

# 照度差ステレオと深層学習を用いた鋳物の異常検知

Anomaly detection using Photometric Stereo and Deep learning for cast products

中野 可也\*      松田 一徳\*      平賀 幹敏\*  
Yoshinari Nakano      Kazunori Matsuda      Mikitoshi Hiraga

Every casting has various appearances despite same products such as dimensional change, surface treatment, difference of viewpoints and light source. It is important for proving automatic visual inspection system for castings, that the system includes these fluctuations. Authors divided this into two elements that imaging, and anomaly detection. At the time of visual inspection, inspectors evaluated not only the color of the surface, but also the shape of the surface. Therefore, authors adopted Photometric stereo as imaging method to take both of two and PatchCore as anomaly detection method.

In this paper, authors explain how authors came to this method and provide specific examples, along with an explanation of the method and actual data.

KEY WORDS: Visual inspection , Visual testing (VT), Photometric stereo (PMS), Albedo, Surface normal, Anomaly detection, Embeddings, Deep learning, PatchCore

## 1. 緒言

鋳物の外観は、収縮による寸法変化、表面処理、熱処理や光源の影響によって個性豊かな表情を見せる。特に、外観不良の表れ方は多種多様で、全てを網羅する不良見本を用意することは現実的ではない。この課題を整理すると、鋳物の見え方を安定させる撮像方法の確立と、鋳物の個性を柔軟に受け止める評価方法の確立の二つの課題になると考える。

そこで、撮像については、光源を切り替えながら撮像し、数値解析的に光源の影響を取り除く照度差ステレオに注目した。評価については、良品のみを見本とし、見本との差が大きいものを異常として検出する、PatchCoreという深層学習による異常検知に注目した。

本稿ではこの照度差ステレオと深層学習を組み合わせた鋳物の異常検知に取り組み、その有効性を確認する。

## 2. 試験方法の検討

### 2.1 撮像方法の検討

目視検査とカメラによる外観検査を比較すると、カメラでは影や鏡面反射の影響を取り除けな

い点と、表面形状を取得できない点が大きく異なる。そこで、素材の色（アルベド画像）を得ると同時に、表面の傾き（法線ベクトル画像）も取得できる照度差ステレオと呼ばれる撮像手法を採用した。本手法の模式図をFig. 1に示す。




Fig. 1 Diagram of Photometric Stereo.

### 2.2 照度差ステレオ

#### 2.2.1 照度差ステレオの原理

光源から放たれた光が物に当たると、入射角に応じた鏡面反射を起こすほか、物体の表面で拡散反射を起こす。この状況をFig. 2に示す。




Fig. 2 Diagram of Specular and Diffuse reflection.

\*開発本部 開発グループ

ここで、今回取り扱う鋳物と鏡面反射及び拡散反射の関係性について考える。鋳物は金属でできているため、金属光沢を持つ。金属光沢をFig. 2で表すと、太線矢印で示す鏡面反射（グレア、白飛び）になる。また、一般に「素材の色」と呼ばれるのは、細線矢印で示す拡散反射によって見える表面のアルベドである。

白飛びを起こすため、外観の異常検知をする上で鏡面反射は邪魔になるが、後述する照度差ステレオを多数の光源とともに用いることで、鏡面反射の影響は軽減され、素材の色（アルベド画像）を得ることができる。反対に、本手法では鏡面反射の評価ができないが、一般的に鋳物の鏡面反射具合は評価指標とならない。従って、鏡面反射についてここで考慮する必要はない。

これらの前提に基づき、本稿では以降、鏡面反射を起こさず拡散反射のみを起こす、理想的な表面（ランバート面）を想定した、ランバート反射の物理モデルについて取り扱う<sup>1)</sup>。

ランバート反射の物理モデルをEq. 1に示す。

$$\begin{bmatrix} I_1 \\ I_2 \\ I_3 \end{bmatrix} = \rho \left( \begin{bmatrix} L_1 \\ L_2 \\ L_3 \end{bmatrix} \cdot n \right) \quad (1)$$

ここで、 $I \in \mathbb{R}^{3 \times 1}$  は輝度（カメラで撮像した画像のうちのある一画素）、 $\rho \in \mathbb{R}^{1 \times 1}$  はアルベド（ある一画素における素材の色）、 $L \in \mathbb{R}^{3 \times 3}$  は単位光源ベクトル（光源の位置）、 $n \in \mathbb{R}^{3 \times 1}$  は法線ベクトル（ある一画素における表面の傾き）、添え字は光源の番号を示す。また、この時の光源ベクトル $L$ 及び法線ベクトル $n$ の詳細はEq. 2, 3のように表現する。

$$L_i = [L_{ix} \quad L_{iy} \quad L_{iz}] \quad (2)$$

$$n = \begin{bmatrix} n_x \\ n_y \\ n_z \end{bmatrix} \quad (3)$$

ここで、xyzは光源の軸を示す。

続いて、光源、対象物、カメラの位置関係、光源の位置を示す光源ベクトル $L$ の関係についてFig. 3を用いて説明する。光源ベクトル $L$ を  $(L_{ix},$

$L_{iy}, L_{iz})$ 、対象物を置く位置の原点を  $(0, 0, 0)$ 、また、カメラの位置を  $(0, 0, 1)$  と定める。




Fig. 3 Diagram of positional relationship with vectors.

### 2. 2. 2 法線ベクトルとアルベドの算出

続いて、法線ベクトル $n$ 及びアルベド $\rho$ の計算方法についてEq. 1を用いて説明する。

既知の光源ベクトル $L$ から照らした際の画像として、輝度 $I$ は得られる。よって、Eq. 1の未知の変数はアルベド $\rho$ 及び法線ベクトル $n$ のみとなる。法線ベクトル $n$ は光源ベクトル $L$ の逆行列から算出でき、残るアルベド $\rho$ は既知の変数を使って計算できる。このように、数値解析的にアルベド画像や法線ベクトル画像を得る手法を照度差ステレオと呼ぶ<sup>2)</sup>。

### 2. 2. 3 一般化した照度差ステレオ

ここまで、光源の位置が異なる3組の画像データを使った例を示した。光源ベクトルと画像のペアは多いほど計算誤差を減らすことができ、鏡面反射の影響も小さくできる。

そこで、照度差ステレオを一般化して、光源ベクトル及び画像の対が $i$ 個あった場合の式をEq. 4に示す。 $L \in \mathbb{R}^{i \times 3}$ であるから、光源数 $i$ が4以上の場合、 $L$ は非正方行列となる。非正方行列は解を持たないため、光源数が4以上となる場合にはEq. 4の方程式は解を持たない。

$$\begin{bmatrix} I_1 \\ \vdots \\ I_i \end{bmatrix} = \rho \left( \begin{bmatrix} L_1 \\ \vdots \\ L_i \end{bmatrix} \cdot n \right) \quad (4)$$

ここで、 $i$ は $i>3$ 満たす整数、 $I \in \mathbb{R}^{i \times 1}$ は輝度、 $\rho \in \mathbb{R}^{1 \times 1}$ はある一画素におけるアルベド、 $L \in \mathbb{R}^{i \times 3}$ は単位光源ベクトル、 $n \in \mathbb{R}^{3 \times 1}$ はある一画素における法線ベクトルを示す。

このような非正方行列の近似解を得る方法として、ムーア・ペンローズの疑似逆行列が知られている<sup>3)</sup>。具体的な方法をEq. 5に示す。

$$\hat{n} = (L^T L)^{-1} L^T I = L^\dagger I \quad (5)$$

ここで、 $\hat{n}$ はある一画素における法線ベクトル、 $n$ の擬似法線ベクトル、 $L^\dagger$ は光源ベクトル $L$ のムーア・ペンローズの疑似逆行列を示す。

ここまでである一画素における輝度 $I$ も光源ベクトル $L$ も既知であり、 $\hat{n}$ はEq. 5より得られる。従って、残る未知変数アルベド $\rho$ は、Eq. 1を詳細に示したEq. 6に、これまでに明らかになった変数を代入すれば得られる。

$$\begin{bmatrix} I_1 \\ \vdots \\ I_i \end{bmatrix} = \rho \left( \begin{bmatrix} L_{1x} & L_{1y} & L_{1z} \\ \vdots & \vdots & \vdots \\ L_{ix} & L_{iy} & L_{iz} \end{bmatrix} \cdot \begin{bmatrix} \hat{n}_x \\ \hat{n}_y \\ \hat{n}_z \end{bmatrix} \right) \quad (6)$$

### 2.2.4 照度差ステレオの拡張

ここまでの一連の式は、ある一画素における輝度 $I$ の計算例を示したが、この計算方法を縦横方向に任意画素数を持った画像に拡張することで、照度差ステレオの適用範囲を拡張できる。

また、同様に、ここまでの一連の式は、ある一画素におけるグレースケールの輝度 $I$ について説明したが、この計算方法をRGBの3チャンネルに拡張することで、照度差ステレオの適用範囲をカラー画像に拡張できる。

実際の計算処理は一連の計算を抽象化したまま扱えるPython及びPythonの数値計算ライブラリのNumPyを用いた。

## 2.3 異常検知手法の検討

画像に対する異常検知手法は様々あるが、ロバスト性の高い異常検知の実現には、深層学習を用いて画像データを $n$ 次元の空間に埋め込む手法が

主流であった<sup>4,5)</sup>。

しかし、 $n$ 次元における超球面のサポートベクターや空間密度を使った異常検知では、異常に対する説明性が低いほか、異常部位を図示することができなかった。また、表現力が足りず、異常の分解能が製造業の現場で求められる水準に及ばないという課題があった。

以下に画像における代表的な異常検知手法2例及び、今回用いたPatchCoreによる手法を示す。

### 2.3.1 Deep One-Class Classificationによる異常検知

Deep One-Class Classification (以降、DOCC)<sup>4)</sup>について、Fig. 4を用いて説明する。

DOCCにおいては、正常画像をラベル0、他の種類の画像は全てラベル1として学習させる。Fig. 4の例では、「2」をラベル0 (正常) として、「1」や「3」はラベル1 (異常) とする。学習の結果、出力層の直前の層では、限られた次元数に画像の特徴量が埋め込まれる。




Fig. 4 Diagram of Deep One-Class Classification.

このように、ニューラルネットワークをカーネルとし、超空間上の超球面を非線形のサポートベクターとするのが本手法の特徴である。そのため、この手法は、Deep SVDD (Deep Support Vector Data Description) とも呼ばれる。

しかし、この手法では、正常か異常かの判別しかできず、程度のスコア化ができない課題と、異常部位を図示できない課題があった。

### 2.3.2 Metric learningによる異常検知

続いて、クラス間の類似度の違いを距離の違いとして学習するメトリックラーニングについて説

明する。メトリックラーニングの基本となる手法はFaceNet<sup>5)</sup>である。Fig. 5を用いてFaceNetの概略を説明する。

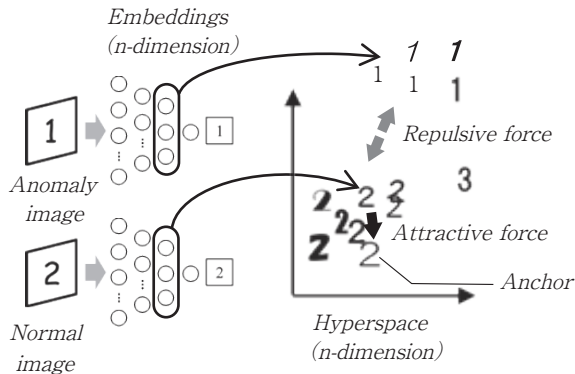


Fig. 5 Diagram of FaceNet.

FaceNetの特徴的な点は、画像を学習させる際にペアとなる異なるクラスの画像 (Fig. 5では「1」と「2」) も併せて学習するサイアミーズネットワーク構造を持つ点と、2つの異なるクラスの画像 (Fig. 5では「1」と「2」) を超空間上で距離を置くように、同じクラスの画像 (Fig. 5では「2」同士) は極力近づくように学習させるトリプレットロスという損失関数 (学習時の指標) にある。

このふたつの働きにより、FaceNetにおける超空間上では似たもの同士が集まり、異なるものは遠くへ排斥するように振舞う。

従って、あるクラスの写像の周囲に、どれだけ同じクラスの写像が集まっているかを評価できれば、データの密集度を使った異常検知ができる。この空間密度を使った異常検知手法は局所外れ値因子法 (LOF) と呼ばれている<sup>6)</sup>。

超空間における最寄り2点を基準としたLOFの模式図をFig. 6に示す。LOFの働きについて説明する。ここでは、「2」を基準とし、「3」を未知の異常とする。埋め込まれた「2」の写像群は、超空間上で密集することから、ある「2」に対する写像の最寄り2点の密集度も高くなる。一方、「3」の写像は離れた位置にあり、最寄り2点の密度は低くなる。このように、LOFでは超空間における空間密度の粗密を基軸に異常を捉えることができる。




Fig. 6 Diagram of Local Outlier Factor (LOF).

実際の鋳物にFaceNetを適用した結果の一例をFig. 7に示す。Fig. 7aに示す良品ではスコアが1.14だったが、異常であるFig. 7bではスコアが1.83と異常度をスコアの違いとして検出できた。一方、偽陰性であるFig. 7cはスコアが1.12であり、良品のスコアとの有意差が見られなかった。

これは、埋め込みによって異常を示す特徴量が欠落したか、異常を示す特徴量が多次元空間に埋め込まれたために生じたと考えられる。この仮説の下、埋め込み次元数を増減させたが、有効な解決策とはならなかった。

また、FaceNet以降に発展型として発表されたArcFace<sup>7)</sup>などの手法も検証したが、結果に大きな変化は見られなかった。




Fig. 7 Evaluation examples of FaceNet.

### 2.3.3 PatchCoreによる異常検知

ここまで挙げてきた、DOCCやメトリックラーニングに基づく手法では、判定アルゴリズムとして産業用に用いるには異常検知能力が不足していた。また、得られる結果がスコアのみで評価の根拠の図示ができず説明性に欠けていた。

そこで、異常検知タスクの最新手法であり、ヒートマップによる根拠の図示も可能で再学習も不要なPatchCoreを検討した<sup>8)</sup>。

PatchCoreとは、学習済みのニューラルネットワークから特徴量を要約し、要約した特徴量に基



づき異常検知を行う手法である。

PatchCoreでは学習を行わない代わりに、メモリバンク生成を行い、異常検知はメモリバンクのパッチとの最近傍距離を元に行う。

まず、PatchCoreにおけるメモリバンク生成について、Fig. 8 を使って説明する。

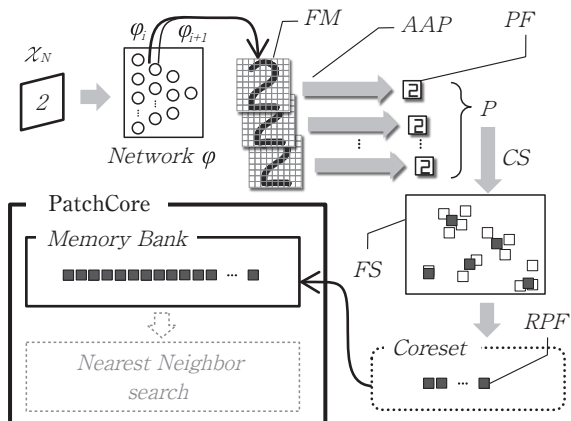


Fig. 8 Diagram of PatchCore while Training.

説明に使うデータは、データセット  $\chi$  に含まれる「2」という見本画像  $\chi_N$  を例として用いる。

PatchCoreでは、一般に公開されている汎用画像データセットを用いて、事前学習が済んだ画像認識ネットワーク  $\phi$  を特徴量抽出器として用いる。なお、ネットワーク  $\phi$  には事前学習によって初めから入力画像の特徴を抽出できる優れたフィルタ (特徴量抽出器) が備わっている。そのため、未学習の画像を入力したとしても、ネットワーク  $\phi$  の中間層  $\phi_i$  から入力画像に応じた特徴量  $FM$  をうまく抽出することができる。

良品イメージ  $\chi_N$  をネットワーク  $\phi$  に入力すると、中間層  $\phi_i$ 、 $\phi_{i+1}$  の持つ多数のフィルタによって、良品イメージ  $\chi_N$  の局所的な特徴に応じた一連の特徴量  $FM$  を得る。

先述の通り、ネットワーク  $\phi$  には膨大な数のフィルタが備わっているため、得られる特徴量  $FM$  も膨大な数に及ぶ。しかし、特徴量  $FM$  は適応的平均プーリングAAPによって集約され、パッチ特徴量  $PF$  (Fig. 8 中に□として記載) として要約される。こうして要約された特徴量をまとめてパッチ特徴量コレクション  $P$  とする。

続いて、コレクション  $P$  の特徴量空間  $FS$  におけるカバレッジについて考える。コレクション  $P$  を特徴量空間  $FS$  にプロットすると、特徴量空間  $FS$  においてパッチ特徴量  $PF$  (□) は一定領域に凝集する傾向がある (Fig. 8 右)。従って、コアセットサブサンプリング  $CS$  によって情報を削減したパッチ特徴量  $RPF$  (Fig. 8 中に■として記載) を代表値として抽出できれば、全てのパッチ特徴量  $PF$  (□) を保持する必要がなくなる。結果として、計算を高速化できるほか、ロバスト性を改善できる。

コアセットサブサンプリング  $CS$  はランダムに代表値をサンプリングする場合に比べて、より少ないパッチ特徴量  $RPF$  (■) でコレクション  $P$  の母集団を表現できる。このようにして得られたパッチ特徴量  $RPF$  (■) は、コアセットとしてメモリバンクに格納される。

続いて、メモリバンクを使った任意画像の評価について Fig. 9 を用いて説明する。PatchCore における評価は、見本画像  $\chi_N$  から得られメモリバンクに格納されているコアセットと、評価対象の画像  $\chi_T$  から得られた一連の特徴量のコレクション  $P$  とが、特徴量空間  $FS$  において、どの程度類似しているかの比較によって行われる。

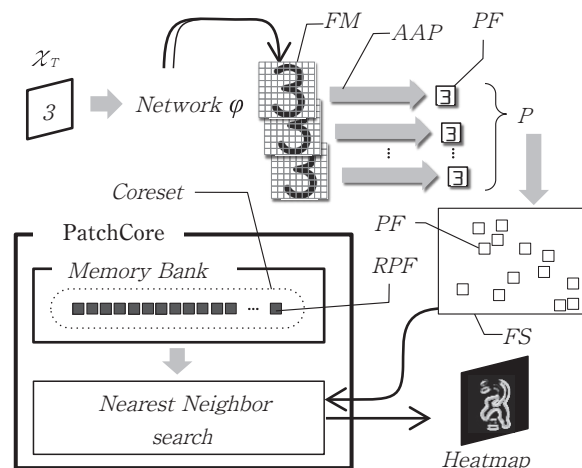


Fig. 9 Diagram of PatchCore while Testing.

ここでは画像の評価データセット  $\chi$  に含まれる「3」という異常画像を試験画像  $\chi_T$  とした PatchCore による推論を説明する。

評価時においても、まず対象画像のコレクショ

ン $P$ を生成する。そして、メモリバンクとコレクション $P$ を元に、近傍検索を用いた異常検知を行う。メモリバンク生成時には「2」を選定していたため、コアセットには「2」の特徴が集約されているが、評価時は一例として「3」を選定したため、コレクション $P$ には「3」の特徴が集約されている。それぞれのパッチ特徴量 $PF$ に対して、メモリバンクとの最近傍距離を計算し、異常スコアを算出することで、ピクセル単位での異常度をヒートマップとして計算できる。

具体的には、「2」を見本画像 $\chi_N$ とした際に、異常画像 $\chi_T$ である「3」を評価すると、「2」と比べた時の欠損部位や余剰部位が異常スコアの高い部分としてヒートマップの形で抽出される。

### 3. 実験方法

実際の鋳物に対して照度差ステレオ及びPatchCoreを適用する方法について説明する。

まず良品10点に対し、照度差ステレオを用いてワーク上面を撮像し、アルベド画像 $\rho$ と法線ベクトル $\hat{n}$ の両画像を得る。続いてPatchCoreを用いて、アルベド画像 $\rho$ を基準画像 $\chi_{N(AL)}$ としたコアセットと、法線ベクトル $\hat{n}$ を基準画像 $\chi_{N(NV)}$ としたコアセットを生成する。

続いて、任意の対象ワークを装置内へ設置し、撮像後にPatchCoreによる異常検知を行う。実際に行った試験条件をTable 1に示す。

異常の分解能を探るため、条件aは約150 [mm]四方を撮像し、条件bでは約30 [mm]四方を撮像して試験を行った。

Table 1 Data table of experimental condition.

Index	
Target item	Impeller blades (In-house products) W:112 × D:76 × H:33 [mm] Approx. 300 [mm] square
Imaging area	Approx. 200 [mm] square
	Approx. 50 [mm] square
	Approx. 30 [mm] square
Computer	Jetson AGX Xavier (NVIDIA)
Light source	LED light source 10 units

### 4. 実験結果

結果の一例をFig. 10a、10bに、凡例をFig. 10c

に示す。一回の処理につき、撮像に3.5 [s]、照度差ステレオ処理に0.7 [s]、PatchCoreによる異常検知に2.6 [s] かった。

約150 [mm] 四方に注目し直径5 [mm] の異物を置いた場合 (Fig. 10a)、アルベド画像の異常ヒートマップと法線ベクトル画像の異常ヒートマップの両方が反応した。




Fig. 10a Example (whole) with anomaly (5 [mm]).




Fig. 10b Example (closeup) with anomaly (1 [mm]).




Fig. 10c Explanatory image.

しかし、約30 [mm] 四方に注目し直径1 [mm] の異物を置いた場合 (Fig. 10b)、法線ベクトル画像の異常ヒートマップに反応が出ているが、アルベド画像の異常ヒートマップには明確な反応が現れなかった。これらの試験から得られた視野の範囲と最小分解能のグラフをFig. 11に示す。




Fig. 11 Resolution of anomaly detection in PatchCore.

## 5. 考察

アルベド画像だけでなく法線ベクトル画像に対しても異常検知を行うことで、異常の見逃しを少なくできることが分かった。提案した方法の検出限界は撮像範囲と連動する。そのため、広い視野で小さい異常を検知するためには、画像領域を分割し、それぞれに対し異常検知を行う必要があり、処理時間がかかることが予想される。

## 6. 結言

照度差ステレオにより生成したアルベド画像と法線ベクトル画像を使った異常検知が、製造上の揺らぎが生じやすい鋳物の外観検査の自動化に有効であることを示した。処理の高速化や異常の最小分解能の改善が今後の課題である。

## 参考文献

- 1) Lambert Johann Heinrich: Photometria, sive de mensura et gradibus luminis, colorum et umbrae (Augsburg: Eberhard Klett) (1760)
- 2) Robert J. Woodham: Photometric method for determining surface orientation from multiple images. 19, (Optical Engineering) (1980) 139-144
- 3) Adi Ben-Israel, Thomas N.E. Greville: Generalized Inverses Theory and Applications Second Edition (Springer New York) (2003) 7
- 4) Lukas Ruff, Robert A. Vandermeulen, Nico Gaörnitz, Lucas Deecke, Shoaib A. Siddiqui, Alexander Binder, Emmanuel Müller, Marius Kloft: Deep One-Class Classification,

International Conference on Machine Learning, PMLR 80 (2018) 4393-4402

- 5) Florian Schroff, Dmitry Kalenichenko, James Philbin: FaceNet: A unified embedding for face recognition and clustering, The IEEE Conference on Computer Vision and Pattern Recognition CVPR (2015) 815-823
- 6) Markus M. Breunig, Hans-Peter Kriegel, Raymond T. Ng, Jörg Sander: LOF: Identifying Density-Based Local Outliers, Proceeding ACM SIGMOD 2000 Int. Conference, Dalles, TX, (2000)
- 7) Jiankang Deng, Jia Guo, Niannan Xue, Stefanos Zafeiriou: ArcFace: Additive Angular Margin Loss for Deep Face Recognition., (arXiv) (2018)
- 8) Karsten Roth, Latha Pemula, Joaquin Zepeda, Bernhard Schölkopf, Thomas Brox, and Peter Gehler: Towards Total Recall in Industrial Anomaly Detection., (arXiv) (2021)