

IoT 行動センシングを用いた作業分析技術

Method for Work Analysis Using Human Activity Sensing Based on IoT Technology

兵頭 靖得

小橋 武弘

山中 泰介

■HYODO Yasuyoshi

■KOHASHI Takehiro

■YAMANAKA Taisuke

近年、ウェアラブルデバイスから取得されるセンサデータを分析することで人間の行動、特に個人の行動を理解し、個人にカスタマイズしたサービスを提供する取組みが活発になっている。

東芝は、リストバンド型の加速度センサを用い、広いエリアを動き回る作業でも、作業者の動作を推定して分類し、1日の作業実績を簡単に把握できる技術を開発した。また、動作推定結果と生産管理システムなどのログデータとを組み合わせることで、より深い作業分析を可能にし、作業効率を低下させる要因を推察できるようにした。更に実際の作業を対象とした適用検証により、この技術が業務効率の改善に有効であることを確認した。

In recent years, concrete efforts have been increasingly focused on offering services tailored to individual characteristics acquired through the analysis of human activities using data obtained by Internet of Things (IoT) devices, such as wearable sensing devices.

As part of this approach, Toshiba has developed a technology that uses a wristband accelerometer to easily grasp the daily work performance of individual workers who are moving around a wide area. By enhancing the accuracy of analysis through the collation of evaluation results concerning the workers' movements with log data recorded in the production management system, it has become possible to predict work performance degradation factors. We have conducted verification tests applying this technology and confirmed its effectiveness in improving work efficiency.

1 まえがき

IoT (Internet of Things) やIoE (Internet of Everything) によるセンサネットワークが広がり、多くのモノやヒトにひも付いた情報が大規模に生み出されるようになった。その情報を分析して利活用することで様々な機能やサービスの提供が可能になる。中でもヒトにひも付いた情報を分析することで、人間の行動、特に個人の行動を理解できるようになり、個人ごとにカスタマイズしたサービスが展開できるようになると期待されている。

IoTやIoEによる個人の行動の理解 (IoT 行動センシング) の方法には固定されたカメラやセンサを用いて個人の動きを把握する方法と、ウェアラブルデバイスなどを用いて個人の行動そのものをセンシングする方法がある。ウェアラブルデバイスを用いて行動を推定する技術の研究開発は1990年代から行われているが⁽¹⁾、近年、センサの小型化や通信技術の発達により各方面で実用化の取組みが行われている^{(2), (3)}。その一つとして、生産現場において作業者の行動を、センサを用いて把握しようとする取組みがある。各作業者の行動 (作業実績) を正しく把握することにより作業効率の改善や、作業者の負担軽減、事故の未然防止などのサービス提供に活用できる。

このような背景から東芝は、リストバンド型の加速度センサを用い、広いエリアを動き回る作業において、作業者に負担を掛けることなく、比較的精度良く作業者個々の動作を推定して

分類し、1日の作業実績を簡単に把握して分析できる技術を開発した。

ここでは、今回開発した動作推定・作業分析技術の概要と、実際の業務に適用して作業効率の改善に有効であることを検証した事例について述べる。

2 加速度センサを用いた動作推定

2.1 インダストリアルエンジニアリングにおける課題

インダストリアルエンジニアリング (IE) において、生産現場での人を含めた生産システムの改善のために、ビデオ分析などの手法が一般に用いられる。ビデオ分析は作業者の後に観察者が付いて作業のようすをビデオ撮影し、後から作業内容とその作業に掛かった時間を測定する方法で、詳細な分析ができる反面、一度に多くのデータを取得できないことや、分析に時間が掛かることなどのデメリットがある。逆に毎日の作業者全員の作業時間を収集できる方法として日報の記録を集計する方法がある。OCR (光学文字読取り) 装置などを用いることで、比較的簡単に各作業者がどの作業にどれだけ時間を費やしたかを集計できるが、正確性に劣り、また時間分解能が粗いというデメリットもある。こうした手法の他に、作業者にタブレットを携帯して作業をしてもらい、一定時間おきに、その時点で行っている作業を入力してもらうことで作業実績を把握する方法もあるが、入力のたびに作業を中断する必要があり、作業者の負担が大きい。

当社は、このような課題を解決するためにウェアラブルセンサを用いて作業者の動作を推定する技術を開発した。ここで、作業者が身に着けるセンサの数が多ければ、より詳細な動作推定が可能になるが⁽⁴⁾、作業者の負担が大きくなることや、作業を阻害する可能性が高くなること、導入コストが高くなることなどのデメリットがある。また、装着する箇所も手首や、腕、脚、腰などいろいろあるが、箇所によって認識できる動作が異なる。これらを踏まえ、作業者の負担を抑え、かつ最小限の動作分類を行うためにリストバンド型センサを用いることとした。また、シリコンデバイスのセンサには加速度や、角速度、地磁気、気圧、温度、湿度、紫外線、照度などがあるが、比較的低価格で入手が容易であることを考慮して、加速度センサだけを使用することとした。

2.2 動作推定・分類技術

リストバンド型加速度センサの場合、作業者が手を動かすたびにセンサの向きが変化し、センサの座標軸は地表に対して一定にならない。静止している場合は、測定値は重力と等しいのでセンサの向きはわかるが、動いている場合は、重力に作業者自身の動きによる加速度が重畳され、センサの各軸に掛かる重力成分を正確に把握することは困難である。角速度や地磁気などと組み合わせることで座標軸を補正する方法もあるが⁽⁵⁾、⁽⁶⁾、市販されているリストバンド型センサの多くは加速度だけを取得するものである。そこで今回、作業者の手首に固定されているという制約を利用することで加速度だけで作業者の動作を推定するアルゴリズムを開発した。

手の動きには分類したい動作ごとに特徴があり、それぞれの特徴にはそれを表現するのに最適な特徴量（例えば、合成加速度や、平均、分散など）がある。また、センサが検出した3軸加速度データから、ローパスフィルタによって簡易的に重力成分の分離除去を行う。特徴量は動作ごとに異なるので、分類したい動作に合わせた識別器を用意する。使用した加速度センサのサンプリング周期は約20 Hzで、単位時間の間に取得したデータを用いて特徴量に変換する。単位時間は1秒を基本としている。単位時間ごとに得られた特徴量から推定した動作を作業区間全体で再評価して、その作業区間の動作を最終的に推定する。

2.3 動作分類の実験及び推定精度

物流倉庫のピッキング作業における動作分類を対象に、実験及び推定精度検証を、東芝ロジスティクス(株)と共同で行った。

倉庫ピッキング業務は、指示書に記載されている商品を、台車を手押ししながら収集していく作業である。現場作業IEの観点から、作業を“台車移動”、“歩行”、“手作業”、及び“静止”の四つの動作に分類することとして、2.2節で述べた特徴量を用いることで作業を分類できることを、適合率^(注1)と再現

(注1) その動作であると認識されたデータのうち、実際にその動作であった正しいデータの割合。推測の正しさを表す指標。

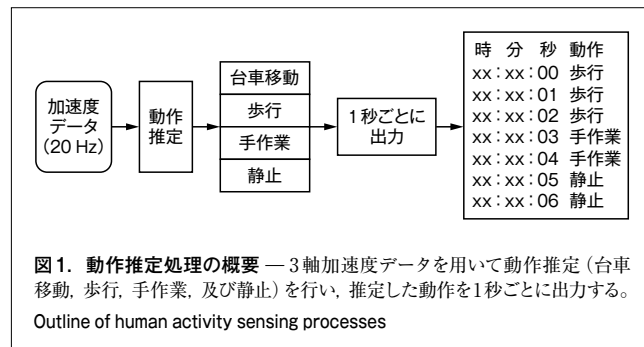


図1. 動作推定処理の概要 — 3軸加速度データを用いて動作推定（台車移動、歩行、手作業、及び静止）を行い、推定した動作を1秒ごとに出力する。
Outline of human activity sensing processes

表1. 動作推定精度
Accuracies of human activity sensing

動作	適合率 (%)	再現率 (%)
台車移動	82	78
歩行	81	72
手作業	89	93
静止	89	90

率^(注2)から検証した。

実験では、作業者8名に加速度センサを装着し、普段どおりの作業を行うとともに、作業のようすをビデオ撮影することで正解データを取得した。

動作推定の処理フローと推定結果の出力形式を図1に示す。物流倉庫内での動作は日常生活とは異なり、同じ動作の継続時間が短く、また、動作の切替わりのタイミングを厳密に定義することが難しいので、推定動作及び正解動作を共に1秒ごとに出力した。

このようにして動作分類を行った推定精度を表1に示す。適合率は4動作全てで80%以上であり、再現率は手作業と静止で90%以上の結果を得ることができた。歩行の再現率は72%とやや低い結果となっているが、これはピッキング業務では数秒の短い歩行が多いことや商品を扱いながらなどの“ながら歩行”が多いことに起因している。

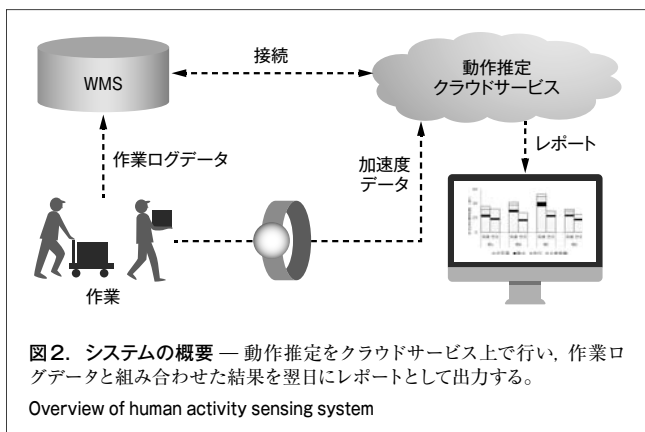
3 行動センシングによる作業分析

ここでは、2章で述べた動作分類を、倉庫ピッキング業務の作業効率の改善に適用した例について述べる。

3.1 データ取得

物流倉庫でのピッキング作業は様々な形状や色彩の商品を認識して把持する複雑な動作の組合せであり、自動化が難しく、いまだに人手に頼った工程となっている。倉庫内でもっとも作業工数が掛かる工程である。2章で検証した動作推定による分類手法を用いて、実現場における業務効率の改善の適

(注2) 該当する動作のうち、その動作であると正しく認識されたデータの割合。網羅性の正しさを表す指標。



用検証を行った。

約2か月間、1日当たり約10名のピッキング作業者にリストバンド型の加速度センサを装着し作業データを取得した。また、作業者はHHT (Hand Held Terminal) を使用して作業を行っており、ピッキング単位作業ごとの作業開始・終了時刻、商品情報、及び棚ロケーションの作業ログデータがWMS (倉庫管理システム) に記録されるので、これらのデータと組み合わせて分析を実施した。

今回の実験に用いたシステムの概要を図2に示す。作業現場の毎日の業務の中でデータの収集と分析を行うために、作業終了後にリストバンド型加速度センサを充電クレードルにセットしたときに、自動的にパソコンを経由してクラウドサービス上にデータが収集され、作業者ごとの動作推定分析エンジンが作動する。また、WMSと接続して作業ログデータを取得し、動作推定結果と作業ログデータを組み合わせて翌日にレポートを出力し、現場マネージャーに分析フィードバックするよう、システムを構成した。

3.2 データ分析

3.2.1 想定処理時間とのギャップ分析 まず、ピッキング単位作業当たりの平均処理時間と想定処理時間を比較した。ここで、想定処理時間はPTS法^(注3)に基づいて算出した値である。平均処理時間と想定処理時間を棚ロケーション別に並べて比較し、更にそれぞれの処理時間を動作の内訳に分類した結果を図3に示す。実績の動作の内訳は2章で述べたように加速度センサを用いて推定した結果である。図3から、棚Cからのピッキングにおいて実績時間と想定時間とのギャップが大きいことがわかる。そこで、棚Cの処理時間について実績時間の動作の内訳を分析すると、静止の時間が他の棚と比べて長いことがわかる。このデータから得られた気づきを基に、実際に現場状況を確認したところ、商品の確認に時間が掛かるような商品配置になっていたことが判明した。

(注3) 人が行う作業を“手を伸ばす”、“つかむ”などの基本動作に分解し、更に手を伸ばす距離やつかむ対象物の大きさ、重さなどに応じた標準作業時間をあらかじめ設定しておき、その組合せによって作業時間を想定して分析する手法。

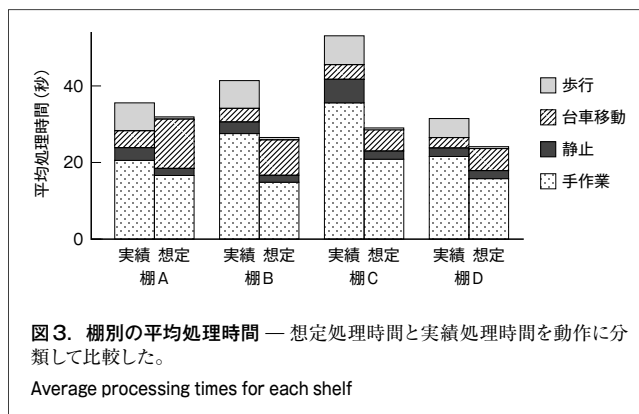


図3. 棚別の平均処理時間 — 想定処理時間と実績処理時間を動作に分類して比較した。

Average processing times for each shelf




図4. 棚Cにおける処理時間の改善効果 — 棚Cの商品配置を見直すことで、ピッキング処理時間を15%削減できた。

Average picking times before and after rearrangement of merchandise to be picked

この分析結果から棚Cの商品配置の見直しを行い、商品配置見直し前後の平均処理時間を検証した。比較結果を図4に示す。台車移動や歩行などの移動時間は直前のピッキング位置に依存するので、静止と手作業だけで比較すると、商品配置を見直すことで処理時間を15%削減できたことがわかった。

3.2.2 棚段別の平均処理時間 データを更に詳細に分析した結果、棚段により平均処理時間に違いがあることが見いだされた。比較結果を図5に示す。もっとも高い位置にある下から5段目の平均処理時間は1~4段目と比べて約1.5倍掛かっており、増加分の約80%が静止と手作業の増加によるものと分析される。この差異の主要因として、身長が低い作業員が背伸びをして作業を行っていることが原因と推測された。そこで、作業員の身長との相関を調査したところ、図6の

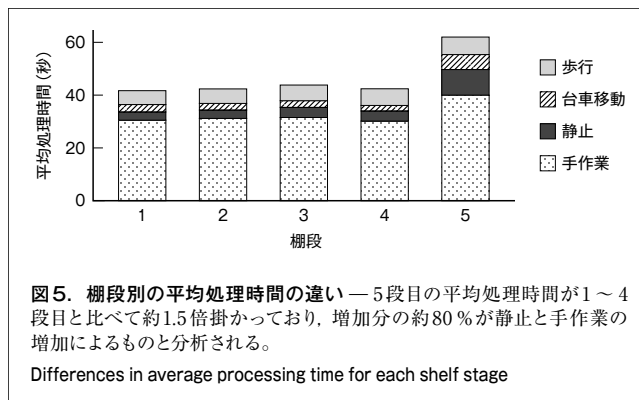


図5. 棚段別の平均処理時間の違い — 5段目の平均処理時間が1~4段目と比べて約1.5倍掛かっており、増加分の約80%が静止と手作業の増加によるものと分析される。

Differences in average processing time for each shelf stage

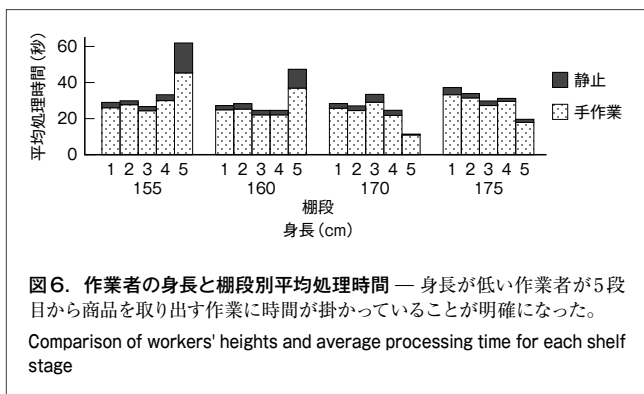


図6. 作業者の身長と棚段別平均処理時間 — 身長が低い作業者が5段目から商品を取り出す作業に時間が掛かっていることが明確になった。
Comparison of workers' heights and average processing time for each shelf stage

ように身長が低い作業者が5段目から商品を取り出す作業に時間が掛かっていることがわかった。これらの分析結果に基づき、出荷頻度が高い商品は高段に置かないことや、高段を補充品置き場とすることなどを改善項目として抽出できた。今後、これらの改善策を実際に作業現場に適用し、その効果を検証する予定である。

3.3 適用検証における考察

今回、静止の時間に注目して商品の配置に改善の余地があることに気づき、見直しなどの施策を通して業務効率の改善にフィードバックできることを確認した。また、棚段別の処理時間を比較することで、高段からの商品取出しは下段より時間が掛かることを定量的に確認でき、更にその原因が作業者の身長と関係していることがわかった。

ビデオ分析などのスポット分析では、データ取得人数に限られるので作業者の属人性の影響を受けたり、観察者が付き添うことで普段の作業ペースと異なるデータが得られたりする懸念があるが、加速度センサを用いることで、データ数増加により全体のトレンドが把握でき、観察者の影響も排除できる。

また、作業ログデータだけを用いても商品や、棚ロケーション、棚段など細かい項目ごとにピッキングに掛かった時間を集計することはできる。しかし、これだけでは特定の項目で時間が掛かっていることはわかっても、その原因はわからない。それに対し、動作分類・推定結果と組み合わせることで、例えば、台車移動の時間が長い場合は、棚への移動を阻害する何かが経路上にあるかもしれないこと、歩行の時間が長い場合は、棚へ行った後どこか他の場所に行く必要があるのかもしれないこと、手作業の時間が長い場合は、商品の置き方が原因で取り出しづらいのかもしれないことなど、原因をある程度推察できることが確認できた。

4 あとがき

リストバンド型の加速度センサを用いて作業者の動作を推定する技術を開発した。また、東芝ロジスティクス(株)と共同で約2か月間実際の業務に適用し、動作推定結果とWMSな

どの作業ログデータとを組み合わせることで、作業効率の低い項目について、その理由を推察できることを確認した。

短期間のスポットデータではその期間の作業内容に依存した結果となるが、日々の作業実績を作業者に負担を掛けずに継続して取得することにより、施策を行い業務効率が改善された後もその効果が継続しているかをチェックできる。また、作業者の日々の成長を見える化することもでき、作業者一人一人に適切な指導を行うことが可能になる。

他にも、ウェアラブルデバイスをクレードルから外した時刻を出社時刻、クレードルに戻した時刻を退社時刻として記録することで勤務時間管理に用いることなどの応用も考えられる。

今回の作業分析実験は物流倉庫の台車ピッキング作業を対象にしたが、フォークリフト作業や梱包(こんぼう)作業などの物流倉庫内の他の作業や製造業への適用も検討を進めている。

加速度データは簡便に動作推定できる一方、利用範囲が限られているので、今後はビーコンなどの他センサとの適切な組み合わせにより、現場作業に即した動作推定技術の開発も進めていく。

文献

- (1) Foerster, F. et al. Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring. *Computers in Human Behavior*. 15, 5, 1999, p.571-583.
- (2) 大内一成 他. スマートフォンを用いた生活行動認識技術. *東芝レビュー*. 68, 6, 2013, p.40-43.
- (3) 村上知子 他. センサデータと業務知識からのトピックモデルを用いた看護業務行動の推定. *人工知能学会論文誌*. 29, 5, 2014, p.427-435.
- (4) Bao, L.; Intille, S. S. "Activity Recognition from User-Annotated Acceleration Data". *Proceedings of the Second International Conference on Pervasive Computing (PERVASIVE 2004)*, LNCS 3001. Linz and Vienna, Austria, 2004-04, Johannes Kepler University Linz and Austrian Computing Society. 2004, p.1-17.
- (5) Lefferts, E. J. et al. Kalman Filtering for Spacecraft Attitude Estimation. *Journal of Guidance, Control, and Dynamics*. 5, 5, 1982, p.417-429.
- (6) Madgwick, S. O. H. et al. "Estimation of IMU and MARG orientation using a gradient descent algorithm". *2011 IEEE International Conference on Rehabilitation Robotics (ICORR 2011)*, Zurich, Switzerland, 2011-06 to 07, IEEE. 2011, p.1-7.



兵頭 靖得 HYODO Yasuyoshi

インダストリアルICTソリューション社 IoTテクノロジーセンター ディープラーニング技術開発部主務。ウェアラブルデバイスを用いた行動推定技術の開発に従事。

IoT Technology Center



小橋 武弘 KOHASHI Takehiro

インダストリアルICTソリューション社 IoTテクノロジーセンター ディープラーニング技術開発部。センサデバイスを用いたIoTデータ分析・利活用フレームワークの設計・開発に従事。

IoT Technology Center



山中 泰介 YAMANAKA Taisuke

インダストリアルICTソリューション社 IoTテクノロジーセンター ディープラーニング技術開発部参事。IoTデータ業務活用のための分析技術の開発及びフレームワーク構築に従事。

IoT Technology Center