

物体検出手法を用いた粉粒体の付着検知

Detection of Powder Granule Attachment Using Object Detection Methods

若林 直哉[†]

Naoya Wakabayashi

島川 博光[†]

Hiromitsu Shimakawa

1. はじめに

近年は色彩設計の多様化に伴い、光輝性顔料を使用した塗料が多く開発されている。多様な製品に使用されるこれらの塗料は、様々な形状をした粉粒体の集合を粉砕して作られる。

粉粒体には製作の過程上、各粉粒体に対して異なる大きさの粉粒体がランダムに付着することがある。本論文では、このような粉粒体を付着粉粒体とよぶ。付着粉粒体は粉砕が十分にされないため輝度が低くなり、製品の質を左右する要因となる。よって、製品の質を評価するうえで、付着粉粒体の個数や分布を知ることは重要である。

現在は、製造プロセスの熟練者が塗料の顕微鏡写真を目視で判定して評価している。しかし、重なって見える粉粒体の数は多く、評価には時間を要する。そのため、生産性を向上させるには機械的に付着粉粒体を検出することが望ましい。そこで本論文では、製品の質を左右する付着粉粒体を機械的に検知できるかを調査する。

2. 付着粉粒体

顕微鏡によって観察された、塗料に含まれる粉粒体の集合の例を図 1 に示す。従来は、図 1 に示されるような塗料の顕微鏡写真を熟練者が主観的に評価していた。塗料の種類によって様々な形状をした粉粒体があるが、本論文では図 1 に示した小さな粉粒体が大きな粉粒体に付着したもののみを対象として調査した。

図 1 の一部を切り出し、付着粉粒体となる箇所を示した例を図 2 に示す。四角形で囲まれた部分が、本研究にて検出する対象となる付着粉粒体である。粉粒体に付着している、粉粒体に比べて明らかに小さな粉粒体を付着粉粒体として検出する。




図 1: 粉粒体の集合




図 2: 付着粉粒体

3. 付着粉粒体の検出

3.1 付着粉粒体の検出における問題

本研究では、画像内に存在する付着粉粒体のみを検出する。検出した付着粉粒体の個数や分布を活用することで、塗料の品質を評価する。本研究において問題となる点は、主に以下の 2 点である。

- 正解ラベルが与える画像の状態に依存するため、データの拡張が難しい。
- 特徴が隠微である、類似形状物体に付着している付着粉粒体のみを検出する。

正解ラベルが一意かつ不変である場合、データの拡張が容易である。そのため、多くの学習データを用いることができるが、付着粉粒体の有無ではなく付着粉粒体の個数を検出したいために画像の状態に依存する。また、本研究で焦点となる付着粉粒体は、類似形状物体である粉粒体に付着した小さな粉粒体であり、大きさは付着先の粉粒体に依存する。そのため、様々な大きさからなる付着粉粒体の特徴を抽出することは難しい。

同一画像内に複数の対象物が存在する際に、これらの領域を検出する手法は存在し、研究が進められている。しかし、ラベル付けが個別画像に依存するためにデータの拡張が難しい画像から、特定条件を満たすような物体のみを検出するような研究は、著者らの知る限り存在しない。

3.2 物体検出手法における意義

深層学習によって画像内にある対象を認識する場合、各タスクの目的に伴って画像認識・物体検出・セグメンテーションの手法に分けられる。一般的には、画像認識が比較的容易な手法であり、セグメンテーションになるにつれてモデルが複雑になり難度が高くなる。

画像認識では、与えられた画像内に写っている物体の識別を行なう。本研究で用いる画像には複数の付着粉粒体が写っていることが多い。そのため、画像認識によって学習する場合に付与する正解ラベルは、画像内に存在する付着粉粒体の個数となる。その際、対象となる付着粉粒体のみを大きな特徴として捉え、正解ラベルと付着粉粒体に関連していることを学習するまでには大量のデータセットを必要とする。画像認識に適したタスクでは、様々なデータ拡張によって異なるデータセットを作成することで、学習に必要なデータ数を増やす。しかし、本研究では正解ラベルが付着粉粒体の個数であり画像の範囲に依存するため、拡大や並行移動といったデータ拡張を施すことができない。よって、大量の画像すべてに手作業でラベル付けする必要がある、現実的ではない。

物体検出では、モデルに学習データを与える際に、評価者が対象の位置とそのラベルを指定する。多くの物体検出モデルは画像認識手法をモデル内で活用しているが、学習の際に位置を指定することで、対象を認識するまでの学習が不要となり、特徴を学習することにデータを使用できる。そのため、画像認識で本研究を遂行する際と比べると、学習に必要なデータ数は大幅に減少する。また、物体検出によって学習されたモデルの予測結果には、対象の範囲と信頼度が出力される。本研究において付着粉粒体の個数と分布を知ることが重要であるため、物体検出手法を用いることは有意義である。

[†]立命館大学大学院情報理工学研究所

セグメンテーションでは、画像内に写っている物体の種類に加えて、その物体の境界領域を学習し予測する。本研究において付着粉粒体の特定は重要なタスクであるが、個数や分布によって品質を評価するため、境界領域を予測する必要はない。データ数の増加やモデル複雑化による処理速度の低下につながり効率的ではない。

本研究では、物体検出手法を用いて検出する。

3.3 YOLO の活用

本研究では、物体検出手法を用いてランダムに存在する付着粉粒体の検出を行なう。代表的な物体検出手法として、R-CNN・YOLO・SSD が多用されている。

R-CNN は、RPN (Region Proposal Network) によって物体候補領域の探索と画像認識を組み合わせ検出を行なう。精度は比較的高いことが知られているが、指定した範囲内の特徴を学習するため、画像背景とのコントラスト等の学習が難しく、背景の誤検出が多い。また、バウンディングボックス毎に CNN を学習する必要があり、推定時にも認識領域に対してそれぞれ CNN で予測するため、処理に時間を要する。さらに、予測結果として出力される領域の重なりが多く発生するため、付着粉粒体の分布を正確に予測できない。

YOLO[1] は、画像を分割して生成したグリッドセル毎に、バウンディングボックスと物体クラス確率を計算する。画像全体を学習に使用するためコントラストなどを考慮しやすく、背景の誤検出を抑えることができる。単一の CNN からなり、複数の畳み込み層およびプーリング層にて特徴を抽出後、CNN ネットワーク構造の最後にある 2 層の全結合層にて、バウンディングボックスの信頼度と各クラスの確率を計算する。最後の 2 層のみで領域内容を計算するため、計算速度が非常に速いといった特徴をもつ。また、YOLO では 1 つの物体を複数の領域で検出しないよう、NMS(Non Maximal Suppression) を用いている。そのため、R-CNN と比べると領域の重なりを排除することができる。YOLO はグリッドセルが一定の大きさのため、小さいスケールの物体やその集合を検出することが難しい。しかし、本研究において検出のための画像は十分に拡大されており、付着粉粒体の検出には問題ないと考えられる。

SSD は、特徴マップに沿って設置したデフォルトボックス毎に、物体領域の位置推定と物体クラス推定を行ない、NMS で重複を排除する。その際、各畳み込み層にて物体領域の位置やクラス確率を計算し、最終的にオフセット値を補正するため、スケールの変化に柔軟に対応するが、処理に時間を要する。本研究では、塗料の評価を行なうにあたってデータの偏りが少なくなるように、広範囲の画像を拡大して生成したいくつもの画像に対して付着粉粒体の評価を行なう。その後、合成することにより該当塗料を評価するため、各画像に要する処理速度はできるだけ抑えることが望ましい。よって本研究では、YOLO を用いて付着粉粒体を検出する。

4. 検出結果

本章では、YOLOv5(version5) を用いて付着粉粒体の検出を行なった結果を示す。本検証では、モデルの幅と深さの倍数の違いにより、層数やパラメータ数が異なる 5 種類をモデルに構築した。モデルは、GitHub[2] にて公開されている内容を参考にした。

本検証では、学習データを 40 枚、検証データを 20 枚としてモデルが構築可能であるかを調査した。すべてのモデルに関して、入力画像サイズを 640、バッチサイズを 16、エポック数を 200 に設定した。また、モデルが収束しやすいよう、各モデルの初期ウエイトを異なるデータで学習済みモデル [2] より引用した。

学習時に選択されたもっとも最良なモデルについて、検証データを評価した際の適合率・再現率・AP@0.5 を表 1 に示す。AP(平均適合率)とは、各再現率値における適合率値の平均をプロットした際の下部面積を意味する。AP@0.5 は、モデルが出力するバウンディングボックスを決定する IoU(Intersection over Union) の閾値が 0.5 であることを示す。

表 1: モデル別の評価

モデル	適合率	再現率	AP@0.5
YOLOv5n	0.648	0.742	0.694
YOLOv5s	0.733	0.661	0.703
YOLOv5m	0.804	0.597	0.716
YOLOv5l	0.714	0.644	0.655
YOLOv5x	0.755	0.645	0.659

表 1 より、すべてのモデルは 0.7 前後の AP 値を出力しており、適合率や再現率も一定の値を保持している。完全には実現できていないながらも、すべてのモデルが過半数以上の付着粉粒体を正しく検出できた。最良な AP 値は YOLOv5m が出力した結果であり、モデルが大きくなるにつれて低下している。また、YOLOv5m を境に適合率と再現率の傾向が変化した。

本検証では、少数のデータセットから一定の結果がえられた。AP 値の IoU の閾値を 0.5 と設定したが、正しいにもかかわらず学習データの少なさから高い値を出力しなかったバウンディングボックスも存在したため、データセットを増やすことで性能はさらに上昇すると考えられる。大量のデータセットを必要とする従来の画像認識手法よりも学習効率が良く、正解ラベルが画像状態に依存し、類似形状物体である付着粉粒体の検出に適していたと考えられる。

5. おわりに

本論文では、物体検出手法の YOLO を用いた付着粉粒体の検出を行なった。本検証の結果より、類似形状物体である付着粉粒体のみを検出するモデルを構築することができた。今後は、異なるモデルとの比較や、モデルのネットワーク構造の改変による最適化により、精度向上を見込めると考えられる。

参考文献

- [1] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi. You Only Look Once: Unified, Real-Time Object Detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp.779-788. 2016.
- [2] Glenn Jocher. "yolov5". GitHub. <https://github.com/ultralytics/yolov5>. access at 2022-05-25.