

深層距離学習を応用したベルトコンベア上の石灰岩分別

Limestone classification on belt conveyor with deep metric learning

賀川 経夫[†]
Tsuneo Kagawa

永田 亮一[†]
Ryouichi Nagata

1. はじめに

石灰製品の加工において、原材料の石灰岩に不純物が多く含まれていると、製品の品質や品位が著しく劣化する。そのため、加工工程の早い段階で、すなわち、原材料の段階での石灰岩の分別が非常に重要である。通常の石灰岩の表面は、灰色が基調であるが、雑岩と呼ばれる低品質の石灰岩には、鉄などの鉱物が不純物として多く含まれており、その組成により表面色などが多少異なってくる。したがって、目視での分別が可能ではあるが、表面色の差異が微妙である、高速なベルトコンベアによって大量に運搬される石灰岩を見分けなければならない、などの理由により、人手の分別は非常に困難である。

本研究では、画像処理による石灰石の自動分別の実現に取り組んでいる。そこで、近年、多方面で応用されている機械学習モデルの一つである CNN (Convolutional Neural Network) を利用して、判別性能を評価した[1]。その結果、正解率が 0.74 となる結果が得られた。しかしながら、実際の現場において、雑岩は多くは含まれないため、学習時のデータが普通の石灰岩の画像が多く不均衡になる、さらに不均衡なデータになってしまう、不純物の組成により、様々な雑岩が含まれる可能性があり、あらかじめクラスを決めることが困難であるなどの理由により、CNN などを用いたクラス分類については実用に向けて多くの課題が残されている。

そこで、本研究では、深層距離学習による異常検知技術を応用した画像情報に基づく良質の石灰岩と不純物を含む石灰岩の分別について、その性能について評価・検討を行う。

2. 石灰岩の分別

2.1 石灰岩の分別

本研究での石灰石分別の実験環境を図 1 に示す。実際の石灰石加工工程で利用されるベルトコンベアとほぼ同じ速度で回転するシミュレーション装置を用いて石灰岩を移動させながら、30fps で撮影可能な高速ビデオカメラでそれらを撮影する。照明は、2基の LED ライトを用いて影の影響がでないようにしている。

2.2 画像処理

図 2 に撮影された動画の 1 フレームを示す。丸で囲まれたものが雑岩である。この雑岩は鉄を含んでおり緑がかっているが、高速移動している時にそれを目視で確認することは非常に困難である。ベルトコンベア上の石灰岩の識別を行うには、なるべくサイズの小さな画像を利用して高速処理を実現する必要がある。また、実用的には、雑岩を検




図 1 ベルトコンベアシミュレータ



図 2 石灰石の画像例




図 3 画像サンプルの例

出しても、その個体だけをコンベアから取り除くことは非常に困難であり、コストもかかるので、周囲の正常な石灰岩とともに取り除かれることを考慮する必要がある。そこで、図 2 に緑の矩形として示すように幅が 16 画素の領域を設定し、その間の雑岩と石灰岩の判別を行う。実際には、

[†] 大分大学 理工学部 Oita University, Faculty of Science and Technology

この領域を上下に 2 分割し、図 3 に示すように 16×450 サイズの領域を一つのサンプルとし、それぞれに雑岩がふくまれているかどうか判定する。

3. 深層距離学習を用いた画像の分別

本研究で利用するネットワークは 6 層で構成される CNN であり、出力層は 8 次元となっている。深層距離学習 (DML, Deep Metric Learning) では、CNN の出力によって構成される特徴空間でのサンプルの分布について、類似したものは特徴空間でも近傍に、類似していないものは、離れた位置に配置されるように距離関数を学習するものであり、医用画像の異常検知[2]などに広く応用されている。

本研究では、一般的な画像処理による分別が困難である、異常データが少なく学習サンプルの獲得が困難である、などの理由により、深層距離学習の適用を試みる。本手法では、Triplet Network[3]によって、石灰岩画像を雑岩が含まれない正常画像と雑岩を含む異常画像とに分類する。Triplet Network では、Anker と呼ばれる基準サンプルを中心に、Anker と類似している Positive と、Anker とは類似していない Negative という 3 つのサンプルデータを、一組のデータとして学習が行われる。Anker を基準にして、ある距離関数 $distance$ に従い、Positive と Negative との距離を以下のように定義する。F ()

$$D_p = distance(f(Positive), f(Anker))$$

$$D_n = distance(f(Negative), f(Anker))$$

ただし、 $f()$ は、サンプルに対する CNN の出力を表す。その上で、以下の式を損失関数として学習をすすめていく。

$$L_{triplet} = \max(0, D_p - D_n + m)$$

ただし、 m はハイパーパラメータである。本手法では、距離関数は、ユークリッド距離を用いる。

4. 評価実験

実験では、図 3 に示すように動画をフレーム画像に分割し、各フレーム画像より 8 枚の領域サンプルを獲得する。そのうち、各領域サンプルに少しでも雑岩が含まれている場合は、異常サンプルとしてラベルを付ける。このようにして得られたデータセットのうち、正常データをランダムに 1000 枚、異常データを 400 枚選択し、50epoch 学習を行った。次に学習を行ったネットワークに対して、別の動画サンプルからランダムに抽出された検証用のデータセット (正常サンプル 800 枚、異常サンプル 383 枚) を適用し、t-SNE を用いて 2 次元空間上に可視化したものを図 4 に示す。図 4 上段は、最終的な距離空間であり紫色が正常サンプル (図 4 中段)、黄色が異常サンプルの分布 (図 4 下段) を表している。重畳している部分があり、鮮明ではないが、ある程度の分別はできているといえる。

5. おわりに

今回は、通常の画像処理や画像分類が困難な石灰岩の分別に深層距離学習が利用できるか評価を行った。適当な分類手法を用いれば、ある程度の分類が可能であることが判明した。今後は、分別性能に関する定量的な評価を行うと

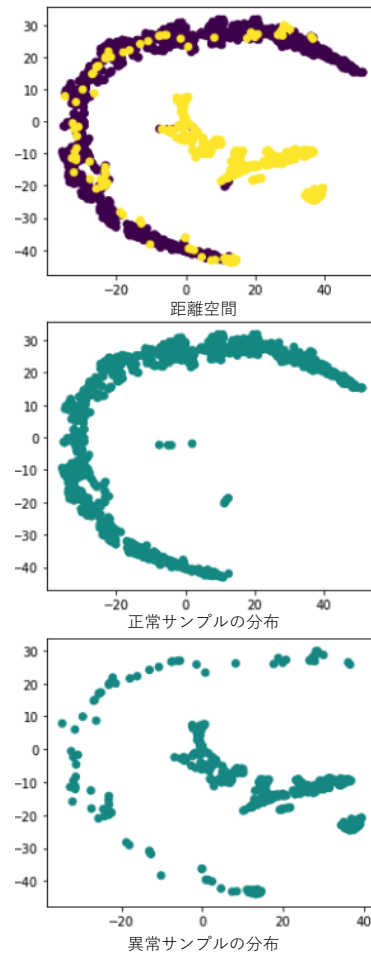


図 4 深層距離学習の結果

ともに、knn や SVM などの分類手法との組み合わせにより、実用的な分別手法について検討を進めていく。さらに、深層距離学習については、AdaCos[4]などの手法の適用について検討を行う。

謝辞 本研究を遂行するにあたり、実験機材の提供および有益な助言を頂きました。共同研究先である古手川産業株式会社の方々には厚く御礼申し上げます。

参考文献

- [1] 永田, 賀川, “ベルトコンベア上の石灰石分別: 機械学習を用いた雑岩検出法の検討”, 2021 年度電気・情報関係学会九州支部連合大会 (第 74 回連合大会) 講演論文集 2021 年.
- [2] J. Wang, Y. Song, T. Leung, C. Rosenberg, J. Wang, J. Philbin, B. Chen, and Y. Wu. "Learning Fine-grained Image Similarity with Deep Ranking.", International Conference of Computer Vision and Pattern Recognition (CVPR2014), 2014.
- [3] 中井, 韓, “距離学習を用いた深層学習ネットワークによる肝硬変状態分類の検討”, 2021 年度 第 35 回人工知能学会全国大会 4C4-OS-1b-03, 2021.
- [4] Xiao, Rui, Yu, Xiaogang and Hongsheng, “AdaCos: Adaptively Scaling Cosine Logits for Effectively Learning”, International Conference of Computer Vision and Pattern Recognition (CVPR2019), 2019.