

PatchCore アルゴリズムで
少量の異常サンプルからモデルを作成

Google Colabで体験! AI画像認識で異常検知

古賀 直樹

● 目視に変わってディープ・ラーニング・ベースの検査が増えつつある

製造業の現場では、外観検査の自動化が進められています。これまでは目視によって傷や汚れなどの不具合が検査されていましたが、これをコンピュータによる画像処理/認識技術に置き換えることにより自動化を実現しています。その中でも、より多様な欠陥形状や環境条件(照明環境やカメラ撮影アングルの相違など)に対応するために、ディープ・ラーニングをベースとした画像認識技術を活用する事例が増えています(図1)。

● 欠陥品のサンプルは少ない

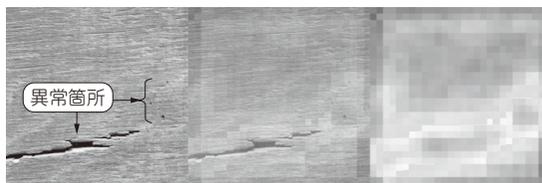
一般的にAIモデルを作成する教師あり学習という手法では、大量の画像データと、ラベルと呼ばれる正解情報(どの種類の欠陥なのか、また画像のどの箇所に欠陥があるかなどの情報)を利用します。しかし、外観検査の現場の課題として、欠陥品のサンプルが少なく教師あり学習に必要な情報を集められないことが挙げられます。中には年に数件しか発生しない欠陥も存在し、なかなか多くの欠陥サンプルを集めるのが難しい事情があります。

このような事情から欠陥サンプルを必要としない、または少ない欠陥サンプルで認識モデルを作成する手法の必要性が増えています。これは正常サンプルの画像だけを使って(またはそれに加えて微量の欠陥サンプル画像を使って)モデルを作成することを意味します。正常サンプルの特徴をとらえてそこからかけ離れた特徴を持つものを異常と判定する考え方で、これを外れ値検知と呼びます。外れ値検知の手法は、教師あり学習のように欠陥の特徴を学習しそれに近いものを検出するアプローチではないので、未知の欠陥を検出できる可能性も有します。

外れ値検知のアルゴリズム

● 畳み込みニューラル・ネットワークを利用したものがやはり

近年は外れ値検知にニューラル・ネットワークを



(a) 可視化1



(b) 可視化2



(c) 可視化3

図1 異常箇所をAIで検出、ヒートマップで可視化

使った手法が提唱されています。ニューラル・ネットワークを使った外れ値検知の手法としてはオートエンコーダを使った手法などがありましたが、昨今は画像を扱うのに特化したモデルであるCNN(畳み込みニューラル・ネットワーク)を活用した手法が提唱されています。

基本的には正常サンプル画像と検査対象サンプルの形状特徴を比較し、正常な特徴から離れているものを異常と判定します(図2)。直接画像のピクセル単位で比較するのではなく、CNNを通した特徴ベクトルを使うことで汎化性能を向上します。

CNNは画像データのある局所的な形状との類似度マップに変換します(特徴ベクトル)。そのため画像の特徴を抽象的に捉えることができ、わずかな位置ズ