

正常データだけ用意すればOK! 異常検知AIの使いどころ

[ご購入はこちら](#)

古賀 直樹

長年、製造業における外観検査は、熟練の検査担当者による目視によって行われてきました。製品の傷や汚れ、へこみ、変色、異物混入など、さまざまな異常を見つけ出しますが、課題として難易度の高いものも多く、検査担当者の熟練の技と知見が要求されます。

現在は検査担当者の経験、力量による検査精度のばらつきや人手不足を背景として、外観検査の自動化が進められています。これを後押しする新しい手法として、正常データのみを使った異常検知AIが注目されています。本稿では、この手法について、従来の方法（ルール・ベース、正常/異常データから異常検知するAI）と比較し、使いどころを説明します。

外観検査の難しさ

カメラやソフトウェア処理による外観検査の自動化に際して、さまざまな課題があります。

1. 同じ傷、汚れといっても、大きさ、色、形状など多種多様である
2. 異常を見分けるには高い専門性・経験が必要とされるケースも多く、それを明確にルール化、判断基準の定量化をするのが難しい
3. 工場、拠点ごとに環境条件（環境光やカメラ画像に映り込む背景など）が異なり、全ての環境において検出性能を出すのが難しい

従来のルール・ベース

● 慣れ親しんだ方法

従来の検査手法は、ソフトウェアやシステム設計者が次を行っていました。

- 人力で異常の特徴をルール化
- 判定基準の定量化を行い
- それを元に異常判定プログラムを開発

いわゆる、ルール・ベースのアプローチです。

● 課題…撮像条件などの制約がある

パターン・マッチングによってピクセル・レベルで

の一致度合いで判定を行ったり、カメラの撮影条件（画角など）を厳密に固定して異常箇所の大きさの測定を行ったりするため、各種条件の制約が厳しく、上記1、3のような多様性に対応するのが困難でした。

また、上記2にあるとおり、人間がルール化および判定基準の定量化を行う難しさに直面します。

AIを使う従来の手法…正常/異常データを学習して異常を検知

● 10年前から流行し、実用化されているディープ・ラーニング

機械学習はデータから共通する特徴を捉え、目的のタスクを実現します。外観検査の場合は正常/異常を判定する画像認識が目的のタスクです。

正常/異常のデータを用意し、それぞれのデータに共通する特徴を捉え、それを用いて正常/異常の判定を行うモデルを作成します。この工程を学習と呼びます。

画像認識タスクでは、ディープ・ラーニングという深い層のニューラル・ネットワークを使った機械学習の手法、特にCNN（畳み込みニューラル・ネットワーク）やVision Transformerが主に使われます。ディープ・ラーニングが世の中にインパクトを与えたのもCNNが画像認識タスクにもたらした圧倒的な認識性能でした。

● 処理の流れ

正常/異常それぞれを学習するアプローチは、学習の際に正常/異常データに対してラベルを付与し、あるデータが正常データなのか異常データなのかを分けるようにします（教師あり学習）。データにラベルを付与する工程をアノテーションと呼びます。

学習済みモデルに、判定対象となる新たな画像を入力すると、入力した画像が正常なのか異常なのかを予測します。これを分類タスクと呼びます。正常/異常の2クラス分類だけでなく、例えば、正常、傷、よごれのように、多クラスの分類モデルを作ることも可能です（図1）。