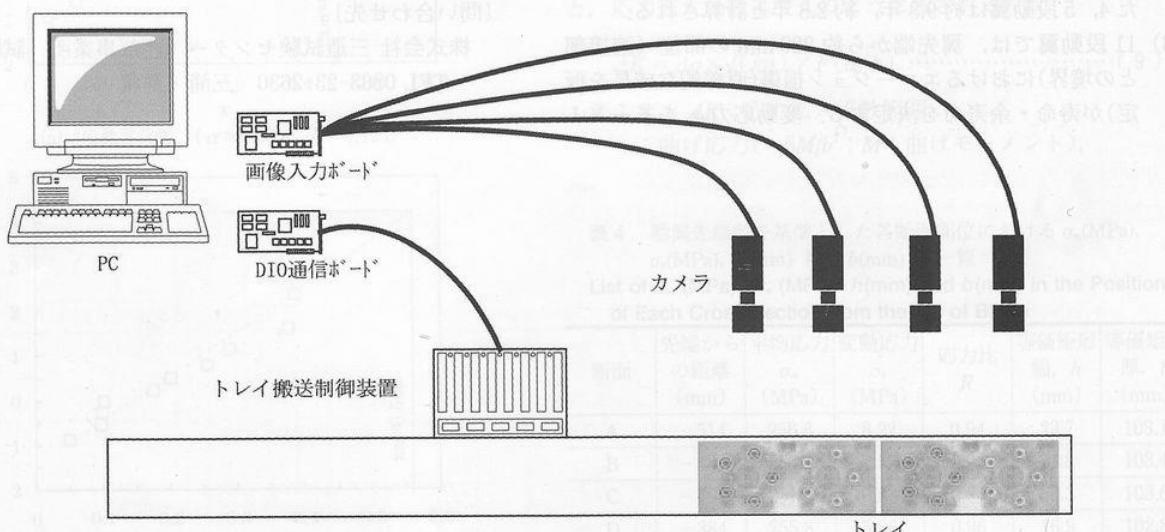


図1 システム構成図  
Structure of System

\* 機械・システム事業本部 メカトロセンター

\*\* 技術本部 機械制御技術開発センター

## 1. タイヤナット画像検査の自動化に成功

### 1.1 ナット田植とは？

自動車の生産ラインでは、ロボットがトレイ上のナットを掴み、ナットランナーで車体にタイヤホイールを締めている。しかし、トレイにナットが正しく並べられていないと、ラインがストップし、生産に支障が生じる。

トレイにナットを並べるのは手作業で行うことで、稻の苗を植える様子と似ていることから、この作業はナット田植と呼ばれる。逆田植とは、ナットが正常とは向きが逆さまでトレイに並んでいる状態のことを言うが、ここでは、斜めのもの、ナットがない状態のものも含めた総称としている。

作業員は田植しながら目視でナットの状態を確認しているが、長時間の作業による集中力の低下、疲労などにより、どうしても見落としが出ることがあり、ナット田植は神経を使う作業である。

そこで、この問題を解決するために、人の確認作業に替わる、境界学習型ニューラルネットワークを使った自動画像検査装置を開発したので、以下に報告する。

### 1.2 タイヤナット画像検査装置

#### 1.2.1 構成

1枚のトレイに載るナットの数は、タイヤホイール1つ分について5個、自動車の片側では10個となっている（写真1参照）。1回の検査は、2枚のトレイを対象とし、計20個のナットについて行う。

システム構成図を図1に示す。1台のCCDカメラで5個のナットを撮影し、2台のカメラで1枚のトレイを撮影するため、自動車1台分では4台のカメラを要する。カメラで撮影した画像は、パソコンの画像入力ボードから取り込む。また、ナット搬送ライン制御装置とは、DIO通信ボードを介して通信を行ない、逆田植を検出すると正常田植になるまでラインは停止している。装置の各機器仕様を表1に示す。

図2に処理の流れを、図3にプログラムの構成を示す。

- ① ナット田植の作業が完了した作業員は、トレイ搬送ライン制御装置の検査開始ボタンを押す。
- ② トレイ搬送ライン制御装置は、DIO通信によって検査すべきナットの種別と検査開始の指令を検査装置へ出す。
- ③ 検査装置は、その時のカメラ画像を撮影し、ナットの田植

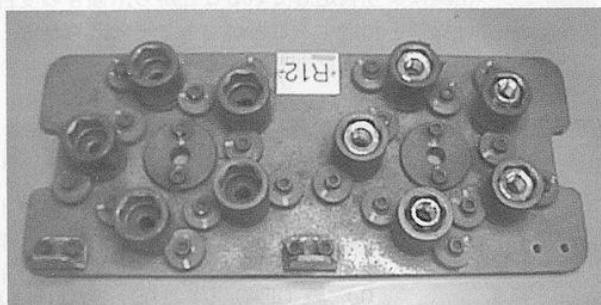


写真1 トレイ 円ナット表(正面)とナット裏(逆向き)の写真

状態を判定し、その結果を再びDIO通信によってトレイ搬送ライン制御装置へ送る。

- ④ 検査結果を受けたトレイ搬送制御装置は、OKまたはNGのランプを点灯し、作業員へその結果を明示する。

表1 機器仕様

Specification of Hardware

PC	CPU	Pentium 4 1.5 GHz
	メモリ	256 MB
	OS	WindowsNT Workstation 4.0
CCDカメラ XC-7500 (SONY)	光学サイズ	1/2インチ
	有効画素数(水平)	659
	有効画素数(垂直)	494
Cマウントレンズ VCL-25Y-M (SONY)	焦点距離	25 mm
	画角(水平)	20.0°
	画角(垂直)	15.0°
	画角(対角)	24.8°

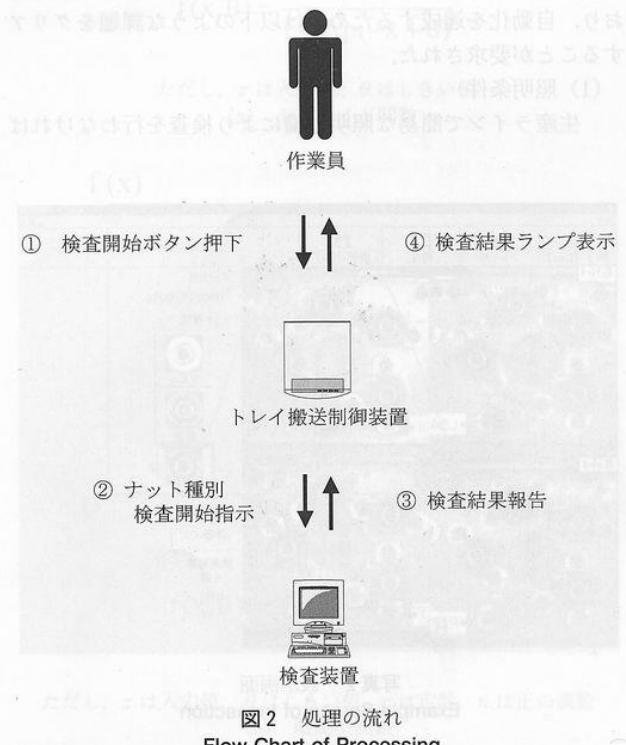


図2 処理の流れ  
Flow Chart of Processing



図3 プログラム構成  
Structure of Program

写真2にソフトウェアの画面を表示する。各ナット枠の右肩は正常ナットとの相関値である。また、検査結果がNGの場合は、該当するナット枠が赤く点滅し、作業者にその箇所を知らせる。作業者は指示に従って正常田植を行う。

### 1.2.2 性能

ナット田植の完了した作業員が検査開始のボタンを押し、検査結果のランプが点灯するまでの処理時間は、2秒弱である。判定精度は顧客の要求値を満足しており、現在ラインで順調に稼動している。

### 1.2.3 他への応用性

他への応用としては、表2のようなものが考えられる。

## 2. タイヤナット画像検査技術について

### 2.1 タイヤナット画像検査の課題

近年、工場の生産ラインにおいて、画像による製品検査の自動化ニーズが高まっており、これまで様々な自動化の試みがなされてきた。ところが、従来の方法では自動化ができないために、人に頼らざるを得ない検査が多く残されている。本報のタイヤナット画像検査も、これまで人により行われており、自動化を達成するためには以下のようないくつかの課題をクリアすることが要求された。

#### (1) 照明条件

生産ラインで簡易な照明設備により検査を行わなければ

ならない。ところが、簡易な照明設備を使い生産ラインでナットの画像を撮影すると、季節、天候（雨天、晴天）、時刻（昼間、夜間）などによる太陽光の変化及び、工場に設置された既設照明の照射具合の影響を受け、安定な画像を得ることができない。そこで、安定な画像が得られない場合でも十分な精度でナットの供給状態を判定できるロバスト性の高い判定方法が要求される。

#### (2) 加工精度

検査対象とするナットは、高い精度で加工されている部分と低い精度で加工されている部分があり、低い精度で加工された部分の画像は個体差による光の反射具合が異なるため、画像間にばらつきが生じてしまう。そこで、照明条件への対応と同様、ロバスト性の高い判定方法が要求される。

#### (3) ナットの傾き

ナットの向きの判定と同時に、図4(a)に示すようにナットが傾いて供給されているかどうかを検査しなければならない。ナットの表裏（図4(b), (c)）の状態を判定するだけならば、画像内のナットもある程度一定で判定が容易である。しかし、傾き画像は傾き具合及び方向のパターンが幾通りもあるため、ナット画像が様々で判定し難く、正常（ナット表）と誤判定してしまう場合がある。

#### (4) 判定精度

誤判定率は車両500台で1台の割合とされ、1車両当たり20個のナットを使用するため、ナット単位では精度99.99%という高い判定精度が必要である。

### 2.2 画像検査手法

タイヤナット画像検査に適用できる手法としてテンプレートマッチング<sup>1)</sup>、シグモイド型関数を用いたニューラルネットワーク（以下NN）<sup>2)</sup>及び当社独自の境界学習型NN<sup>3)</sup>の3つの手法が考えられる。そこで、これらの方法の適用可能性を検討する。

#### (1) テンプレートマッチング

テンプレートマッチングは、カテゴリごとに標準パターン（テンプレート）を用意し、これらのパターンと入力されたパターンとを比較し、入力パターンがもっともマッチング率の高い標準パターンのカテゴリに属するパターンと判定する方法である。表3に示すように、画像にばらつきがあると、判定精度が悪くなる。ナットの傾きに対しては、画素ごとの相関により判定していることから、傾きの度合いによっては異常と判定することができると思われる。

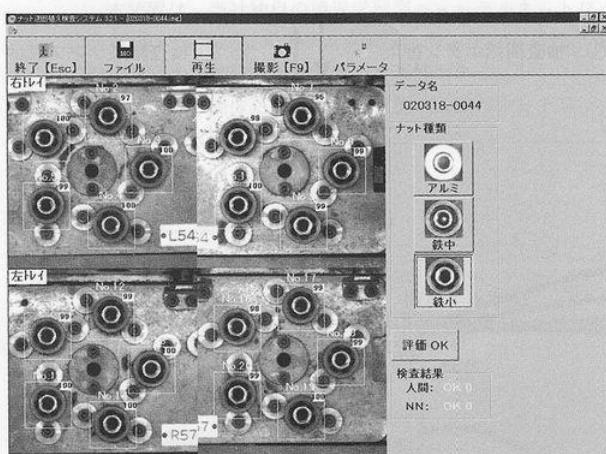


写真2 表示画面  
Example Screen of Inspection

表2 他への応用例  
Other Examples of Application

分野	例
画像検査	電子・機械部品の検査
	表面傷検査
	食品の等級検査
	薬品の検査
セキュリティ	文字認識
	火災・煙検知
	侵入者検知
	個人認証

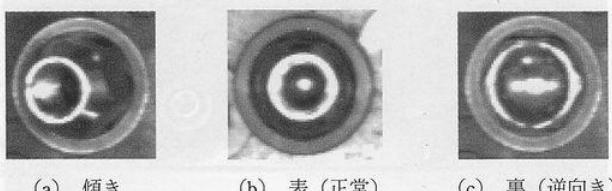


図4 ナットパターン  
Pattern of Nut

表3 ナット画像検査への適用度  
Ability for Inspection

判定手法	照明条件	加工精度	ナット傾き	判定精度	判定速度
テンプレートマッチング	△	△	○	△	△
シグモイド型NN	○	○	×	×	○
境界学習型NN	○	○	○	○	○

### (2) シグモイド型ニューラルネットワーク

シグモイド関数（図5(a)）を用いたNNは、生物の大脳を模擬した情報処理方法であり、パターン識別能力が高いことが知られている。ばらつきのある多数の画像を学習データとして用いることにより、ある程度ばらついた画像に対しても精度良く判定することができる。しかし、シグモイド型NNの欠点としては、未学習パターンが入力されると学習したパターンのどれかと誤判定してしまう場合が多いことである（図6(a)）。このことから、表向きと裏向きだけを学習させた場合には傾きパターンを正常パターンと誤判定してしまう可能性がある。一方、傾きパターンを学習させる方法もあるが、傾きのパターンは無数にあるため、すべてを学習させることは現実的ではない。したがって、シグモイド型NNは傾きナットについては判定できないと考えられる。

### (3) 境界学習型ニューラルネットワーク

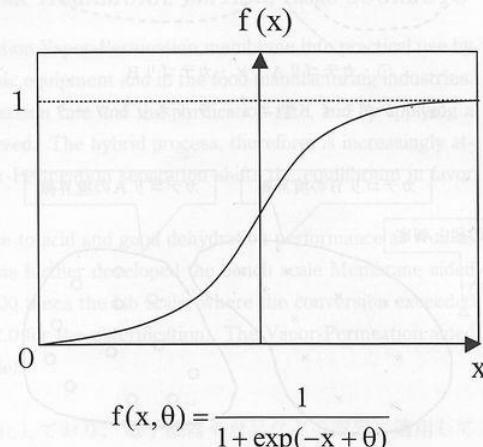
当社独自のNNである境界学習型NNは、シグモイド型NNとは異なり、ある決まった範囲内の入力値に対してのみ有限値を出力する限局型出力関数（図5(b)）を用いてパターンマッチング能力を向上させている。さらに、もう一つの特徴として、カテゴリ境界設定法を適用してNNを構築する。これは、例えはある特徴量の正常と異常を判定するNNを構築する際に、正常データを学習に用いるとともに、正常と異常の境界に当たるデータ（以下境界データ）を正常データの統計量をもとに自動的に生成して学習データに加えることで認識率の向上を図る方法である（図6(b)）。この二つの当社独自技術を用いることにより、未学習パターンに対しても高い判定性能を持ち、傾きパターンに対しても十分に対応可能と考えられる。さらに、学習データとして正常パターンのみを学習させれば良い点もシグモイド型とは違っている。欠点としては、設計パラメータが多く、調整に時間がかかることがある。

以上より、上記3つの手法の中で、シグモイド型NNは、傾きパターンを正しく判定できないため適用不可能である。そこで、テンプレートマッチング及び境界学習型NNの適用可能性を検討する。

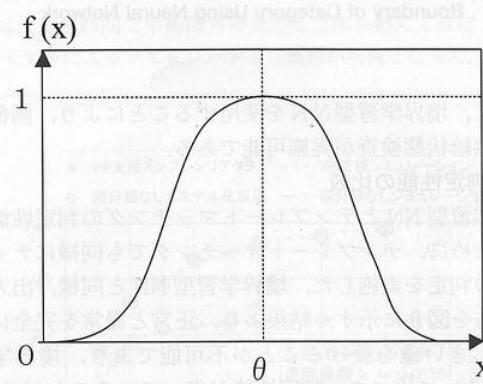
### 2.3 境界学習型ニューラルネットワークによる検査

自動車タイヤ締結用ナットをトレイに供給した際に、ナットの供給状態が正常であるかどうかを、境界学習型NNを使用して判定する検査を実施した。今回、検査の対象としたナットは、鉄ナット、袋ナット及びアルミナットの3種類であるが、本報では袋ナットの検査結果について紹介する。

NNの構築には、学習データとして、ナット表（正常）とナット裏（逆向き）の2パターンを使用した。NN判定とし



ただし、 $x$ は入力値、 $\theta$ はしきい値  
(a) シグモイド関数



ただし、 $x$ は入力値、 $\theta$ はしきい値、 $c$ は定数、 $n$ は正の偶数  
(b) 限局型関数

図5 出力関数  
Output Function

ては、入力したナット画像に対する出力値がしきい値より高いか低いかで正常かどうか判定される。袋ナット3958個（正常3927個、逆向き20個、傾き11個）を対象としたナット画像検査でのNN出力値の頻度分布（ヒストグラム）を図7に示す。結果より、しきい値を0.3～0.6の間に設定すれば、正常と異常の分布を完全に分離できることが分かる。

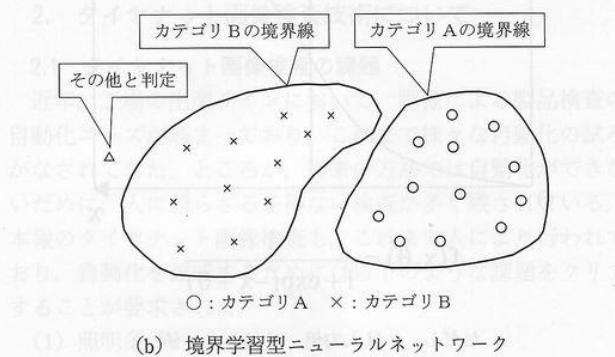
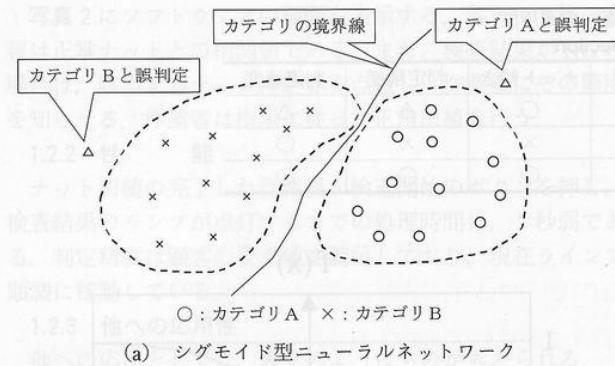


図6 ニューラルネットワークによるカテゴリ境界線  
Boundary of Category Using Neural Network

たがって、境界学習型NNを使用することにより、画像でのナット供給状態検査が実施可能である。

#### 2.4 判定性能の比較

境界学習型NNとテンプレートマッチングの判定性能を比較するために、テンプレートマッチングでも同様にナット画像検査の判定を実施した。境界学習型NNと同様、出力値の頻度分布を図8に示す。結果より、正常と異常を完全に分離できるしきい値を設けることが不可能であり、境界学習型NN(図7)に比べて、判定性能が劣っていることが分かる。したがって、テンプレートマッチングをナット画像検査に適用するのは困難で、今回の検査では境界学習型NNの適用が妥当である。

#### 参考文献

- 1) 大津、ほか：パターン認識、(1996), p. 13, 朝倉書店
- 2) 石井、ほか：パターン認識、(1998), p. 30, オーム社

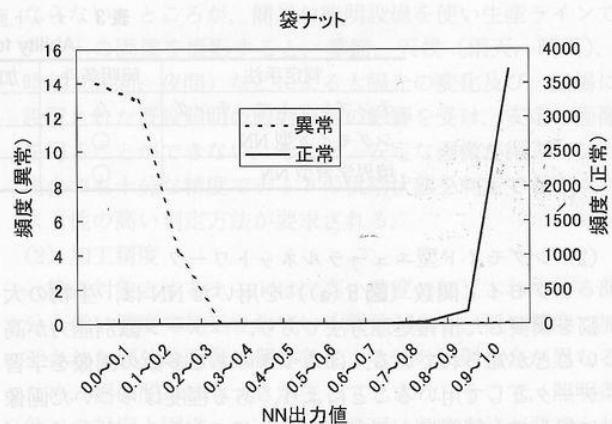


図7 境界学習型ニューラルネットワークの出力値ヒストグラム  
Histogram of Category Boundary Data Method for Learning Type Neural Network Output

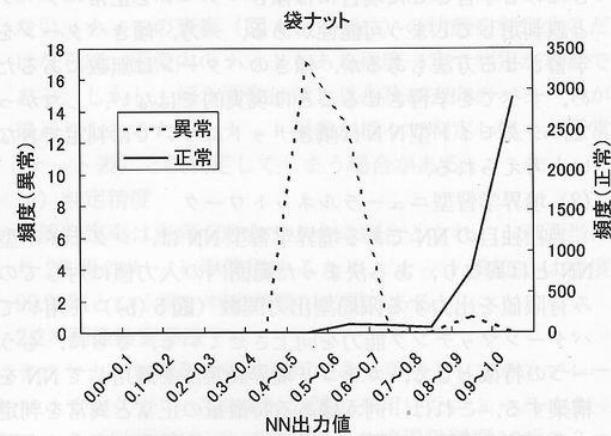


図8 テンプレートマッチングの出力値ヒストグラム  
Histogram of Template Matching Output

- 3) 竹田、ほか：カテゴリ境界設定法を用いて学習した限局型出力関数を有するニューラルネットワークによるパターンマッチング、第38回自動制御連合講演会予稿集、(1995), p. 305

#### [問い合わせ先]

機械・システム事業本部 メカトロ・システム営業部  
TEL 03-3544-3221 奥 幸之介