

# 物流倉庫におけるスマートフォンを用いた作業員のタスク認識

渡邊 企章\*, 加納 一馬, 片山 晋, 浦野 健太, 米澤 拓郎, 河口 信夫 (名古屋大学)

## Task Recognition of Warehouse Workers Using Smartphones

Kisho Watanabe, Kazuma Kano, Shin Katayama, Kenta Urano, Takuro Yonezawa, Nobuo Kawaguchi (Nagoya University)

### 1. 研究背景

産業現場において、労働者の活動を時系列的かつ詳細に認識することは業務効率の評価と改善に繋がる[1]. 特に物流倉庫では倉庫内業務を向上させるために最適な物の配置やタスクの配分を知る必要があり、労働者のタスク分析は重要な役割を持つ。タスク認識のシステムとしては、作業の妨げにならず、コスト面や設備面での導入が容易で継続的に運用可能であるものが要求される。加速度・角速度センサをはじめとする多種多様なセンサを内蔵するスマートフォンは、今や行動認識における主要プラットフォームの1つである[2]. これは軽量で誰でも使いやすく、導入コストも低いという利点を持ち、労働者のタスク認識への応用が期待される。

### 2. 関連研究

スマートフォンを用いた行動認識では、取得した加速度、角速度の時系列データに対して数秒程度のウィンドウをスライドさせ、ウィンドウごとに特徴量を抽出して機械学習モデルを訓練し判別させる方法が主流である。Anguitaらは、30人の被験者の腰にスマートフォンを装着し、1人あたり約6分の歩行や着席、階段の上り下りなど7つの日常動作に対応するデータを集めて特徴量ベースの機械学習を行い、96%の精度での分類を実現している[3]. また、Zhangらの研究では、建設現場の作業員の右腕と左脚にスマートフォンを固定し、類似の手法を用いて、立つ、座るといった基本動作から鉄筋の取り出しや結束といった具体的な作業まで計8つを約90%の精度で分類している[4]. 一方で既存研究においてモデルの評価値として示される正答率は各ウィンドウにおける予測値が多いが、実用に当たっては時系列的に妥当な予測がされているかを評価する必要がある。そこで、本研究では既存研究と同様に特徴量ベースの機械学習で作業員のタスクを予測するモデルを作成するとともに、時系列的に予測結果と正解タスクを比較してその実用性を評価する。

### 3. 提案手法

実験対象は物流倉庫で働く作業員で、分類するタスクは以下に示す3つのタスクである。

1. **Inspecting**: 入荷した商品が注文書や納品書と一致しているかを確認する作業。数量や品目、状態を確認する。
2. **Transporting**: 荷物を乗せた台車を運ぶ作業。
3. **Sorting**: 商品を適切な場所に振り分ける作業。特に荷物を仕分けて台車にまとめたりする。




Fig 1. 作業員の前後方向の加速度とタスクの関係

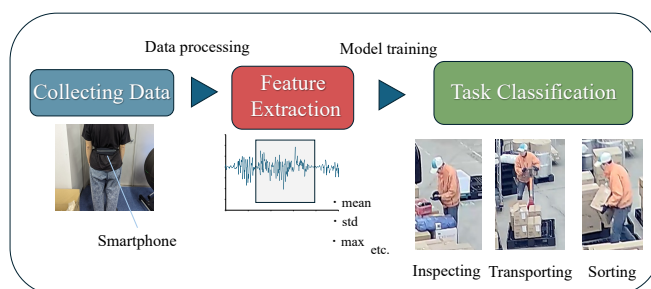


Fig 2.タスク認識のフレームワーク

### 3.1 データ収集と前処理

安定的にデータを取得するためスマートフォンは作業員の腰に固定し、加速度、加速度の重力成分、角速度などを取得して100 [Hz]にリサンプリングしたデータをタスク認識に利用する。加速度については元の値から重力成分と分離したものを計算している。また業務中の様子は天井に複数設置されたカメラによって録画されており、各時刻における正解タスクを把握するために使用する。例として作業員の前後方向の加速度と正解タスクの関係を可視化したものを Fig.1 に示す。

### 3.2 タスク予測モデルの構築

本研究では3軸の重力成分を除いた加速度、重力加速度、角速度とそれらのノルムから特徴量を抽出し、機械学習を用いてタスク認識を行う。全体のフレームワークを Fig.2 に示す。ウィンドウは size=5.12 [s], overlap=50%として、512 サンプルずつ波形を抜き出し、時間領域・周波数領域における特徴量を抽出する。抽出した特徴量は Table 1 に示す。また、倉庫で働く方々の助けを借りて、業務中の様子をビデオと照らし合

わせることで各時刻におけるタスク表を作り、正解ラベルの作成に使用した。3つのタスクに該当しない期間は除外し、各ウィンドウにおける特徴量と正解ラベルを対応付けてデータセットを作成した。本研究では実際の作業員男女4人を被験者とし、作業約1時間分から Inspecting が 1816 個、Transporting が 1424 個、Sorting が 583 個分のデータが収集された。

予測モデルにはロジスティック回帰を使い、データセットを用いて訓練し3クラスの分類を行う。データセットの3つのラベルの比率には偏りがあったため、クラス重み付けを用いて少数データのリコール率が保たれるように学習させる。

### 3.3 評価実験

作成したデータセットを8:2に分けてモデルのトレーニング、テストを行う。また、時系列的な予測に対する評価を行うため、データセットを実際の時系列に沿って並べてモデルへ入力し、予測タスクと正解タスクと比較する。正解データのうち3つのタスクのいずれにも該当しない期間は No label として表す。評価の際は予測、正解ともに1分間の最頻のものをその時刻における代表タスクとして扱う。

## 4. 結果

訓練したモデルのテストデータに対する予測の結果として、混同行列を Table 2 に示す。全体の精度として、Precision, Recall の調和平均である F1-score は 0.83 となった。項目別では Sorting の Precision が 0.71 と最も低い結果となった。

続いて、センサデータを時系列に沿って入力した時の予測タスクと正解タスクについて Fig. 3 に示す。Fig. 3-(a)に示す1人目の予測をみると、タスクの誤認識はあるが長期的に見ると正解に近い出力が得られていると分かる。また Fig. 3-(b)に示す2人目の予測からは、例えば Inspecting が長時間続いているような期間は予測も Inspecting と出力される頻度が高いが、何度か異なるタスクとして誤認識している様子が確認された。現場での運用を考えるとその予測精度には課題が残った。

## 5. 考察

Sorting の Precision が低くなった原因としてクラス重み付けによりデータ数の少ない Sorting を見逃さないため敏感に検知していると考えられるが、これを行わないと Sorting の recall が下がるためより根本的な解決が必要となる。誤認識の原因としては、例えば Sorting に代表される荷物を持ち上げて他の場所に置く動きや、Transporting に代表されるどこかへ歩く動きは他のタスクの中でも数秒、数分単位で発生し得るという点が1つ挙げられる。つまり、認識精度向上のためには動作がどのタスクにおける動作であるかを認識する必要がある。1つの解決策として、分類タスクの階層化が挙げられる。これはセンサデータを使い第一段階で静止、歩行、屈伸など作業員のステータスを抽象度の高いものに分けて、その後時系列的な予測結果と組み合わせでどのタスクにおける動きであったかを認識する手法である。森らの研究[5]では隠れマルコフモデルと動作の階層化を組み合わせで人間の動作の時系列性と階層性を考慮した日常動作の予測モデルを構築しているが、この手法はタスク認識に対しても有効なもの1つであると考えられる。

Table 1 抽出した特徴量の一覧

	Features
Time domain	Mean, Standard deviation, Maximum, Minimum, IQR Sum, Mean absolute change, Energy, Auto regressive, Skewness, Kurtosis
Frequency domain	Bands energy (0-255 Hz divided into 5 bands)

Table 2 予測モデルのテストデータに対する混同行列

True label	Predicted label			
	Inspecting	Transporting	Sorting	Recall
Inspecting	336	24	24	0.88
Transporting	29	214	18	0.82
Sorting	5	14	101	0.84
Precision	0.91	0.85	0.71	0.83

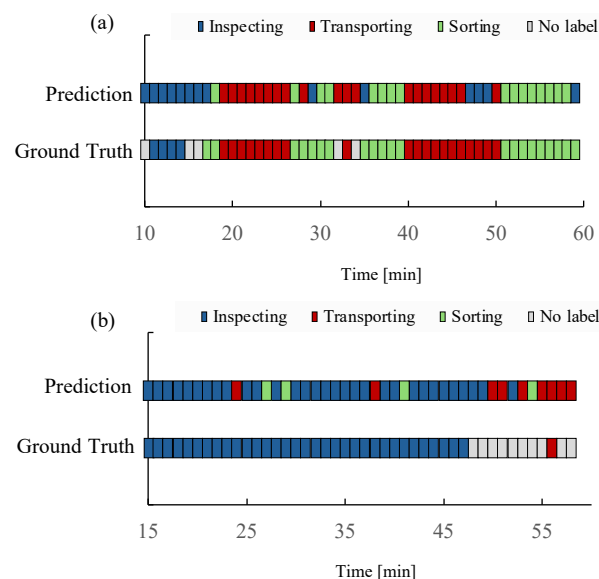


Fig. 3. 予測タスクと正解タスクの時系列的比較  
(a) 1人目 (b) 2人目

## 6. まとめ

本研究では物流倉庫で働く作業員のタスク認識を目的とし、スマートフォンによる加速度・角速度データを用いたタスク認識モデルを構築した。作業員の腰に固定したスマートフォンから収集したデータの特徴量を抽出しロジスティック回帰モデルで訓練した結果 F1-score 0.83 の精度で分類できた。しかし Sorting の Precision が 0.71 と比較的低く、タスク間の類似動作の識別に課題が残った。さらなる精度向上には分類タスクの階層化と時系列情報の活用が必要であると考察された。

**謝辞** 本研究の一部は NICT 委託研究 (22609), NEDO 委託研究 (JPNP23003, JPNP23025), JSPS 科研費 (JP22K18422) のご支援を受けています。また実験環境提供にご協力いただきましたトラスコ中山株式会社に感謝いたします。

## 文献

- [1] T. Stiefmeier, et al.:IEEE Pervasive Computing, Vol.7, No.2, pp.42-50, 2008.
- [2]X. Su, et al.: Tsinghua Science and Technology, Vol.19, No.3, pp.235-249, 2014.
- [3]D. Anguita, et al:ESANN 2013 proceedings, Vol.3, p.3, 2013.
- [4]M. Zhang, et al:MDPI Sensors, Vol.18, No8, 2018.
- [5]森 武俊:日本ロボット学会誌, Vol.23, No.8, pp.957-964, 2005.