

画像生成 AI を活用した 外観検査 AI システム開発の高速化

Accelerating the Development of Visual Inspection AI System Using Image Generation AI

吉田 舜*
Shun Yoshida

石田 翔也
Shoya Ishida

三浦 勝司
Katsushi Miura

当社では従来、不良品の検査を人による目視で実施していたが、人手が相応に必要なうえ、担当者によって検査基準にばらつきが生じやすかった。そこで外観検査 AI システムを開発し、不良品の検査の自動化を進めているが、同システムの教師データとして利用する不良品の画像がなかなか集まらず検出精度が上がらないことが課題であった。そこで、少量の不良品画像から多量の疑似的な不良品画像を生成できる画像生成 AI を導入し、さらに、同システムが誤判定しやすい画像、すなわち、弱点を分析・特定する仕組みもあわせて開発することで、その弱点を克服する画像を生成し、弱点を集中的に訓練するループ（弱点トレーニング・ループ）を繰り返し回すことができるようにした。これにより、不良品画像が十分収集できていない状況でも、外観検査 AI システムの開発期間を大幅に短縮しつつ検出精度を向上することができたので報告する。

Our company has traditionally relied on manual visual inspections for defect detection, which required considerable manpower and often led to inconsistencies in inspection standards depending on individual inspectors. To address these issues, we developed an AI-based visual inspection system to automate defect detection. However, a key challenge was the limited availability of defective product images for training, which impeded the enhancement of detection accuracy. To resolve this, we introduced an image generation AI capable of producing a large number of synthetic defect images from a small number of real defective samples. Furthermore, we developed a complementary method to analyze and identify the types of images that the inspection AI system is prone to misclassifying, thereby pinpointing its weaknesses. By generating targeted images to address these weaknesses and iteratively training the inspection AI system in a focused manner—a process we term the “anti-weakness training loop”—we were able to significantly improve system performance. Consequently, even with limited real defect data, we shortened the development time and enhanced the detection accuracy of the visual inspection AI system. This paper reports on the development and results of this approach.

キーワード：画像認識、外観検査、画像検査、ディープラーニング、画像生成 AI

1. 緒 言

当社では画像認識 AI を用いて、外観検査や製品開発における画像データの官能的な良否判定や定量評価の作業の自動化を行える外観検査 AI システムの開発を進めており、多くの工程にて運用が進んでいる。本システムにはディープラーニング^{*1}を用いているが、運用に耐える高い性能を得るには、一般に良品と不良それぞれで数千枚以上の多量の教師データが必要となる⁽¹⁾。しかし、製造現場では不良の発生率は低く、本システムの訓練に必要な不良画像の収集に数か月から数年という長い期間を要するケースが多い。このため、外観検査 AI システムの開発が長期化する課題を抱えていた。

そこで我々は、近年注目の高い画像生成 AI 技術に着目した。画像生成 AI はその名のとおりに画像を生成できる技術であり、実際の画像（実画像と呼ぶ）とよく似た画像（疑似画像と呼ぶ）を生成することができる。また、高度な画像生成 AI では図 1^{(2),(3)} のように生成する画像の見た目を制御することが可能であり、画像上に映る不良の位置や大きさ、色などを自由に変更することが可能である。この画像生成 AI を活用することで、外観検査 AI システムが誤判定

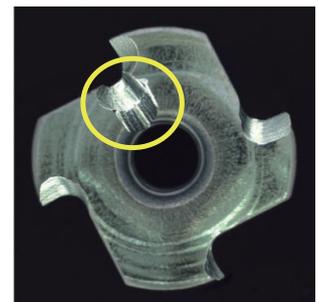
しやすい画像の見た目、すなわちシステムの弱点を特定することができる。さらに、製造現場で収集したごく少量の実画像から、本システムの弱点を克服するのに効果的な多量の教師データを集中的に生成できるため、高速な外観検査 AI システムの開発が可能となる。

実画像



疑似画像

○部に欠けを生じさせた



データグリッド社 [Anomaly Generator] により生成

図 1 実際の画像と画像生成 AI で生成した画像

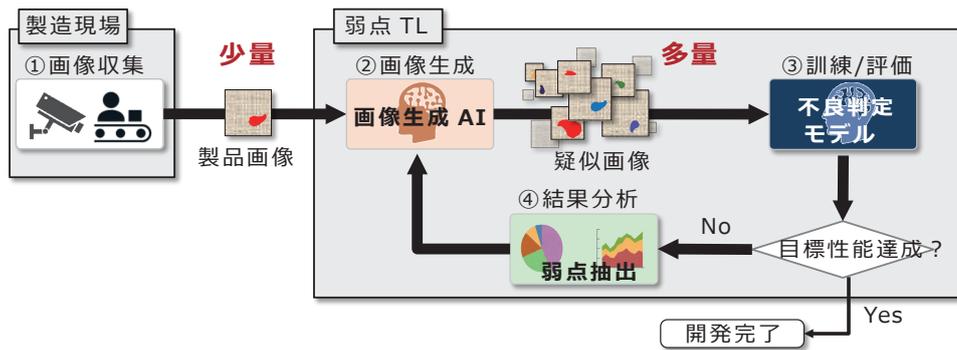


図2 弱点トレーニング・ループの概要

本稿では2章で弱点トレーニング・ループ技術の概要とその構成要素、3章で本技術を適用した結果を報告する。

2. 弱点トレーニング・ループ技術の概要

図2に外観検査システム用の不良判定モデルを訓練する仕組みを示す。大きく4つのステップから成り、

- ステップ①：実画像の収集
- ステップ②：疑似不良画像の生成
- ステップ③：不良判定モデルの訓練と評価
- ステップ④：誤判定結果の分析

(その後ステップ②に戻る)。

②に戻った後は、④で判定がうまくいかない弱点の疑似画像を多量に生成し、再度不良判定モデルの訓練を行う。本稿では、このように不良判定モデルの弱点を繰り返し発見し学習させる過程を人の「訓練」に見たて、弱点トレーニング・ループ (弱点 TL) と呼ぶ。なお、本技術の開発は少量の画像から多量の疑似画像を生成する技術に強みを有し、不良品画像生成AI「Anomaly Generator」を提供する㈱データグリッド^{*2}と共同で実施した。また、この技術は、画像分類や物体検出、セグメンテーション^{*3}のいずれのタスクにも適用可能である。以降の節では、良品と不良の2クラス分類タスクとして、弱点 TL の各ステップについて詳細に説明する。

2-1 製造現場での画像収集

ステップ①では、検査対象製品の良品画像および不良画像を収集する。画像の撮影にあたって特別なことは何もなく、撮影は一般的な市販カメラで問題ない。また、カラー画像でもグレー画像でも構わない。これらの画像は画像生成AIの学習に用いられる。必要な枚数は良品と不良それぞれ最低1枚であるが、経験的には10枚以上が望ましい。

2-2 疑似不良画像の生成

ステップ②では、不良判定モデルの訓練に用いる疑似画像の生成を行う。今回用いた疑似不良画像の生成方式を図3に示す。ベースとする実際の良品画像と不良画像、および、不良部の見た目をどのように変更するか

の情報を画像生成AIに入力する。画像生成AIで良品と不良の画像を合成することで、わずか10枚の不良画像から多量のリアルな疑似不良画像を生成することができる。不良判定モデルに不良の位置・大きさ・色などが異なる多様な不良を多量に訓練することで、不良の判定性能を向上することができる。あらかじめ、このような疑似不良画像を当社のベテラン検査員に検証依頼したところ、81.1%と高い割合で実際の不良と区別できないとの評価を得た。

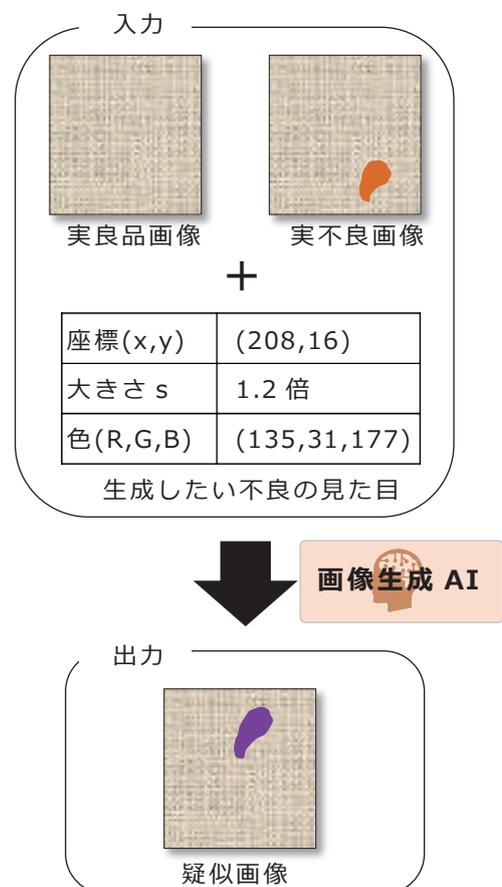


図3 疑似不良画像の生成方式

画像生成AIにより、任意の枚数の疑似画像を生成できるようになる。生成したい不良部の見た目を指示できるため、製造現場でめったに生じない不良モードの疑似画像の集中的な生成や、現場では起こり得ないことがわかっている不自然な疑似画像の生成の棄却が可能である。指示できる不良の見た目（見た目プロパティと呼ぶ）の例を表1に記す。

表1 画像生成AIで指定できる見た目プロパティの例

不良の見た目	説明
座標 (x,y)	不良をどこに生じさせるか
大きさs	不良を何倍に拡大縮小するか
色 (R,G,B)	不良を何色にするか

2-3 不良判定モデルの訓練と評価

ステップ③では、少量の実画像と多量の疑似画像の両方を教師データとして、不良判定モデルの訓練を行う。不良判定モデルには任意のモデルが利用でき、画像分類タスクでは Vision Transformer⁽⁴⁾ や ResNet⁽⁵⁾ 等がよく知られている。

不良判定モデルの訓練後は、テストデータを用いて不良判定モデルの性能評価を行う。評価結果が目標性能を上回っていれば不良判定モデルの訓練を完了する。目標を下回ってれば、ステップ④に移る。

2-4 誤判定結果の分析

ステップ④では、不良判定モデルがどのような見た目の画像でよく誤判定を起しているか、すなわち不良判定モデルの弱点はどのような画像か、詳細に分析を行う。この分析に用いるテストデータも画像生成AIにて生成する。ただし、同一の画像生成AIで不良判定モデルの教師データとテストデータの両方を生成するとデータのリーク^{*4}が生じ、不良判定モデルの結果を正しく分析できなくなるため、ステップ②で学習を行った画像生成AIとは別にもう一つ、異なる画像セットで学習した画像生成AIを評価用に用意する。

ここから不良判定モデルの結果分析の手順を説明する。まず評価用の画像生成AIを用いて、少なくとも1つの見た目プロパティを選択し、選択したプロパティの値をそれぞれ等間隔に変化させたテストデータを生成する。画像のどの位置に不良が存在するかが弱点かを分析する際には、不良座標xとyの値を等間隔に変化させた疑似画像を、それぞれの座標ごとに複数枚生成したものをテストデータとする(図4)。そして、図5のように不良判定モデルの座標ごとの誤判定率分布を評価することで、不良の位置に対する不良判定モデルの弱点を視覚的に確認することができる。なお、今回は見た目プロパティをx座標とy座標の2つとした例で説明したため、図5のように不良判定モデルの正解率を2次元のヒートマップで図示できるが、4つ以上の見た

目プロパティを選択した場合は図示できず、弱点を視覚的に推測することは容易ではないことに注意されたい。

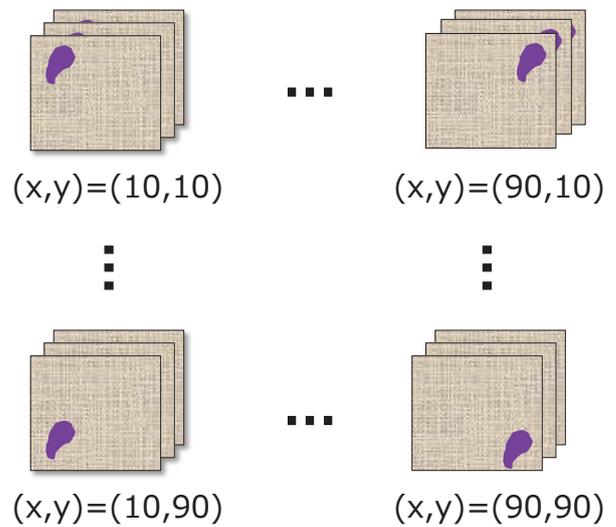


図4 評価用テストデータの生成

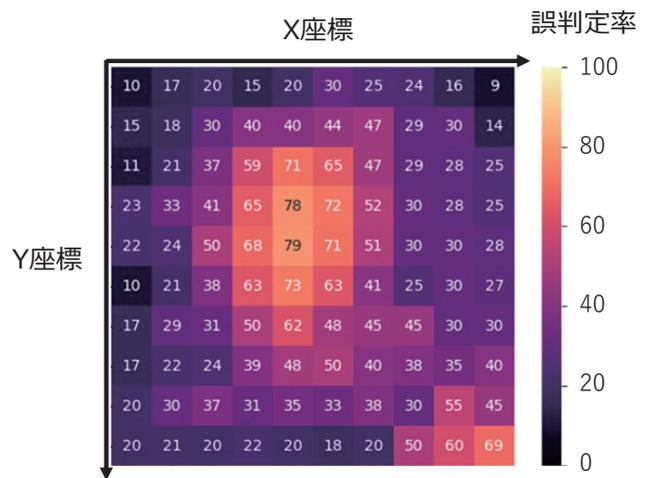


図5 座標ごとの不良判定モデル誤判定率
高い部分が誤判定率が高く、弱点である

2-5 訓練ループ2週目以降

ここで、図2を参照しながらステップ④からステップ②へと移行する際の手順を説明する。ループ2週目以降のステップ②では、ループ1週目に学習した画像生成AIを用いて、弱点の見た目プロパティに類する疑似画像を生成する。次に、ステップ③でこれらの疑似画像を教師データに追加して不良判定モデルの訓練を行う。訓練後は、初回のステップ③で用いたテストデータにて不良判定モデルの性能評価を行い、評価結果が目標性能を上回ってれば不良判定モデルの開発を完了する。目標を下回ってれば、再

度ステップ④にて弱点の見た目プロパティの分析を行い、次の訓練ループへと進む。このような訓練ループは複数行うことができ、ループ回数をさらに重ねることで不良判定モデルの更なる性能向上も期待できる。

なお、画像生成 AI の学習は初回実行時のみで行えばよく、また、ステップ④における弱点抽出に用いるテストデータはどのループでも同一のデータを利用することができる。そのため、画像生成 AI の学習コストやテストデータの生成コストはループ回数に応じて増大しない。

3. 実験結果

この章では、当社で製造する製品に弱点 TL を適用した結果を報告する。対象は図6のセラミックス素材の画像であり、黄丸内側になる白い点が不良箇所である。良品か不良かの2クラス分類タスクとし、不良画像を誤って良品と誤判定する見逃し率を評価指標とする。教師データに含まれる良品画像は実画像500枚とし、不良画像は実験に応じて変更する。



図6 検証に用いたセラミックス素材画像

3-1 不良判定モデルの弱点抽出

本実験において、弱点 TL のステップ④で求めた見た目プロパティごとの正解率分布から不良判定モデルの弱点をどのように抽出するかを説明する。

図5のように誤判定率の分布はある点を極大点として、なだらかに変化することが多い。これは、見た目が似ている画像間では誤判定率がある程度近くなることを示唆している。もし誤判定率が閾値より高い点をすべて弱点とする決め方をすると、よく似た見た目プロパティばかりが弱点となる。その結果、教師データに偏りが生じ多様性が失われる。これは、不良判定モデルの性能悪化や、不良判定モデルの性能改善に必要なループ回数増大の原因と成りうる。

そこで、類似の見た目を重複して弱点と見なさず、多様な見た目の弱点を効率的に抽出する方法として、誤判定率分布の極大点だけを探索することにした。見た目プロパティを p 個設定した場合、誤判定率分布は p 次元空間で表される。この p 次元空間を任意の大きさの小領域 k^p で等分割す

る。ここで、 k は小領域の大きさを決めるパラメータであり、不良判定モデルの性能に影響する。 $p=2, k=2$ の場合は図7 (a) のように2次元空間を赤線で示した小領域に分割することになる。そして、それぞれの小領域内から弱点の候補を1つだけ抽出することで、類似の見た目を排除する。さらに、取り出した弱点候補のうち、あらかじめ設定した閾値 r より小さい誤判定率は除外する (図7 (b))。これは、不必要に弱点を増やさないための措置である。

不良判定モデルに弱点が存在する原因は、教師データにその弱点の見た目プロパティの画像が十分に含まれていないためと考えられる。そのため、弱点の誤判定率に応じて、弱点の見た目プロパティに類する疑似画像を生成し、不良判定モデルの教師データに追加することで不良判定モデルが弱点を克服し、性能が向上することが期待できる。そこで、弱点の誤判定率の値に比例した弱点度合いを求めておく (図7 (c))。弱点度合いは次の訓練ループのステップ②において、どの弱点の疑似画像をそれぞれ何枚生成するかを決める指標となる。

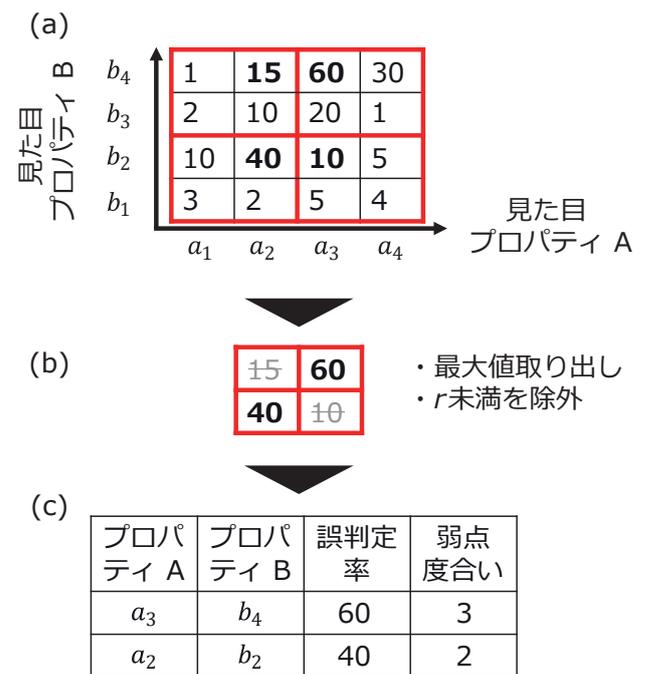


図7 弱点抽出アルゴリズム

3-2 疑似画像の有効性

画像生成 AI で生成した疑似不良画像が不良判定モデルの見逃し率低減に寄与するかの検証を行った。教師データの実不良画像は、10枚の実画像をディープラーニングモデルの訓練でよく用いられる上下左右反転等の水増し手法を用いて1000枚まで増やしたものをを用いた。テストデータには、実不良画像140枚から成る実不良テストデータと疑似

不良画像1000枚から成る疑似不良テストデータの2つを用意した。結果を表2に示す。実不良画像だけを教師データとした場合より、疑似不良画像も教師データに用いた方が低い見逃し率となっており、疑似不良画像が不良判定モデルの見逃し率低減に寄与したことがわかる。ただし、疑似不良画像だけを教師データとすると、疑似評価テストデータにおける見逃し率が改善する一方で、実評価テストデータにおける見逃し率が悪化する。疑似画像には、実画像には含まれない疑似画像独特のノイズが含まれる⁽⁶⁾ことが知られており、疑似不良画像だけで不良判定モデルの訓練を行うとこのノイズが不良の特徴であるという誤った特徴を獲得してしまったことが見逃し率悪化の原因と考えられる。そのため、教師データには実画像と疑似画像を両方とも使うことが有効である。

表2 疑似画像を学習させたときの見逃し率の変化

教師データ		評価結果 (見逃し率)	
実不良	疑似不良	実不良	疑似不良
1000枚	0枚	23.8%	11.4%
1000枚	1000枚	14.3%	7.2%
0枚	1000枚	26.4%	4.8%

教師データに疑似不良画像のみを使う条件は検証用であり、実運用を推奨するものではない

3-3 実画像と疑似画像の比率

教師データには実画像と疑似画像の両方が有効である検証結果を踏まえ、実画像と疑似画像の比率の違いによって実評価画像データにおける見逃し率がどのように変化するかを評価した。その結果を表3に示す。教師データの実不良画像を前節と同様の水増し手法により増やして比率を変えている。実不良画像と疑似不良画像の比率により、見逃し率は大きく異なっており、本データセットにおいてはおよそ2:1の比率を保つと見逃し率が最も低くなることからわかる。なお、この最適な比率は対象とする画像データセットにより変わることには注意されたい。

表3 疑似画像を訓練させたときの見逃し率の変化

教師データ		評価結果 (見逃し率)
実不良	疑似不良 (実: 疑の比率)	実不良
500枚	1000枚 (1:2)	18.6%
1000枚	1000枚 (1:1)	14.3%
2000枚	1000枚 (2:1)	7.2%
4000枚	1000枚 (4:1)	17.9%

3-4 ループ回数による影響

弱点TLの訓練ループを複数回行うことによる不良判定モデル性能の変化を図8に示す。なお、教師データの不良画

像に含まれる実画像と疑似画像の比率は2:1に固定し、既述した弱点抽出手法を用いている。TL回数0は弱点TLを行う前の状態、すなわち疑似画像をまったく使わず実画像のみで訓練した状態を指しており、教師データの実不良画像の枚数は1000枚である。ループ回数を経るごとに見逃し率が改善しており、疑似画像を使う前の23.8%からループ3回目では4.4%へと大きく改善している。さらに、ループを経るごとにステップ④で抽出される弱点の見た目プロパティがどのように変化するかを確認した(表4)。ここでは可視化のため、見た目プロパティの内、不良のx座標とy座標、不良の大きさをそれぞれ軸にとった3次元空間の中で弱点の見た目プロパティと見なした点を赤点で表記した。訓練ループを行う前は22個もの弱点が存在していたが、訓練ループを経るごとに弱点が徐々に減少し、3週目の訓練ループ後には弱点が4個と大幅に減少したことがわかる。これらの結果から、弱点TLにより、不良判定モデルの弱点が効率よく克服され、その結果見逃し率が大幅に改善できたことがわかる。

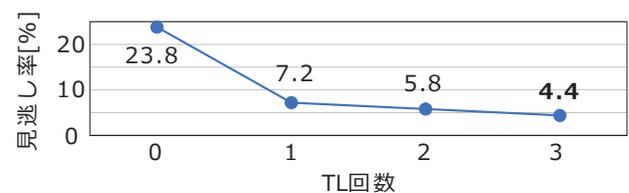


図8 ループ回数による見逃し率の変化

3-5 不良判定モデル開発の高速化

今回実験の対象とした図6のセラミックス素材では、訓練に用いた水増しを行う前のオリジナルの実不良画像は10枚であったが、弱点TLにより見逃し率を4.4%にまで改善できた。今回の対象とは別品種のセラミックス素材で弱点TLを行わずに、通常の方法で不良判定モデルの訓練を行ったところ、見逃し率5%未満を達成するのに要したオリジナルの実不良画像の枚数は1000枚であった。つまり、弱点TLにより必要となる実不良画像の枚数を1/100に低減できたことになる。緒言で述べたとおり、不良の発生率が低い製造現場での実不良画像の収集には長い期間を要するため、少ない実不良画像から不良判定モデルの開発が行えることの開発高速化効果は大きい。本セラミックス素材では、実不良画像1000枚の収集に約4年かかる試算であったが、弱点TLでは画像生成AIの学習も含めて約1か月で外観検査システムの開発が可能となり、90%以上の開発期間短縮を達成した。

表4 学習ループ回数による不良判定モデルの弱点の変化

TL回数	0回目	1回目	2回目	3回目
弱点数	22個	15個	10個	4個
弱点散布図				

4. 結 言

画像生成AIを活用することで、ごく少量の実画像から高速に不良判定モデルを開発する技術である弱点トレーニング・ループを開発した。弱点TLにより、10枚程度の少量の実不良画像から高性能な不良判定モデルが開発可能となり、長期間を要する教師データの収集期間を大幅に短縮できる。これにより、外観検査システムの開発高速化が実現できることを示した。今後は見た目プロパティの拡張により、より複雑な弱点の抽出への対応を進め、本技術が適用できる対象製品を拡大していく。

用語集

※1 ディープラーニング

機械学習のモデルの1つ。教師データを与えることで、そのデータの分類パターンを自動で獲得することができる。高い分類性能で知られる一方、教師データが多量に必要であるというデメリットがある。

※2 (株)データグリッド

京都大学発のスタートアップであり、2017年の創業当初、生成AIの黎明期からその研究・開発に取り組んできた、生成AIのパイオニア企業。

HP : <https://datagrid.co.jp/>

※3 画像分類・物体検出・セグメンテーション

画像分類は画像単位で分類を行うタスクであるが、物体検出は画像のどこに対象が映っているかを矩形で検出するタスク。セグメンテーションは物体検出をより高精細にしたもので、画素単位で対象がどこかを検出するタスク。

※4 データのリーク

機械学習モデルの学習時に、本来知るべきでない情報が紛れ込んでしまうこと。学習時に、評価データがどのようなものかの情報が紛れると、正解を事前に知っていたことになり、正しくモデルが評価できなくなる。

・ Anomaly Generatorは(株)データグリッドの商標です。

参 考 文 献

- (1) S. Shahinfar et al., "How many images do I need?" understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring," *Ecological Informatics*, 57, 101085 (2020)
- (2) P. Bergmann et al., "The MVTEC anomaly detection dataset: a comprehensive real-world dataset for unsupervised anomaly detection," *International Journal of Computer Vision*, vol. 129, no. 4, pp. 1038-1059 (2021)
- (3) P. Bergmann et al., "MVTEC AD-A comprehensive real-world dataset for unsupervised anomaly detection," *Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 9592-9600 (2019)
- (4) A. Dosovitskiy et al., "An image is worth 16x16 words: Transformers for image recognition at scale," *arXiv preprint arXiv:2010.11929* (2020)
- (5) K. He et al., "Deep Residual Learning for Image Recognition," *CVPR2016*, pp. 770-778 (2016)
- (6) N. Kamali et al., "Characterizing Photorealism and Artifacts in Diffusion Model-Generated Images," *arXiv preprint arXiv:2502.11989* (2025)

執 筆 者

吉田 舜* : DX技術研究開発センター 主査



石田 翔也 : DX技術研究開発センター



三浦 勝司 : DX技術研究開発センター グループ長
博士(工学)



*主執筆者