

骨格情報を利用した労働災害防止のための 深層学習に基づく異常検知手法

Anomaly Detection Based on Deep Learning

Using Skeleton Information for Prevention of Industrial Accident

学 橋本 慧志 (中央大学) 正 池 勇勲 (中央大学)
工藤 謙一 (中央大学) 高橋 孝幸 (プリマハム株式会社)
正 梅田 和昇 (中央大学)

Satoshi HASHIMOTO, Chuo University, hashimoto@sensor.mech.chuo-u.ac.jp
Yonghoon JI, Chuo University, ji@mech.chuo-u.ac.jp
Kenichi KUDO, Chuo University, kkudo32h@tamajs.chuo-u.ac.jp
Takayuki TAKAHASHI, Prima Meat Packers, Ltd., takayuki.takahashi@primaham.co.jp
Kazunori UMEDA, Chuo University, umeda@mech.chuo-u.ac.jp

In Japan, the number of casualties due to an industrial accident in 2009 was 114,154 people. Currently, a comprehensive system to prevent such an accident is basically done manually. Furthermore, it has not been automated. Therefore, in this study, we develop an anomaly detection method for the prevention of industrial accident using machine learning technology. In order to carry out anomaly detection reliably, we use a skeleton map of a person as training data from skeleton information extracted by OpenPose. Here, Variation Autoencoder (VAE) is applied as a deep learning model. We confirm that detection results with high accuracy are produced compared with the conventional method.

Key Words: Anomaly detection, Deep learning, Industrial accident

1. 序論

我が国の平成 21 年の休業 4 日以上の労働災害における死傷者数は 114,152 人で、そのうち食品製造業におけるそれは 8,050 人にも及ぶ[1]。一度労働災害が発生すれば、企業に対して様々な責任が課せられることとなる。これらの労働災害や事故を未然に防止する取り組みの 1 つに、リスクアセスメントがある[2]。リスクアセスメントは、一般にハザードを特定してリスクを評価し、それに沿った改善行動を行う一連の流れのことを言う。しかし、リスクアセスメントなどの包括的な労災を防止する取り組みは、一般に人手によって実施されるものであり、その自動化には至っていない。一方、日常生活における様々な場面での異常をとらえる異常検知に関する研究が行われている。異常検知は、防犯カメラから取得できる動画画像を活用して犯罪行動の検出や、日常生活での転倒事故の検出など多方面での活用が期待されている。異常検知においては、従来の手法として主成分分析 (PCA: principle component analysis) により正常データを表す部分空間を学習し、その分布の距離から異常度を算出する部分空間法や、混合ガウス分布 (GMM: gaussian mixture model) を用いた教師なし学習による手法が存在している[3]。しかし、これらの従来手法は画像などの高次元のデータを扱う場合、精度を十分に担保できない恐れがある。

そこで本研究では、以上の背景を踏まえ、異常検知手法を用いて労災を防止する包括的な自動監視システムを構築することと、深層学習を用いることで、従来の異常検知手法と比べ高い精度での異常検知を可能にすることを目的とする。具体的なタスクとして工場内での作業を模した複数の行動パターンの異常検知をあげ、検証実験により精度を確認する。

本稿では、最初に深層学習を用いた教師なし異常検知のフレームワークを紹介する。次に、検証実験に関して紹介し、最後に本手法の有効性に関して検証する。

2. 深層学習による異常検知

2.1 提案手法の概要

提案手法の流れを Fig. 1 に示す。本手法では、まずカメラを用いて人物の作業行動の様子を 640×480 の解像度の画像に撮像し、OpenPose を用いて人物の骨格情報を取得する。次に、得られた骨格画像に前処理を施し、 28×28 の解像度の骨格情報マップを作成する。次に、この骨格情報マップを入力として Variational Autoencoder (VAE) [5] による学習を行う。最後に、学習したモデルを用いて異常検知を行い、入力した骨格情報マップと、VAE により復合された骨格情報マップとの差分から、逐次的に異常度を算出する。




Fig. 1 Proposal framework

2.2 OpenPose を用いた骨格情報の取得

2.1 節にて、撮像した入力画像に対して、OpenPose を用いて人物の骨格情報を取得する。OpenPose とは、Cao ら[4]の骨格推定手法を実装したライブラリであり、Convolutional Neural Network (CNN) を組み合わせることで 1 枚の画像から 25 箇所の人物の骨格座標の検出を行うことが可能である。次に、得られた骨格画像に前処理を施し、骨格情報マップを作成する。前処理の流れを Fig. 2 に示す。まず、OpenPose を用いて得られた人物の骨格画像を、首の座標を中心として 480×480 のサイズに切り取る。次に、 28×28 のサイズに低解像度化を行う。

ここで補間手法としてはバイリニア法を用いる。最後に、グレイスケール化と2値化を行い、骨格情報マップを作成する。




Fig. 2 Skeleton map from skeleton information

2.3 VAE を用いた異常検知

VAE は Fig. 3 に示すように通常の Autoencoder (AE) にベイズ推論の枠組みを取り入れたネットワーク構造を持つ。

AE は、入力を良く表す特徴を次元削減により取得し（符号化）、それを用いて入力画像を復元する（複合化）、front-end 型のニューラルネットワークである。

一方、VAE は、次元削減により得られる特徴に確率分布を仮定することで、符号化から確率分布の平均や分散を出力し、それらを用いて複合する構造のニューラルネットワークである。提案手法では確率分布に多変量正規分布を用いる。




Fig. 3 Framework of VAE

3. 検証実験

3.1 実験概要

提案手法の有効性の確認および PCA を用いた従来手法との精度比較を目的として、検証実験を行った。

まず、正常データの学習に用いる骨格情報を取得するために、工場内での作業を模した複数パターンの行動を行った。そして、その様子をカメラを用いて収録した。このように収録した動画から 11,500 枚の骨格情報マップを作成し、これを訓練データとした。最後に、このマップを用いて VAE と、比較対象である従来手法の PCA の学習を行った。VAE の学習時におけるエポック数は 50、特徴ベクトルは 28 次元となるように設定した。PCA では 2 次元までの次元削減を行った。

続いて、作成したモデルの異常検知の精度を確認するために、テストデータの取得を行った。訓練データの取得時と同じ実験環境において、作業行動以外の異常行動を行い、4,400 枚の骨格情報マップを作成し、これをテストデータとした。また、適切に異常な行動パターンを検知できるか検証を行った。

3.2 実験結果

モデルの精度を評価する指標である ROC (Receiver Operating Characteristic) 曲線を Fig. 4 に、異常度の推移を Fig. 5 に示す。また、モデルの AUC (Area Under the Curve) 値を Table 1 に示す。提案手法では、異常な行動パターンを正しく異常と判別することができた。VAE により複合された画像の一例を Fig. 6 に示す。各画像上段が入力、下段が出力である。また、従来手法と比較して、ROC 曲線、AUC 値のどちらも提案手法のほうが良い精度を示す結果となった。

Table 1 AUC

	Proposed method	Conventional method
AUC	0.875989	0.763373




Fig. 4 ROC curve




Fig. 5 Abnormality degree from proposed method



(a) Low abnormality degree (b) High abnormality degree

Fig. 6 Inputs and outputs of VAE

3.3 実験考察

提案手法は、3.2 節の結果を根拠に、労災防止のための自動異常検知手法として有効であると言える。また、VAE による深層学習を用いた異常検知アプローチにより、従来の PCA を用いた手法と比較しても高い精度を出すことができた。

しかし、提案手法は入力を静的な情報に限定しており、VAE の抽出した特徴は人物の姿勢に関する情報を表していると推測される。よって、人物の行動の動的な情報などは考慮できていないため、AUC は 0.87 にとどまってしまったと考えられる。また、骨格情報マップの作成手法に関しても、低解像度化に伴い人物の姿勢を十分に表せていない場合があるため、画像サイズの大きさなどで検討の余地がある。

4. 結論

本研究では、異常検知手法を用いて労災を防止する包括的な自動監視システムを構築した。また、深層学習を用いることで、従来の手法と比べ高い精度での異常検知を可能にした。

今後の展望として、動的な情報を考慮できる深層学習モデルである LSTM を用いることや、包括的な労災防止システムの実現に向けて周辺の環境認識手法の検討がある。

参考文献

- [1] 中央労働災害防止協会, “食品加工作業におけるリスクアセスメント”, 2011.
- [2] 齋藤 剛, “機械のリスクアセスメントの実施手順”, 日本信頼性学会誌, Vol. 31, No. 1, pp. 53-58, 2009.
- [3] Saligrama V. and Chen Z., “Video anomaly detection based on local statistical aggregates”, Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR2012), pp. 2112-2119, 2012.
- [4] Cao Z., Simon T., Wei S. E., and Sheikh Y., “Realtime multi-person 2D pose estimation using part affinity fields”, Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR2017), pp. 1302-1310, 2017.
- [5] Carl D., “Tutorial on variational autoencoders”, arXiv, 2016.