

画像検査でルール・ベースに立ち返る



安藤 尚隆

画像解析の分野では、ルール・ベースでの処理が広く使われてきました。ルール・ベースは、あるルールに従って画像情報を処理する技術で、機械学習やディープ・ラーニング技術が普及する前の画像解析技術では主流でした。

ディープ・ラーニングは技術としてはまだ完全には確立していないまでも、画像解析における顔認識や人体認識などの物体認識の用途では定着してきています。2020年代で当たり前の技術となり、AIブームは終わりを迎えるかもしれません。

この章では、ディープ・ラーニングおよび従来のルール・ベースによる画像解析の有効性について、製造現場の視点から比較してみます。

AI導入における製造現場の悩み

この10年、大手自動車メーカーをはじめ多くの製造現場の目視検査を画像のAI解析で自動化する例が増えてきました。導入の目的は、検査員によるバラツキや見逃しの軽減、検査時間の短縮です。導入例が増えている中、期待通りの成果が得られず断念している例も少なくありません。その理由はいくつかあります。

● 理由1：失敗サンプルを用意できない

ディープ・ラーニングにはアノテーション・データを準備して学習させる工程が必要です。これは良/不良の各画像を数多く用意して、人が特定した不良部分の情報とともにPCに読み込ませて不良部分(図1)の共通点をPCに学習させる工程です。

ある自動車部品メーカーでは、不良発生率が月に1個か2個なので、仮に100枚の不良画像を撮るまでには1年以上自動化を待たなければなりません。準備ができたとしてもその時点で製造終了間近の可能性もあります。

そこで誰もが考えるのが、意図的にキズをつけて不良画像を撮ることです。しかし、実際に製造ラインで発生する不良と人為的な不良は似て非なるものなので、結果としてディープ・ラーニングでは本当の不良

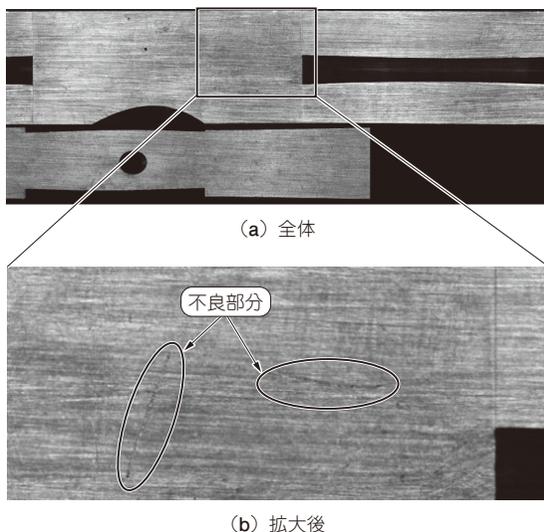


図1 部品の不良部分

は見逃してしまいます。

● 理由2：製造するものが頻繁に変わる

ある冷凍パスタ・メーカーの製造現場では、各製造ラインがその日によって、更には午前/午後で製造する商品が変わります。パスタの種類、ソース、具材の種類が変更になるのです。学習用の画像を取得できたころには製造する製品が変わってしまいます。季節ごとにも変わるし、売上が芳しくない商品は以後製造しないかもしれません。結果として、運用上、導入を見送るケースがほとんどです。

不良画像を多くそろえるのが困難な場合は、良品のみを学習させる手法もあります。しかし、学習させた画像には無かった洗浄痕や吹けば飛ぶゴミを不良と判断してしまう過検出が続出します。これらを良品画像に加えて再度学習させますが、終わりが見えません。

● 理由3：大きな画像の中の微小な不良を探せない

多くのディープ・ラーニング・プラットフォームでは、学習時間短縮のために学習画像のピクセル数を制