

VAE を用いたハニカム構造パターン画像における 異常検出技術の開発

Development of Variational Auto-Encoder based Anomaly Detection Technique for Pattern Images of Honeycomb Structure

大 島 誉 寿	技術開発本部技術基盤センター検査・計測グループ
鈴 木 一 将	技術開発本部技術基盤センター検査・計測グループ
前 田 宗 彦	技術開発本部技術基盤センターセンシング・エレクトロニクス開発グループ
今 井 清 濟	株式会社 IHI エアロスペース 品質保証部ロケット品質保証グループ
木 村 憲 志	株式会社 IHI エアロスペース 品質保証部品質保証技術グループ

ハニカムサンドイッチパネルで欠陥となる接着面剥離は、非破壊検査による構造物内部の可視化により検出できる。しかしながら不明瞭な可視化画像では、画像処理のようなルールベースの手法による自動検出は困難であった。そこで深層学習の一つである Variational Auto-Encoder (VAE) によって、学習データに正常な製品の画像しか用意できない場合でも異常検出モデルを生成し、検査を自動化できる見込みを得た。また、独自の損失関数を定義した学習とすることで、より高精度な検出モデルを構築した。


Debonding defects in honeycomb sandwich panels can be detected by visualizing the inside of the structure by nondestructive inspections. However, automatic detection by rule-based methods such as image processing is difficult for an unclear visualization image. Therefore, using the Variational Auto-Encoder, which is one of the deep learning techniques, even if only good product images can be used as training data, an anomaly detection model was generated and the possibility that the inspection could be automated was obtained. In addition, further high-precision detection model was realized by definition of its own loss function in the training phase.

1. 緒 言


軽量化を目的として航空機部品に多用されるハニカムサンドイッチパネルは、主に複合材を使用した表面板とアルミニウムなどの箔材を使用した中空柱状のハニカムコア間を接着した構成となっている。外部からの損傷や製造時の不良により表面板-ハニカムコア間の接着面が剥離すると構造部材の強度・剛性の低下を招くため、接着面剥離を検出する非破壊検査手法が用意されている。代表的な検査手法の一つとして超音波探傷試験があり、材料表面に配置した超音波プローブから超音波を発信し、材料内部の欠陥から反射してきた超音波を受信して、その強度や到達時間から欠陥の情報を調べるパルスエコー法が一般的に用いられている。ハニカムサンドイッチパネルの検査は、表面板とハニカムコア接着界面でのハニカムコアの有無による超音波反射強度の変化を利用した検査を可能としている。また近年、多数の超音波センサを一つのプローブに搭載したアレイ型プローブを用いたフェーズドアレイ法⁽¹⁾やトータ

ルフォーカシングメソッド (TFM)⁽²⁾ という信号処理技術との組合せにより、構造内部の任意の箇所に焦点を設定して画像化できることも特徴である。身近な例では病院での胎児のエコー検査がある。第1図にハニカムサンドイッチパネルの超音波探傷試験の例を示す。

第2図に接着面を超音波探傷試験で画像化した例を示



第1図 ハニカムサンドイッチパネルの超音波探傷試験例
Fig. 1 Example of ultrasonic testing schematic example of honeycomb sandwich panel



第2図 ハニカムサンドイッチパネルの超音波画像と欠陥
Fig. 2 Ultrasonic echo image of honeycomb sandwich panel and its defects

す。接着面の剥離は人工的に挿入されたものである。白く表示されている箇所ほど超音波の受信強度が強いことを示しており、接着が良好な場合、接着を介してハニカムコアに超音波が伝搬し、その部分だけ受信強度が低下し黒く映る。接着面が良好な場合、ハニカムの規則的な配列パターンが反映され、白い斑点が互いに分離して同じく規則的に並ぶように可視化される。しかし、接着面剥離の欠陥箇所があるとパターンが乱れて隣り合う白い斑点同士がつぶれるように観察される。検査員はこの画像を目視して剥離を検出するが、構造部材の用途の特性上、検査範囲が大面積に及ぶことが多く、多大な検査時間を要するため検査の自動化の要望が高い。ただし、第1図における超音波アレイプローブと検査対象との接触状態および構造材内部の状態に画像の性状が左右されやすいため、画像処理で一般的なアプローチであるフィルタ処理や形状検出といったルールベースでは定義が難しく対応しにくい。また一般に、不良品の数は良品に比べて非常に少なく検出対象のデータが十分に集まらないことも課題である。

本稿では、近年、人間に近い柔軟さで目的タスクを解決でき、製造業の現場でも適用が期待されている深層学習を活用し、ハニカムパターン画像上の欠陥検出を可能にする異常検出モデルを構築した結果を紹介する。具体的には Variational Auto-Encoder と呼ばれる不良品データが不要の教師なし学習方式でハニカムパターン画像の再構成を実施し、その過程で生じる変化を欠陥として検出した。また、従来の学習方式に対し、本タスク向けに新たな損失関数の定義を提案し、検出モデルの高精度化を図る。

2. 深層学習による異常検出

2.1 教師あり学習方式と教師なし学習方式


欠陥データが定義可能な場合、本検討における教師あり学習方式として物体検出 (Object Detection) のアプローチを選択できる。代表的な物体検出手法としては

R-CNN⁽³⁾、SSD⁽⁴⁾、YOLO⁽⁵⁾などが挙げられる。第3図に R-CNN を使用したときの欠陥検出の出力例を示す。ただし学習には、画像編集により生成したダミーの欠陥画像 100 枚を使用している。物体検出は、物体の位置 (バウンディングボックス)、物体の分類クラス (第3図では分類は欠陥のみなのでクラス数 1)、物体がそのクラスと分類された確信度 (0.0 ~ 1.0) を同時に出力するマルチタスクである。このように高精度に欠陥を直接検出できるメリットがある一方で、製品の製造傾向が変わった場合には欠陥の定義変更に対応できず、再び学習データを収集しなければならないデメリットがある。

教師なし学習方式は、入力データから規則性を抽出するため一般的にクラスタリング用途で使用されることが多く、代表的な手法に k-means 法や自己組織化マップがある。良品データのみを取り扱うことで、学習モデルに正常データの範囲を学習させられるので想定外の欠陥にも対応しやすいメリットがある。ただし、学習させるデータに多様性がないと正常データ範囲が狭くなり誤検知が増えるデメリットがあるので注意が必要である。本検討では画像を取り扱うことから Auto-Encoder (自己符号化器)⁽⁶⁾ や AnoGAN (Anomaly Detection with Generative Adversarial Networks)⁽⁷⁾ に代表される画像生成が可能なアプローチを選択し、良品データの収集数による学習可否を考慮して Auto-Encoder 系を採用した。

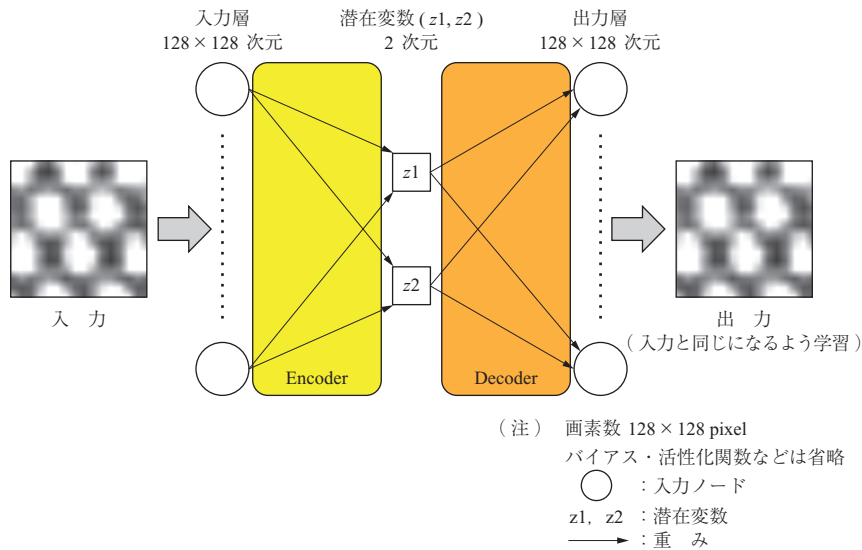
2.2 Auto-Encoder による異常検出

Auto-Encoder は異常検出に特化した手法ではなく、元来は多層化するニューラルネットワークの課題であった勾配消失問題への対応策としてパラメータ初期値学習方法で使用され⁽⁶⁾、昨今の第3次人工知能ブームの初期の礎となった技術の一つである。現在は次元圧縮や生成モデルとしての用途が主である。第4図に簡単な3層構造の Auto-Encoder のネットワークモデルを示す。特徴は以下の3点である。



(注) □: 物体の位置 (バウンディングボックス)

第3図 物体検出手法による出力例 (R-CNN)
Fig. 3 Output example with object detection method (R-CNN)



第4図 3層の Auto-Encoder ネットワークモデルの一例
 Fig. 4 Example of Auto-Encoder network model with 3 layers

- ① 入力が出力と同じになるようにモデルを学習させる
- ② Encoder と Decoder と呼ばれる対称な層を配置する
- ③ 中間層では潜在変数と呼ばれる入力よりも次元圧縮された表現が得られる Encoder が次元圧縮を行い、Decoder が新たな画像の生成モデルとして機能する

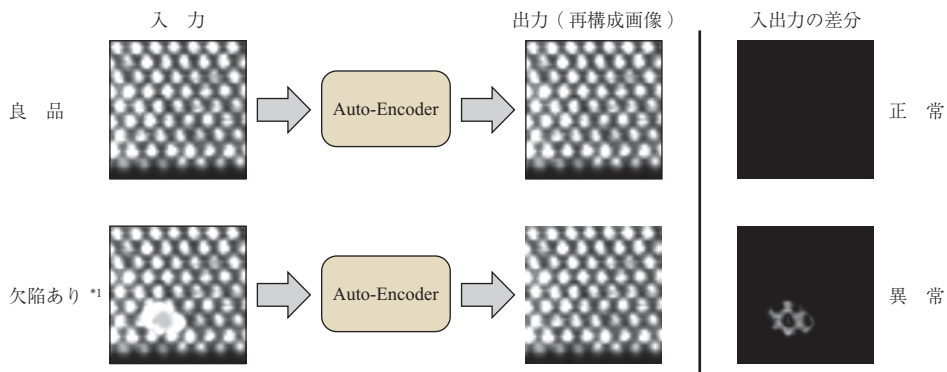
第5図に Auto-Encoder を利用した異常検出方法を示す。学習に良品画像のみを使用することで Encoder は良品の特徴を潜在変数として抽出し、Decoder は潜在変数から良品画像を復元しようとする機能を獲得する。よって学習後のモデルに不良品画像を入力として与えると、最終的に良品画像に変換したような出力が得られる。このとき入出力の差分をとると欠陥箇所が強調された画像が得られるため、任意の後処理と組み合わせることで異常検出が実施できる。

2.3 VAE 概要

VAE は変分ベイズ推定法の一つであるため、理論的背景は Auto-Encoder とは異なるものの、異常検出における実施形態は Auto-Encoder と同様となるため、概要のみを紹介する。第6図に VAE のネットワークモデルを示す。Auto-Encoder と比較して、潜在変数の表現に確率分布を用いていることが大きな特徴である。入力から潜在変数へ直接変換するのではなく、潜在変数はある確率分布からサンプリングされると仮定し、その平均と分散を Encoder で求める。ただし潜在変数のサンプリングに関してはモデル学習時の誤差逆伝搬が実施不可能になってしまうので、実際には(1)式のような近似式を使用する (Reparameterization Trick⁽⁸⁾)。

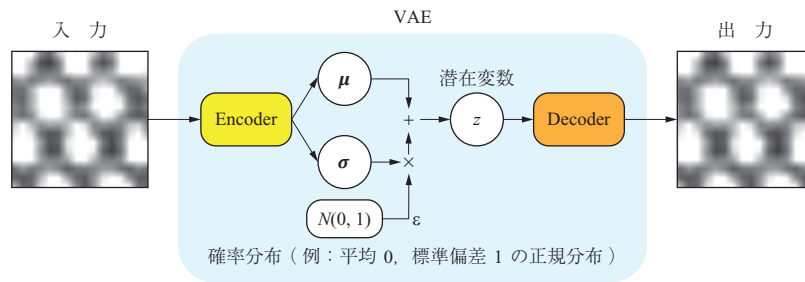
$$z = \mu + \epsilon\sigma^2 \dots\dots\dots (1)$$

$$\mu : \text{平均}$$



(注) *1: 欠陥は学習させていないので復元されない。

第5図 Auto-Encoder による異常検出の仕組み
 Fig. 5 Anomaly detection mechanism by Auto-Encoder



第 6 図 VAE のネットワークモデル
Fig. 6 VAE network model

σ : 標準偏差

ε : 平均 0, 標準偏差 1 の正規分布からのサンプリング

Auto-Encoder では決定論的に入力画像をある潜在変数に変換しており, 潜在変数がつくるデータ空間の構造の把握は困難である. 一方, VAE は潜在変数を確率分布という構造に制限しているので確率分布上で距離が近い潜在変数同士は似た特徴量をもち, Decoder を通すと似た画像を生成できることになる. そのため VAE は連続的に変化する画像を生成しやすい特徴がある. 3 章では実際に VAE モデルを構築し, ハニカムパターン画像に適用した場合の結果について報告する.


3. 実験結果

3.1 学習データ

第 7 図に学習に使用した良品のハニカムパターン画像の例を示す. 総数 1 200 枚で, 画素数は一律 128 × 128 pixel のグレースケール画像である. これらは, ある程度大きさのあるハニカムサンドイッチパネルの超音波可視化画像を分割し, 指定サイズにアップサンプリングしたものである. 細かく分割すると, 大きな欠陥箇所を評価する場合に白つぶれのための画像を入力することになってしまうため, 学習データ枚数の確保を考慮し, 1 画像中に 7, 8 個程度のハニカムが映るようなスケールに調整した.

3.2 構築モデルと学習

実装にあたりフレームワークには, オープンソースの深



(注) 画素数: 128 × 128 pixel

第 7 図 使用した学習用データセットの例
Fig. 7 Examples of learning dataset

層学習のライブラリ化である Keras⁽⁹⁾を使用した. 構築した VAE ネットワークモデルの構造を第 8 図に示す. 比較的単純な画像が対象であることから, Encoder と Decoder は共に畳込み層, 全結合層を 2, 3 層積み重ねた構成にとどめた. 畳込み層のカーネルサイズは一律 7 × 7 pixel である. 潜在変数は 32 次元のベクトルであり, 確率分布は正規分布とした. 学習時のバッチ数は 32 枚, エポック数は 30 である. 損失関数は VAE に広く使用されている (2) 式を用いた.

$$L_{total} = L_{recon} + L_{KL} \quad \dots\dots\dots (2)$$

$$L_{recon} = \sum \{-p \log q - (1-p) \log(1-q)\} \quad \dots (3)$$

$$L_{KL} = \frac{1}{2} \sum (-2\sigma + \mu^2 + \sigma^2 - 1) \quad \dots\dots\dots (4)$$

L_{total} : 損失関数

L_{recon} : 画素間のクロスエントロピーによる再構成ロス (モデル全体の入力と出力の画像の差)

L_{KL} : カルバック・ライブラー距離 (潜在変数の確率分布と正規分布 (平均 0, 標準偏差 1) の一致度合いを表す尺度), 最適化アルゴリズムは RMSProp⁽¹⁰⁾ を使用

p : 入力画像の画素値

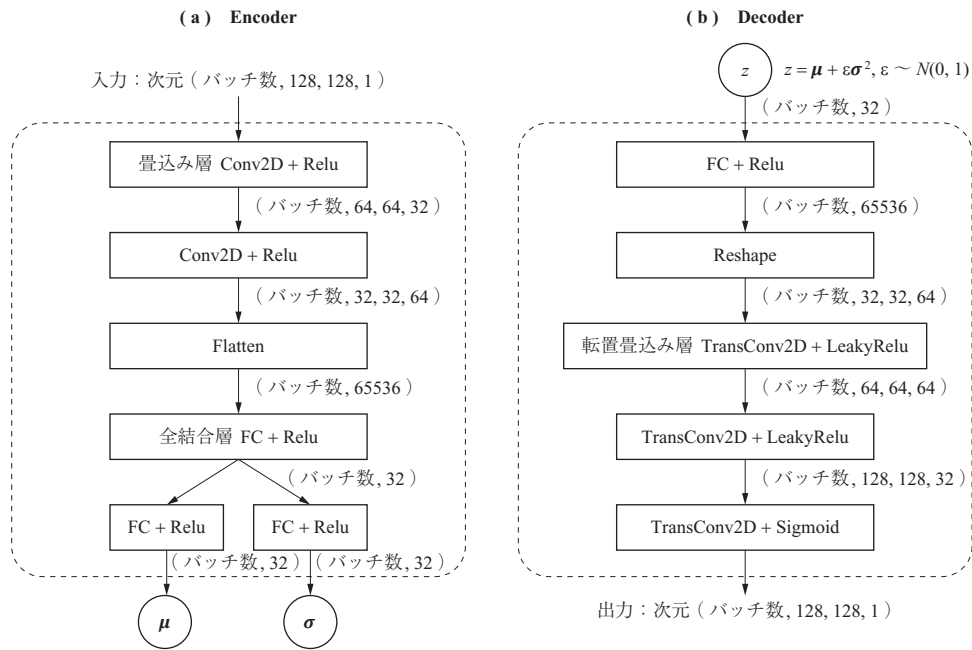
q : 出力画像の画素値

μ : 潜在変数をサンプリングする確率分布の平均ベクトル

σ : 潜在変数をサンプリングする確率分布の標準偏差ベクトル

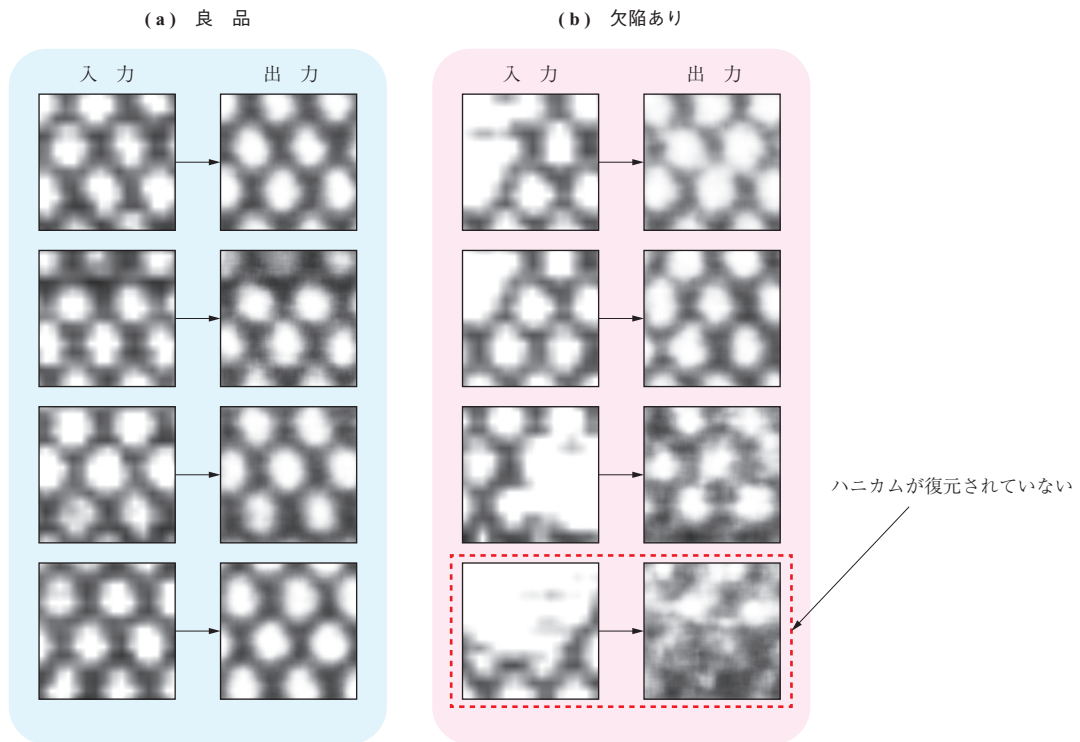
3.3 推論結果

学習データと同形式の評価用データセットを推論した結果を第 9 図に示す. 欠陥はハニカムサンドイッチパネル内に人工的に導入されたものである. 良品画像ではパターンの並び方, ハニカムの個数・大きさがモデルの出力であ



(注) μ : 平均
 σ : 標準偏差
 z : 潜在変数

第 8 図 構築した VAE ネットワークモデルの構造
 Fig. 8 Architecture of constructed VAE network model



第 9 図 推論結果
 Fig. 9 Inference results

る再構成画像でも入力に近い形で再現されていることが分かる。一方で欠陥を含む画像を入力した場合はモデルが欠陥の特徴表現をもっていないことから、再構成画像では欠陥が取り除かれ正常なハニカムパターンのみが残ってい

る。これはモデル入出力の差分をとるとき、欠陥のみを強調した画像を得るうえで有利に働く。

しかしながら欠陥を含む画像の中にも、再構成した際に欠陥像の消去だけでなく、元のハニカムパターンの特徴が

失われてしまう例が観察された（第9図 - (b) の下部）。この改善方法を4章において提案する。

4. 形状特徴量による VAE の改良

従来の Auto-Encoder, VAE では学習時の損失関数の項の一つに復元誤差を表す尺度として入出力画素間のクロスエントロピーが使用されていた（(2)式における第1項）。そこで、元のハニカムパターンの消失や元の画像にないパターンの出現を抑制するよう、入出力画像の各画素自体の値だけでなく隣接画素間における勾配も評価し、損失関数に新たに形状特徴量として追加した（(5)式）⁽¹¹⁾。形状特徴量の項を(6)式に示す。

$$L_{total} = L_{recon} + L_{KL} + L_{shape} \quad \dots\dots\dots (5)$$

$$L_{shape} = \frac{1}{2} \sum \left\{ L_H \left(\frac{\partial p}{\partial x}, \frac{\partial q}{\partial x} \right) + L_H \left(\frac{\partial p}{\partial y}, \frac{\partial q}{\partial y} \right) \right\}$$

$$L_H(s, t) = -s \log t - (1-s) \log(1-t) \quad \dots\dots\dots (6)$$

- L_{shape} : 形状特徴量
- x : 画像の横方向ピクセル位置
- y : 画像の縦方向ピクセル位置

損失関数に形状特徴量を追加した再学習後の推論結果を第10図に示す。通常の VAE では入力画像中の欠陥があ

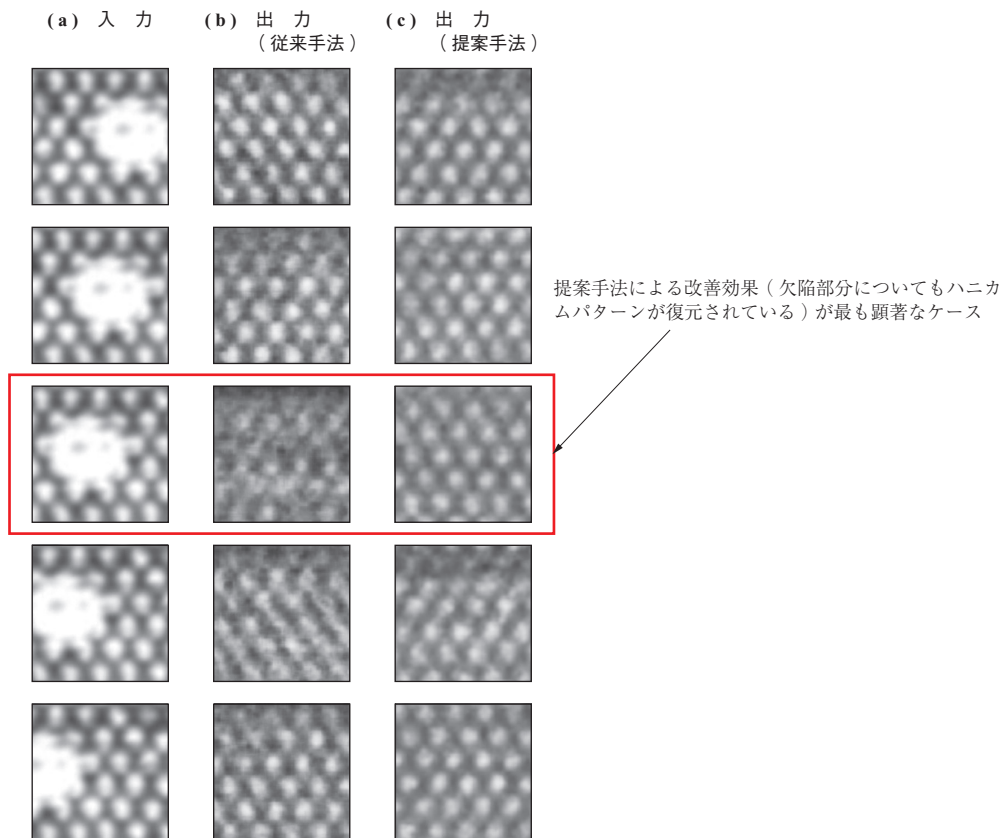
る箇所について再構成画像上ではハニカムパターンの形状が崩れているのに対し、提案手法ではハニカムパターンの特徴を維持可能なことが確認できる。したがって入出力の差分を用いた異常検知において、欠陥に対してより正確な抽出が可能となり検知性能の向上が期待できる。

5. 結 言

ハニカムサンドイッチパネル内部の超音波可視化画像における接着面剥離の自動検出を目的とし、Variational Auto-Encoder を用いた良品学習モデルを構築した。学習後にモデル入出力の差分をとることで剥離欠陥像が抽出できることを確認した。さらに形状特徴量なる新たな評価項を損失関数に追加し学習した結果、検出に使用する再構成画像の品質向上につながり、検知性能向上の見込みを得た。今後は欠陥の大きさや程度の定量評価ができるような後処理手法の開発を行い、製造現場における適用を目指す。

参 考 文 献

- (1) 大島誉寿, 永井祐気, 鳩 昌洋, 畠中宏明, 田上稔, 横山 慎, 浅野 徹, 福島憲明, 武田祐司: ステンレス鋼継手の検査技術の高精度化, IHI インフ



第10図 欠陥を入力した際の、提案手法によるハニカムパターン再構成の改善
 Fig. 10 Improvement of honeycomb pattern reconstruction by the proposed method with defects image input

- ラ技報, Vol. 5, 2016
- (2) 大島誉寿, 川崎 拓, 島中宏明: FMC/TFM における溶接きず評価方法の検討, 日本非破壊検査協会, 平成 29 年度秋季講演大会 講演概要集, 2017 年 10 月, pp. 27 - 28
 - (3) S. Ren, K. He, R. Girshick and J. Sun: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, Advances in Neural Information Processing Systems, Vol. 28, 2015
 - (4) W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Y. Fu and A. C. Berg: SSD: Single Shot MultiBox Detector, arXiv:1512.02325, 2016
 - (5) J. Redmon, S. Divvala, R. Girshick and A. Farhadi: You Only Look Once: Unified, Real-Time Object Detection, arXiv:1506.02640, 2016
 - (6) G. E. Hinton and R. R. Salakhutdinov: Reducing the Dimensionality of Data with Neural Networks, Science, Vol. 313, Iss. 5 786, 2006. 7, pp. 504 - 507
 - (7) T. Schlegl, P. Seeböck, S. M. Waldstein, U. S. Erfurth and G. Langs: Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery, arXiv:1703.05921, 2017. 3
 - (8) D. P. Kingma and M. Welling: Auto-Encoding Variational Bayes, arXiv:1312.6114, 2013. 12
 - (9) Keras Documentation: Keras:Python の深層学習ライブラリ, <https://keras.io/ja/>, (参照 2019. 12. 5)
 - (10) S. Ruder: An overview of gradient descent optimization algorithms, arXiv:1609.04747, 2016. 9
 - (11) 佐藤 玄, 前田宗彦, 鈴木一将, 内田雄太, 大島誉寿, 米倉一男: 形状特徴項を用いた VAE の復元性能の向上, 情報論的学習理論と機械学習研究会, 第 21 回情報論的学習理論ワークショップ, D1-36, 2018 年 11 月