

変化点検知を用いた作業者行動のラベル付け および動作推定手法の提案

藤原 龍聖[†] 工藤 諒太[‡] 堀川 三好[‡] 岡本 東[‡]

岩手県立大学ソフトウェア情報学部[†] 岩手県立大学大学院ソフトウェア情報学研究科[‡]

1. はじめに

製造現場における可視化技術の導入事例として、動画から作業者の姿勢推定により得られる骨格データを用いてグラフニューラルネットワーク（以下、GNN）による動作推定を行い、標準作業時間の算出等を行う取り組みがある。このような動画は、設備や作業台等により骨格データの欠損が多く生じる点が課題としてあげられる。この課題に対して、先行研究¹⁾では、骨格データとセンサデータを用いたマルチモーダル学習により、骨格データの欠損が多い事例において高精度な動作推定が可能な手法を提案した。しかしながら、データセット生成における Annotation 作業に多大な労力を要することが課題として残っている。

本研究では、簡易センシングデバイス（以降、センサ）と動画を併用した動作推定を実現する研究の一環として、教師あり学習における動作ラベル付け作業を省力化する手法を提案する。提案手法では、センサから取得される加速度・角速度データに変化点検知手法、クラスタリング手法および動的時間伸縮法を適用し、動作分類ごとの基準変化点スコアを生成することで、人間が行うラベル付けを最低限に抑制する。また、本稿では、ラベル付け手法の有効性を確認するため、セル生産環境を想定した実験において、提案手法により生成したデータセットを用いてセンサデータと骨格データのマルチモーダル学習による動作推定を行った結果を報告する。

2. 関連研究

ラベル付け作業を省力化する取り組みとして、

Proposal of Worker Behavior Labeling and Motion Estimation Method using Change Point Detection

[†] Ryusei Fujiwara, [‡] Ryota Kudo,

[‡] Mitsuyoshi Horikawa, [‡] Azuma Okamoto

[†] Faculty of Software and Information Science, Iwate Prefectural University

[‡] Graduate School of Software and Information Science, Iwate Prefectural University

任意の区間ごとの時系列データに対し、区間内に占める割合が高い動作ラベルを付与していくことで、最も割合の多い動作区間を自動抽出して教師データを作成する手法がある²⁾。また、先行研究¹⁾では、センサデータと骨格データを用いた動作推定モデルを比較し、マルチモーダル学習が骨格データの欠損が多い場合にも高精度の推定が可能なことを示した。

3. 作業者の動作推定

3.1 作業者行動のラベル付け手法の方針

動画とセンサを併用する際に、センサデータを用いて動画のラベル付けを省力化する手法を提案する。これは、製造工程の動画から取得可能な骨格データは、作業員の交差等も含めると欠損が多く、安定した観測が困難なためである。

3.2 作業者行動のラベル付け手法

以下の手順でラベル付けを行う。

(1) 変化点スコアによる動作区間推定

センサから取得される加速度・角速度値に変化点検知手法を適用することで変化点スコアを算出し、動作区間推定を行う。変化点検知には、Change Finder を適用する。変化点スコアの閾値としてポリンジャーバンドを適用し、抽出された変化点から次の変化点を動作区間とする。

(2) クラスタリングによる動作分類

抽出された動作区間毎の特徴量を用いてクラスタリング手法を適用し、動作分類を行う。各動作区間の特徴量（加速度値・角速度値の平均・標準偏差等の 21 種類）について、主成分分析にて次元削減を行い、k-means 法を用いて動作分類する。

(3) 時間補正による基準変化点スコア生成

同じ動作分類の変化点スコアに対して、動的時間伸縮法(DTW)を用いてノイズを除去する。その後、DTW Binary Averaging (DTW-BA) を適用して動作毎の基準変化点スコアを合成する。

(4) 基準変化点スコアへのラベル付け



図1. 実験環境




図2. 動作区間の抽出事例 (被験者 A)

人間が行うラベル付けを最低限に抑えるため、基準変化点スコアへのみ目視でラベル付けを行い、その後、(3)と同様に逆時間補正を行うことで個々のラベル付けを行う。得られた動作ラベルとタイムスタンプを動画に適用する。

3.3 動作推定モデル

動作推定モデルを比較した先行研究¹⁾で精度が高い Multimodal CNN-LSTM & GNN(MuCL-G)を適用する。この動作推定モデルは、センサデータを CNN-LSTM、骨格データを GC-LSTM で処理し統合するアーキテクチャとなる。

4. 検証実験

4.1 実験環境

セル生産を想定した実験環境でデータ収集を行う(図1)。センサデータ収集のため、ERi inc. と共同開発した加速度・角速度センサが内蔵されたスマートタグを用いる。被験者3名がスマートタグを装着し、作業する様子を固定カメラから動画撮影をする。各作業台で3種類の作業を行い、3箇所の作業台を移動するため9種類の動作分類を行う。これを1セット(約240秒)とし、各作業者が10セット実施する。

4.2 作業行動のラベル付け

30セットの実験から得られたデータセットの内、習熟度を考慮し、初めの1セットを除外した27のデータセットに対し、提案手法を用いて動作ラベルを付与する。手順(1)では、変化点スコアの閾値を 2σ とした。その結果、全ての各作業台の3種類の作業が動作区分として抽出された(図2)。また、手順(2)により、抽出した動作区間を2つのクラスタに分類した。これは、同じ作業内容であるが被験者の個人特性や習熟度が影響したものと考察される。次に、手順(3)でDTW距離が大きい場合を除外した後、基準変化点スコアを算出した。手順(4)として




図3. 基準変化点スコアとラベル付け例

表1. 動作推定精度

モデル1:精度(F値)			モデル2:精度(F値)
A	B	C	
0.93	0.88	0.94	0.92

基準変化点スコアに対して目視で3種類の作業をラベル付けした。手順(2)から(4)の一例を図3に示す。

結果として、全ての実験データについて、各作業台での3種類の作業にラベル付けすることが可能であった。

4.3 動作推定

提案手法でラベル付けしたデータセットを用いて、MuCL-Gを適用した動作推定の精度検証を行う。評価指標として、再現率と適合率の調和平均であるF値を用いる。被験者ごとに学習モデルを構築するモデル1と全被験者で学習モデルを構築するモデル2を、リーブワンアウト法を用いて実験する。

実験結果を表1に示す。モデル1およびモデル2ともに、約0.9のF値となった。モデル1の場合は、高精度かつ個人特性の影響があると予想していたが、モデル2でも高い精度を維持している。これは、先行研究¹⁾と同じ水準であり、このラベル付け手法が有効であったと考察される。

5. おわりに

本稿では、センサと動画を併用した動作推定を行う際に、動作ラベル付けを省力化し、生産現場で容易に使用できる作業者の動作推定手法を提案した。また、実験を通じて提案手法の有用性を確認することができた。今後は、異なる粒度の動作分類の検討や実作業現場への適用を行う予定である。

参考文献

- 1) 小村 皓大, 堀川 三好, 岡本 東: センシングデータと骨格データのマルチモーダル学習による作業者の動作推定, 日本経営工学会論文, Vol.74, No.2, pp. 31-39, (2023)
- 2) 株式会社富士通研究所: 時系列データの AI 利用を加速させる自動ラベル付け技術を開発, 2019-5-11, <<https://pr.fujitsu.com/jp/news/2019/05/10.html>>, (参照 2024-01-03)