

金属加工品上の異種欠陥の同時自動検出に関する検討

A Study of On-Stream Defect Detection of Metal Artifacts

黒川 健太†

Kenta Kurokawa

森本 雅和†

Masakazu Morimoto

藤井 健作†

Kensaku Fujii

1. まえがき

製品の品質保証のために、欠陥を含む不良品の検出を行う製品検査が行われている。また、生産性の向上のために、その製品検査がコンピュータビジョンシステムによる自動化が進んでいる。例えば、織物製品や半導体パターンの欠陥検出がよく知られている。

本稿では、表面がヘアーライン加工された円筒型の金属加工品(図1)を製品検査の対象物とする。その表面をラインCCDセンサで撮影し得られた画像から、製造過程で発生したキズや液体の流出によるシミといった異種の欠陥(図2)を同時に自動検出することを目的とする。また、本稿では、製品の品質保証のために見逃し率1%未満、誤検出率数%未満という識別精度で、1製品当たりの検査を200ms以内というオンライン処理で行うことを目標とする。

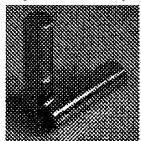


図1 円筒型金属加工品



(a) キズ



(b) シミ

図2 欠陥例

2. 異種欠陥の特徴ベクトル抽出

本章では、異種欠陥を識別するための特徴ベクトル抽出法について述べる。まず、得られたライン画像に対して処理を施し、処理後の画像から特徴量を抽出する。そして、抽出した特徴量をベクトル変換することで、特徴量を特徴ベクトルとして表す。以下で各処理の詳細について述べる。

2.1 前処理

図3に物体表面をラインCCDセンサで撮影し得られた1500×1600pixelsの原画像を示す。図3から原画像の左右両側は撮影時の光源の影響により暗く、ローラの押し付けにより縦方向に直線を含む。また、横方向にはヘアーラインと呼ばれる髪の毛のような細い線が連続的に含まれている。これらは欠陥とは別の特徴なため、前処理として、ヘアーライン以外の特徴を欠陥とは別に除外する。そこで、原画像において、縦一列の画素値の平均値が128になるように各画素値をシフトさせ、画像の補正を行う。補正結果を図4に示す。

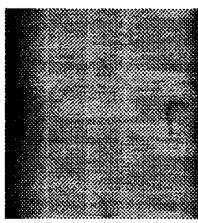


図3 原画像

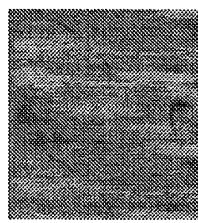


図4 補正画像

†兵庫県立大学大学院工学研究科電気系工学専攻

2.2 特徴量抽出

特徴量の抽出は、画像を $N \times N (=d)$ サイズのブロックに分割し、ブロック単位で行う。また、各ブロックから抽出する特徴量として、オンライン処理を考慮し、以下に示すものを用いる。

(a) 画素値

ブロック内の画素の輝度値を特徴量とする。

(b) 離散コサイン変換(DCT)

離散コサイン変換(DCT)は、離散フーリエ変換(DFT)と同様に入力信号を周波数領域に変換する直交変換である。しかし、DFTはコサイン関数とサイン関数を用いて複素数からなる係数への変換に対して、DCTはコサイン関数のみを用いて実数からなる係数への変換を行うため、DFTよりも計算コストが低い。また、ブロック内の各画素値に対する変換後のDCT係数の各成分は、変換前のブロック内の画像の特徴に応じて異なる値をもつ特徴がある。そこで、このDCT係数を特徴量として抽出する。

2.3 特徴量ベクトル変換

各ブロックから抽出した特徴量は、 $N \times N$ の2次元配列で表されている。そこで、ブロック内をラスタスキャン順で1次元配列に再配置し、 d 次元のベクトルに変換したものを持特徴ベクトルとする。

2.4 特徴ベクトル成分選択

コンピュータビジョンによる欠陥検出では、高い検出精度を保ちつつ、計算コストや処理時間を低減することが重要とされている。ここで、抽出する特徴ベクトルの次元が高次元の場合、それだけ計算コストが膨大となり、処理時間も掛かる。そこで、特徴ベクトルを構成する d 個の成分中で有効な成分のみを選択し、ベクトル次元数を削減することで、計算コストと処理時間の低減を図る[1]。

3. SVMによる異種欠陥識別

Support Vector Machine(SVM)は、最も認識性の優れた学習モデルの一つとして知られている。本稿では、SVMを用いた異種欠陥の識別を行う。まず、学習用画像から抽出した特徴ベクトルによって張られる特徴空間上で、マージン最大化という基準を用い、非欠陥・欠陥の特徴ベクトルを2つのクラスに分ける。その特徴ベクトルとクラスとの対応関係を学習したものを学習データとして蓄える。そして、その学習データとテスト画像から同様の方法で、各ブロックから抽出した特徴ベクトルを照合することで、各ブロックにおいて非欠陥・欠陥の識別を行う[2]。

4. 評価実験・結果

4.1 検出評価

本稿では、欠陥を含む5個の製品サンプル表面をラインCCDセンサで撮影し得られた画像から欠陥を検出する。なお、得られた原画像は物体表面を1回転半撮影した画像のため、画像の一部を切り除いた1回転分の1472×1024pixelsの画像を準備する。今回準備したサンプルではキズを含むものが1つしかなかったため、各画像を上下半分に分割し、

クロスバリエーション法により評価を行った。表1に示すように、画像サイズとブロックサイズを変更し、各特徴量を用いた欠陥検出を行う。図5に各検出条件における識別精度をグラフにしたものを見た。ここで、見逃し率は欠陥単位で、誤検出率はブロック単位で算出した。

表1 画像サイズとブロックサイズの変更

画像サイズ	ブロックサイズ		
	Large	Middle	Small
Normal (1472×1024)	64×64	32×32	16×16
Half (736×512)	32×32	16×16	8×8
Quarter (368×256)	16×16	8×8	4×4

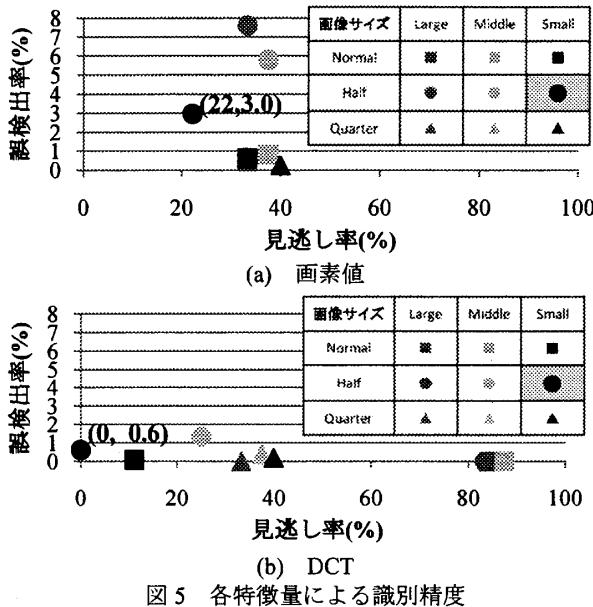


図5から特徴量としてDCT係数を用いたとき、画像サイズHalf、ブロックサイズ8×8において見逃し率0%、誤検出率1%未満と目的の識別精度を実現できた。以下の実験では、この条件下で行うものとする。

4.2 キズ・シミを区別した評価実験

上記の評価実験では、欠陥であるキズとシミを区別することなく、非欠陥・欠陥を識別していた。そこで、キズとシミの特徴量を別々に抽出し、キズとシミを別々に検出したものと識別精度を比較した結果を表2に示す。

表2 識別精度の比較

キズ・シミ一括		キズ・シミ区別	
見逃し率(%)	誤検出率(%)	見逃し率(%)	誤検出率(%)
0.00	0.60	0.00	0.56

表2から、キズとシミを別々に検出することで、誤検出率をわずかに低減することができた。

4.3 成分選択による識別精度と処理時間の関係性

これまでの評価実験では識別精度のみを考え、処理時間のことは考慮していなかった。本実験では、抽出した特徴ベクトルの64成分のうち有効な32成分のみを選択し、計算コストを削減することで、識別精度を保つつつ、処理時間の高速化を図った。図6にキズとシミの特徴量を別々に抽出し、8×8ブロック内の各成分で分散を計算したものを見た。

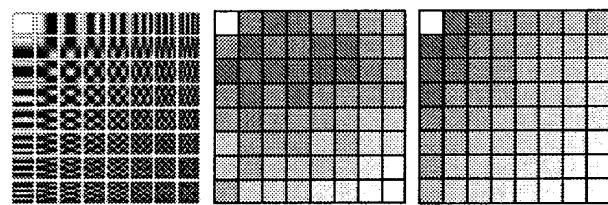
(a) DCT 基底関数 (b) キズ (c) シミ
図6 8×8 ブロック内各成分の分散(キズ・シミ区分)

図6(b)から、垂直方向の周波数成分はキズにのみ強く現れるため、キズの検出にはDCTブロックの上半分32成分を選択した。また、シミの特徴量は図6(c)から低周波成分に強く現れるため、DCTブロックの左上32成分を選択した。

キズとシミの区別と成分選択を行った場合の識別精度と処理時間の変化を図7,8にそれぞれ示す。ただし、CPUにはCore2 Quad Q6600を用いた。また、キズとシミの特徴量を一括して抽出した場合における成分の選択は、シミの特徴量と同じ選択をした。

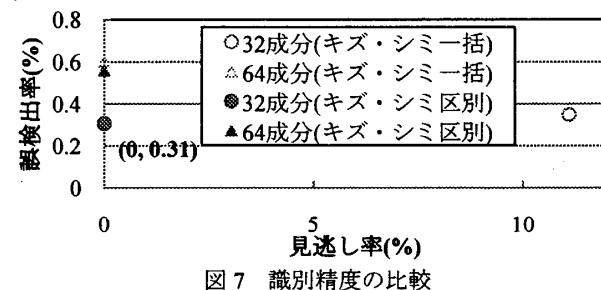


図7 識別精度の比較

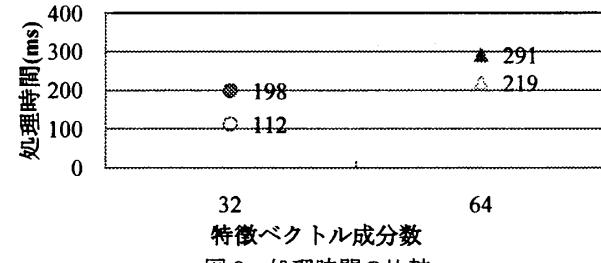


図8 処理時間の比較

図7,8から、キズとシミを区別して特徴量を抽出したこと、で、キズとシミそれぞれで有効な成分を選択でき、ベクトル成分数を削減しても高い識別精度が保ち、処理時間を低減することができた。

5.まとめ・今後の課題

本稿では、円筒型の金属加工品を検査対象物とし、その表面をラインCCDセンサで撮影し得られたラインCCD画像から異種欠陥の検出を行った。そして、シミとキズの欠陥を別々に検出することで識別精度を向上でき、特徴ベクトル成分のうち有効な成分のみを選択することで、識別精度を保つつつ、処理時間の低減を行えた。今後の課題として、PCAやICAなどを利用した他の特徴量を用いた識別における識別精度・処理時間の確認が挙げられる。

参考文献

- [1] Zhen Hou and John M. Parker, "Texture Defect Detection Using Support Vector Machines with Adaptive Gabor Wavelet Features," IEEE, 2005.
- [2] 栗田多喜夫, "サポートベクターマシン入門," 2002.