

# 曖昧さを含んだ目視検査の自動化技術に関する研究

— 高次局所自己相関特徴と統計処理 —

大高 理秀\* 富長 博\*

## 1. はじめに

県内の機械部品やプリント基板の製造現場では、製品の品質向上のために検査員による目視検査が行われているが、一方では、海外や地域間の価格競争に打ち勝つために、さらなる自動化が求められている。

代表的な目視検査として外観検査があるが、キズの有無などの検査では、良・不良の判断に幅があるため事前に判定データを準備できないことが多い。また、従来のテンプレート・マッチング等による画像認識が難しいことから、自動化が遅れている。このため、曖昧な判断要素を含んだ目視検査を自動化するためには、新たな手法の開発と適応が必要である。

## 2. 目的

従来の画像認識装置では、判定条件として、形状や寸法等の明確な基準が必要である。このため、面積と長さなどを複合的に判断する場合や、「多い」・「少ない」などの曖昧な条件の場合には基準の数値化が難しく、また数値化に時間を要するため、多品種少量、短納期、サイクルが短い工業製品では、自動検査装置が導入できない場合が多い。

本研究では、画像の認識に統計的手法を用いることにより、判定基準を数値化しなくても（または、判定基準が曖昧であっても）判定結果が得られる画像認識技術について研究を実施する。統計的手法は、主に画像データからの特徴抽出と統計処理による学習で構成されるが、本研究では、工業製品に適した特徴抽出法と学習法について研究するとともに、従来の画像処理技術との組合せによる曖昧さを含んだ画像認識アルゴリズムを開発することを目的とする。

## 3. 実験方法

### 3.1 高次局所自己相関特徴

高次局所自己相関 (HLAC) 特徴は、独立行政法人 産業技術研究所の研究成果である。この HLAC 特徴パターン (図 1) を利用し、参照点まわりの 3 × 3 画素の特徴パターンに対応した画素の値の積和を計算する。全領域についてスキャンニングし特徴量を求める。各サンプルの特徴量と答えとの相関関係を求め関係式を決定する。この関係式を未知データに対し、使用して画像認識を行う。

HLAC の特徴の一つは、位置普遍性である。画像の位置が変わっても特徴量は変化しない。もう 1 つの特徴は、画面加法性が成り立つ。画像を追加した場合、画像全体の特徴量は、それぞれの画像の特徴を足すことで求まる。




図 1 高次局所自己相関 (HLAC) 特徴パターン

### 3.2 HLAC 特徴と因子分析

HLAC 特徴は画面加法性から下の行列式が成り立ち、行列式を解くことで数が計算できる。この方法では、画像の切り出しは一切不要で計算時間は一定である。

$$\begin{aligned}
 x &= \sum_{i=1}^n a_i f_i \\
 &= [f_1, f_2, \dots, f_n] a \\
 &= F a \\
 a &= (F' F)^{-1} F' x \\
 a_i &: \text{因子付加量} \\
 f_i &: \text{因子}
 \end{aligned}$$

図 2 の学習データをもとに、画像のマークを数える実験を行った。既知のマークであれば、正確に数えることができた (図 3)。ただし、未知データの混入 (図 4) や画像の回転 (図 5) により、計算が不正確になることが分かった。因子を新たに学習的に獲得する機能が必要となる。この際に、不正確さ (個数が整数からはずれる) が未学習因子の存在の検出に逆に利用できる。





図 2 学習データ



因子分析結果

- 1 : 1.000000
- 2 : 3.000000
- 3 : 1.000000
- 4 : 2.000000

図 3 既知マーク




図 4 未知データ混入




図 5 画像の回転

### 3.2 HLAC 特徴と判別分析

手書き数字 (図 6) の判別分析実験を行った。学習用データ (各クラス: 50) と未学習データ (各クラス: 50) を用意して、学習数による判別率の変化を調べた (図 7)。クラス 3 は、1~3 の数字、クラス 5 は、1~5 の数字である。学習数が少ないと判別率が落ちることが分かる。クラス数の約 10 倍程度の学習数が必要であることがわかった。工業製品の良品・不良品を判別するためには、良品・不良品のサンプルを数多く集める必要がある。実際は、不良品を数多く集めることは難しく、良品のみを学習して不良 (異常) を検出する必要がある。




図 6 手書き数字




図 7 手書き数字の判別

### 3.2 HLAC 特徴と主成分分析

主成分分析は、学習データから主成分を分析して、その主成分から大きく離れたものを異常として判断するものである (図 8)。




図 8 主成分分析

基板の異常 (傷) について検査実験を行った。この基板は場所により様々な模様が存在し、傷を模様と区別して検出するのは難しい基板である。

今回学習数が少ないため、3x3 画素の HLAC 特徴を参照点の HLAC 特徴として取扱い、1 枚の基板中で各参照点の HLAC 特徴を学習した。それぞれの HLAC 特徴が異常な値か判断し、異常と判断した参照点は赤くする実験を行った。結果を図 9・図 10 に示す。図 9 の基板では、輪状の異常を検出できたが、図 10 の基板では、長い縦の傷 (異常) が検出できなかった。今後、HLAC 特徴抽出方法の工夫や画像処理による前処理を追加する必要がある。



図 9 基板の検査結果 1



図 10 基板の検査結果 2

### 5. まとめ

HLAC 特徴と統計処理の特徴を理解し、有効性を確認するとともに、課題があることが分かった。検査対象により、画像処理による前処理や HLAC 特徴抽出の工夫をすることで、今まで難しかった検査が可能になると考えられる。今後、様々なサンプルに適用して、目視検査の自動化技術を検討する。

### 謝辞

本研究において、実験方法や HLAC 特徴・統計処理についてご指導いただいた独立行政法人 産業技術研究所 フェロー 大津展之氏に深謝いたします。

### 参考文献

1) 大津, 栗田, 関田, パターン認識, 朝倉書店, 1996.