

機械学習を用いた建設現場の労働環境・生産性データ収集分析システム構築に用いる各種端末開発

助成研究期間：2021 年 10 月 1 日～2025 年 3 月 31 日

五艘隆志¹・武藤一伸²

¹ 東京都市大学建築都市デザイン学部都市工学科・准教授

² 大成ロテック株式会社技術本部技術部技術指導室・課長代理

研究要旨 本研究では加速度計を用いた HAR (Human Activity Recognition) 手法と深層学習を組み合わせることで、建設現場作業員の従事している作業を大局的に把握するシステムの開発を行った。ヘルメットに装着した加速度計から得たデータを画像化するプロセスを構築し、これを CNN (Convolutional Neural Network；畳み込みニューラルネット) によって特徴抽出を行い、作業員の従事する動作の種別を分類する深層学習モデルを得た。これによる歩行の有無と前傾姿勢の判別については本モデルによってそれぞれ 80.0%と 92.1%の正解率となった。また、最終的な生産性動作判別システムとしてはアンサンブルを行うシステムの設計を行った。その後、研究フィールドとなった舗装工事を対象とした特有の機械や作業員の動作を考慮したシステムの改良も行った。併せて、このシステムの入力値となる位置情報、加速度情報、温度情報を統合分析するための端末開発の準備段階として、複数の別種の市販端末から得られる情報を時刻歴にて一元化する分析支援アプリケーションの開発を行った。さらに、これら端末のデータ記録開始・終了操作をスマートフォンにて一元的に行うアプリケーションの開発を行った。

1. 目的

本研究は既存のワークサンプリング手法による生産性情報の把握を、センシング技術を用いた HAR (Human Activity Recognition) 手法と深層学習を組み合わせることで、建設現場作業員の従事している作業状況を自動的かつ定量的に把握することを目的とする。これにより得られたデータと実際の現場の状況把握によって、工程や動線の問題抽出と見直しや、新工種などの導入効果を統計情報に基づいて定量的に示すことができる「生産性向上とワークフロー改善のためのツール」の基盤とすることを目指すものである。また、頭部を中心にセンサを配置するため、労働災害の防止や事故時の早期対応などへの活用ができるような情報の収集を包括的に行える労働安全管理システムとしての基盤としても期待できるものである。

前者の生産性向上ツールとしては、人手を介さず自動的で一定の精度かつ継続的にデータを収録

することが必要である。取得するデータは、現場作業員が各作業に従事した時間の長さ、作業場での移動などの位置情報、ヘルメットに装着した IMU (慣性計測ユニット: Inertial Measurement Unit) によって計測される加速度などである。本研究ではこれらのデータから深層学習によって作業員ごとの作業環境や労働強度、建機との近接・落下事故の予防、生産性低下要因の抽出などの直接的に改善可能な項目を判別できるシステムの開発を行う。

2. 対象とした工種・職種

本研究では作業員が時間経過と共に一定方向に展開しながら作業を行う屋外の舗装工事を対象とした。後述する既往研究では建築工事を含めた建設工事全体を対象としてデータ取得を行っていたが、例えば建築工事では工種が極めて細分化し、職種ごとの動作状況が異なるだけでなく、各職種

の出入り（ある職種は1日だけしかいないなど）も激しいため、作業員の動作の一貫性も乏しいというデータ集計上の困難さがあった。また、トンネル覆土工事ではGNSSが使えないため位置情報が困難であることと、作業領域が狭いために人手によるワークサンプリング取得が難しいという課題があった。

この点、屋外の舗装工事は、ベースペーバによる舗装材の敷均し、振動ローラとタイヤローラによる転圧作業からなる繰り返し作業を行う。また進行速度がゆるやかであり、屋内の施工などと異なり頭部付近に障害物が存在しない。このことからイレギュラーな加速度検知が比較的少ないと予測される。さらに、作業員の職種ごとに重機操作・レーキによる圧密・スコップ等の使用など作業内容が異なり、職種ごとの動作分析の簡便性も期待されることからこれを採用した。

また、舗装工事においては路盤工・基層工ともに一方向へ建設機械を移動させながら、進行方向側から資材を投入し、建設機械の後方から道路が形成されていく。舗装工事の一連の流れにおける職種として、建設機械（ベースペーバ、振動ローラ、タイヤローラ）の運転者のほかに、ベースペーバの側方機械を操作するオペレータ補助者、敷き均した材料を適切に調整する作業員など複数の作業に応じたものが存在する。データサンプリングに際してはこれらすべての職種を対象にサンプリングを行った。

3. 既往研究

本研究では作業員が時間と共に一定方向に展開しながら作業を行う屋外の舗装工事を対象とした。後述する既往研究では建築工事を含めた建設工事全体を対象としてデータ取得を行っていたが、例えば建築工事では工種が極めて細分化し、職種ごとの動作状況が異なるだけでなく、各職種の出入り（ある職種は1日だけしかいないなど）も激しいため、作業員の動作の一貫性も乏しいというデータ集計上の困難さがあった。また、トンネル覆土工事ではGNSSが使えないため位置情報が困難であることと、作業領域が狭いために人手によるワークサンプリング取得が難しいという課題があった。

この点、屋外の舗装工事は、ベースペーバによる舗装材の敷均し、振動ローラとタイヤローラによる転圧作業からなる繰り返し作業を行う。また進行速度がゆるやかであり、屋内の施工などと異なり頭部付近に障害物が存在しない。このことからイレギュラーな加速度検知が比較的少ないと予測される。さらに、作業員の職種ごとに重機操作・レーキによる圧密・スコップ等の使用など作業内容が異なり、職種ごとの動作分析の簡便性も

表-1 建設現場における生産性動作の区分とその構成要素

生産性区分	作業構成要素区分
① 直接生産動作 (Direct Work)	① 直接生産動作 (Direct Work)
② 補助支援動作 (Support)	②-1 図面や指示の確認動作(Read Plans/Instruction) ②-2 作業員自身の移動動作(Travel) ②-3 資器材の運搬動作(Transportation) ②-4 工具・材料の準備動作(Tools/Materials)
③ 作業遅延動作 (Delay)	③-1 作業開始遅延/切上終了(Late Start/Early Quit) ③-2 待機(Waiting) ③-3 個人的理由での作業遅延(Personal) ③-4 定められた小休止・休憩(Break)

期待されることからこれを採用した。

また、舗装工事においては路盤工・基層工ともに一方向へ建設機械を移動させながら、進行方向側から資材を投入し、建設機械の後方から道路が形成されていく。舗装工事の一連の流れにおける職種として、建設機械（ベースペーバ、振動ローラ、タイヤローラ）の運転者のほかに、ベースペーバの側方機械を操作するオペレータ補助者、敷き均した材料を適切に調整する作業員など複数の作業に応じたものが存在する。データサンプリングに際してはこれらすべての職種を対象にサンプリングを行った。

(1) 建設産業における標準的な生産性管理データの収集方法とワークサンプリング手法

我が国における建設工事の歩掛調査や労務費調査は（一財）建設物価調査会などに代表される調査団体が各省庁、地方公共団体、独立行政法人、事業団等の発注者組織から受託されて実施している。手法としては印刷された調査票を作成し、工事受注者に配布・回収する形でデータの収集が行われている。受注者は歩掛調査の対象現場の施工数量、作業員の人数、職種、就業時間数、使用機械器具の台数と使用時間数などの項目を調査票の様式に従い記録を行っている。これは各現場の労働環境や物的生産性（作業歩掛）の実態把握を行うものである。

一方で、米国を中心として1980年代からワークサンプリング調査による建設作業員の生産性管理データの取得の取り組みが行われている。調査員が現場を巡回して各作業員の動作状況をあらかじめ定めた種類に分類し、現場ごとの特性や、時系列の変化を捉えようとするものである。この手法自体は我が国の製造業などにも広く導入されている。草柳¹⁾はワークサンプリング調査に先立ち、表-1に示すような建設現場作業で採取されたサンプルを分類する作業動作区分を設定した。「直接生産動作」とは生産性に直接結びつく作業動作である。「補助支援動作」は生産性には直接結びつ

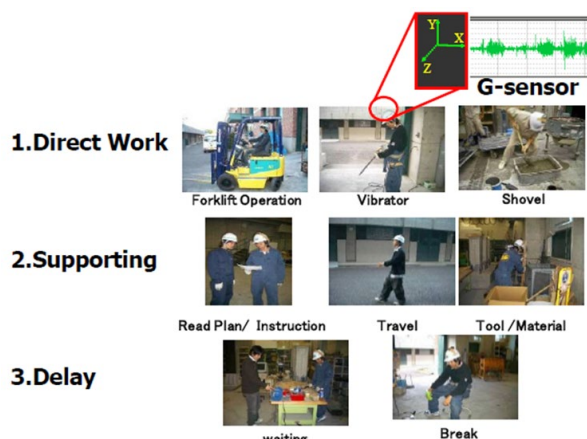


図-1 建設現場における生産性動作の区分のイメージ

かないが、直接生産動作を補助・支援するための動作である。「作業遅延動作」は直接生産動作や補助支援動作の進行を阻害し、遅延させる動作を指している。このイメージを図-1に示す。

しかし、人の目視により作業状況を把握する本手法は多くの時間を要すること、専門的知識が必要になること、人力的コストがかかること、日々の業務内容や人員が変わる建設現場への適用性という点から、建設現場において日常的に活用する管理方法として現実的ではなく、そのことがこの手法が我が国建設業において展開されない原因となっているものと考えられる。

(2) 建設業における動作把握・モニタリング手法

建設分野における国内外のモニタリングシステムについては、手法と目的の違いによって分類ができる。モニタリングの手法については、「映像による認識 (computer vision-based methods)」「音による認識 (audio-based methods)」「運動による認識 (kinematic-based methods)」の3種類である。運動による認識についてはウェアラブルセンサによるサンプリングや位置情報による動線把握などが主である。目的については「労働安全」と「無人運転」に関わる現場全体の把握を行うためのモニタリングシステム構築の傾向がみられた。

特に国内での事例について、ウェアラブルセンサの活用事例としては、作業員に取り付けた加速度センサを用いて、鉄筋の巻き立て作業のみをサンプリングすることで、作業員が鉄筋の巻き立て作業とそれ以外の動作を行っているかを高精度で検出する取り組み²⁾が存在する。

映像分析手法については、定点カメラから撮影した映像で資機材の物体検知を行い、資材の重量や位置情報と統合して出来形を推定し、物的労働生産性を計測する取り組み³⁾がある。

また、GPS等の位置情報を3DCADモデルと統合することによって作業員とクレーンとの接近状況

を検出し、労働災害が起きる危険がある場合にそれをアラートするシステム⁴⁾なども存在する。

こういった建設業での現場モニタリングならびに動作把握事例は i-Construction の潮流から多様な方法で実施されているが、生産性向上のための大局的な現場のモニタリングについては事例が少なく、さらなる発展が求められている。

(3) 生産性動作分類システム開発の経緯

a) 五艘らによる ZigBee を用いたシステム

本研究の基盤としてシステム構築を試みた五艘ら⁵⁾⁻⁸⁾は3軸加速度計と ZigBee を用いた専用端末を開発し、併せて生産性区分の判別基準プロトタイプ of 構築を行った。作業員に装着した加速度センサから得られたセンシングデータより振動パターンを解析し、生産性区分に分類を行っていた。課題としては生産性区分判別基準のプログラム化や機器の小型化と価格の低減ということが残されていた。

b) 大澤らによる事前分類と機械学習の組合せによる生産性動作分類システム

大澤ら⁹⁾⁻¹¹⁾は、作業員に市販の3軸加速度計、GNSS センサ、温湿度計を装着し、加速度情報データと位置情報データを組み合わせてデータを統合し、これを SVM (Support Vector Machine) や FFT 解析等によって、変動や周期性の有無などの個別の設定基準の2値比較を組み合わせることで生産性動作を分類する取り組みの枠組みを構築した。これにより、加速度データおよび位置情報を活用することによって一定の精度で生産性動作を分類することができることが確認された。しかし、このシステムにおいては手作業によって各動作区分の判別処理を行う際の閾値を設定しなければならないこと、またその閾値設定などの基準に測定者の主観が混在してしまうため、他の工種や、同工種であっても条件が異なる現場などでの適用が難しいといった課題が残されていた。また一定時間の加速度データをラベルと紐づけるために平均や分散など統計的に処理することで時系列情報を保持できないという問題も提起されていた。

(4) 他分野における HAR (Human Activity Recognition) に関する研究¹²⁾⁻⁴⁹⁾

HAR (Human Activity Recognition) は、人間の行動を自動的に検知し、分類する技術の総称である。この分野は、センサデータやビデオ映像などから得られる情報を活用し、人が行うさまざまな活動や動作を識別することを目的としており、ヘルスケア、スポーツ、セキュリティ、およびユビキタスコンピューティングなどの多岐にわたる応用分野で活用されている。

HAR の基本的なアプローチは、機械学習やパターン認識などである。これらの手法では、セン

サが捉えたデータから特徴を抽出し、それを学習アルゴリズムに供給することで、モデルが異なる活動を区別できるようになる。従って、大規模なデータセットや適切な特徴量の選択が、HARの性能向上に寄与する重要な要素となる。HARにおいては3D空間での動きや方向の変化をより正確に捉えるため、加速度計やジャイロスコープ、磁気センサなどの複数のセンサを組み合わせ使用することが一般的であるが、昨今の研究では単一のIMU (Inertial Measurement Unit) や統合端末を用いた事例も多く存在する。

また、2010年以降の研究では、ディープラーニングや畳み込みニューラルネットワーク

(CNN)、リカレントニューラルネットワーク(RNN)などの深層学習手法が適用され、複雑な活動パターンの抽出や変動に対する堅牢性の向上が図られている。これにより、リアルタイム性の高い活動認識が可能になり、ユーザビリティの向上や安全性の向上に寄与している。具体的な例として、スポーツ領域ではイングランドプレミアリーグの選手のシューズに取り付けたトラッキングデータとサッカーボールの軌跡データ、定点映像を組み合わせ選手の活動認識モデルを作成することで、パスの回数やシュートの回数やその時の運動強度、ボールの位置に応じた選手の位置取りなど集団の動き(イベント)を高精度で検出できることが報告¹⁶⁾されている。

また、ブレイクダンスを対象に、加速度計を組み込んだ靴によって自然な環境下でのダンス動作を自動的に判別・可視化し、17種類の動作で分類し、そのダンス全体のオリジナリティーを評価しダンサーにフィードバックするといった取り組み¹⁷⁾も報告されている。

介護分野におけるHAR研究事例としては、主にリハビリテーションや高齢者ケア、院内事故防止のための監視を目的とした動作認識などが主となっている。HAR基礎研究としてバングラデシュでは、スマートフォンに搭載されたIMUで取得したデータを深層学習手法(CNN-LSTM: Convolutional Neural Network with Long Short-term Memory Recurrent Neural Network)を用いて、医療データの一元管理システムであるmHealthデータと紐づけて動作認識を高精度で行う事例¹⁸⁾が報告されている。

セキュリティ領域では不審な行動の検知に利用されている。今後の研究では、より多様で複雑な状況における高度な活動認識技術の開発が期待されている。

(5) 深層学習を用いた時系列データ分類に関する研究

大澤らのシステムでは、加速度データの時系列情報が保持できないことが課題点の一つとして挙

げられており、時系列情報を保持したまま一定の時間幅で生産性動作の正解データと紐づけることが求められた。そのため、本研究では時系列情報を保持したまま分類が行える深層学習手法としてCNN, LSTM, Transformer, GBDT(勾配ブースティング決定木: Gradient Boosting Decision Tree)などの検討を行った。前節で取り上げたバングラデシュの事例も該当するが、CNNやLSTMは3軸加速度と時間情報を同時に扱う上で必要となる多次元情報処理に不可欠なテンソル演算が容易であることから加速度計を用いたHARで盛んに活用されている。この特性から本研究ではCNNおよびLSTMのアルゴリズムを使用することとした。

a) CNN (Convolutional Neural Network) の概要

畳み込みニューラルネットワーク

(Convolutional Neural Network, CNN)は、画像認識やパターン認識などのタスクで高い性能を発揮する深層学習モデルの一種であり、特に画像処理分野での革新的な進展に寄与したアルゴリズムである。

基本的な構造は、畳み込み層 (Convolutional Layer)、プーリング層 (Pooling Layer)、全結合層 (Fully Connected Layer) から構成される深層学習モデルであり、畳み込み層が画像の特徴を抽出し、プーリング層が特徴のサイズを削減することで計算効率を向上させ、最終的に全結合層がクラス分類を行う。畳み込み層では、入力データに対して畳み込み演算が行われる。畳み込み演算は、カーネルまたはフィルターと呼ばれる小さな重み行列が入力データに適用され、新しい特徴マップが生成される。畳み込み演算は以下の数式で表される。

$$S(i,j) = (I * K)(i,j) \\ = \sum_m \sum_n I(m,n) \cdot K(i-m, j-n)$$

ここで、 $S(i,j)$ は出力の特徴マップの要素、 I は入力データ、 K はカーネル行列である。畳み込み演算は、入力データ全体に対してフィルターをスライドさせながら適用され、新しい特徴マップが生成される。

また、プーリング層は、畳み込み層で得られた特徴マップのサイズを削減し、計算を効率化するために使用される。代表的な手法であるマックスプーリングは、特定の領域から最大値を取り出して新しい特徴マップを生成する。マックスプーリングの数学的表現は次のようになる。

$$P(i,j) = \max_{m,n} S(i \times s + m, j \times s + n)$$

ここで、 $P(i,j)$ はプーリング層の出力の要素、 S は前の畳み込み層の出力、 s はストライドである。プーリング操作により、特徴の空間的な情報を保持しながら次元を削減し、計算効率を向上させることができる。

畳み込み層とプーリング層の後には、全結合層が続く。全結合層では、前の層のすべてのユニットが次の層の各ユニットと結合され、最終的な出力が生成される。通常、ソフトマックス関数が用いられ、クラス分類の確率分布を得ることが目的とされる。

$$y_k = \frac{e^{z_k}}{\sum_j e^{z_j}}$$

ここで、 y_k はクラス k への確率、 z_k は入力ベクトルに対するクラス k のスコアである。ソフトマックス関数により、ネットワークは入力データが各クラスに属する確率を出力する。

b) LSTM (Long Short-Term Memory) の概要

また、LSTM (Long Short-Term Memory) は、時系列データの処理において長期的な依存関係を捉えるために開発されたリカレントニューラルネットワーク (RNN) の一種である。LSTM は、通常の RNN が直面する勾配消失問題 (Vanishing Gradient Problem) を緩和し、長期の依存関係を効果的に学習できる構造を持つ。

基本的な構造は、セル状態 (cell state) とゲートと呼ばれる情報の流れを制御する仕組みから成り立つ。

まずその時点におけるデータを受け取る入力ゲートは

$$i_t = \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi})$$

$$\tilde{C}_t = \tanh(W_{ic}x_t + b_{ic} + W_{hc}h_{t-1} + b_{hc})$$

で表される。ここで i_t は入力ゲートの出力、 x_t は入力、 h_{t-1} は前の時刻の隠れ状態、 W は対応する重み行列、 b はバイアス項である。また、 σ はシグモイド関数、 \tanh はハイパボリックタンジェント関数である。

そして忘却ゲートは f_t を出力として次のように表される。

$$f_t = \sigma(W_{if}x_t + b_{if} + W_{hf}h_{t-1} + b_{hf})$$

これらの情報からセル状態の更新を次のように行う。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$

そして最終的な出力は次を得る。

$$o_t = \sigma(W_{io}x_t + b_{io} + W_{ho}h_{t-1} + b_{ho})$$

$$h_t = o_t \cdot \tanh(C_t)$$

ここで、 o_t は出力ゲートの出力、 h_t は LSTM の最終的な出力である。ハイパボリックタンジェント関数で活性化し、それに出力ゲートの出力を適用することで、最終的な隠れ状態が得られる。LSTM はこれらのゲートメカニズムによって、長期的な時系列データの依存関係を捉え、勾配消失問題を軽減することができる強力なモデルとなっている。

本研究では後述の方法によって 3 軸の加速度を画像化することで CNN ならびに CNN+LSTM を用いて時系列情報を保持したまま加速度による生産性動作分析を行うシステムを構築した。

4. 建設現場特有の作業データ取得と教師データ作成について

(1) 現場におけるデータ取得環境

舗装工事を対象にデータサンプリングを行った。センサの装着や実際のサンプリングの様子を図-2～図-4 に記す。基本的な流れは以下の通りである。なおこれらの手順は複雑であり、データ取得の失敗も少なくなかったため、最終的には 6 章 (4) に述べる Android アプリケーション構築に至った。

- ・ 現場に入り、加速度センサとスマートフォンの電源を入れ、時刻合わせをする
- ・ 加速度センサとスマートフォンを Bluetooth 接続する
- ・ 加速度センサの付属アプリにて加速度が取得できているかどうかを確認
- ・ スマートフォン側の GPS 機能の起動確認
- ・ GPS データの取得・保存可否の確認
- ・ 加速度センサと GPS のロガーアプリの起動
- ・ 作業員にデータ取得の趣旨を説明 (労働監視目的ではないことを重点的に)
- ・ 各作業員 (5 名程度) のヘルメットを借り、加速度センサをガムテープにて装着 (図-2 の状況)
- ・ ガムテープは作業員の識別を容易にするため、複数色準備しておく
- ・ 各作業員にスマートフォンの携帯も併せて依頼 (図-3 の状況)
- ・ 作業開始後は、図-4 のように、調査者が担当する作業員の作業状況をビデオ撮影する (当日の作業終了後に、教師データとしての人手によるワークサンプリングを行うため)

特に路盤工や基層工の組合せ施工を取扱い、重機作業者とそれ以外の作業者が同一方向に進み、相対的な位置関係が維持されるように撮影上の配慮を行い、作業データを取得した。これは既往の HAR の判別項目に代表される基本動作の「立つ」「座る」「歩く」「走る」がある程度認められる工種であることのほか、トンネルや山岳部でなければ、位置情報を衛星情報などで取得可能であるという点から決定した。

サンプリングに使用したデバイスは 3 軸加速度計を有する IMU として WT901BLECL (Shenzhen Wit Intelligent Co., Ltd.)、そしてそのデータロガーとして moto e7 (Motorola Mobility LLC.) を使用した。また本研究では活用に至らなかったが、労働安全管理システムへの適用を見据えて IBS-TH2 PLUS (Shenzhen Inkbird Technology Co., Ltd.) によ



図-2 ヘルメットへのセンサ類装着及び Bluetooth での接続状況



図-3 作業員のセンサ類装着状況




図-4 作業状況と撮影状況

って温湿度のデータも同時に取得を行った。ヘルメットへの機器の装着に伴って 82g 程度重量が増加するが、これは現場で標準的に使用されているフェイスシールド付きのヘルメットやヘッドライトが通常のヘルメットより 100~120g の重量増加になることと比較しても、作業に多大な支障をき

たさない範囲であると判断して装着を行った。なお、装着にあたっては左右の偏差が生じないように頭頂部や後頭部に固定することで着用時に違和感が無いように配慮した。

IMU のサンプリングレートは 50Hz で設定し、1 秒間に X, Y, Z の各軸方向の加速度を 50 データ取得できるように設定した。IMU による加速度の取得に併せて教師データのラベル作成の為に 1 秒間ずつの行動をマニュアルサンプリングによって記録した。正解ラベルは後述の 5 項目の単純動作について作成した。

(2) 建設現場特有の動作と生産性動作区分

既往の HAR 分野における基礎研究では、「立つ」「座る」「歩く」「走る」など単調で継続的な動作の分類が主となっている。しかし、本研究で対象とする舗装現場での作業は、そういった基本動作を多く有するものの、多岐にわたる建設現場の工種・作業においてそれぞれが複合的な動作となっており、既存の方法のままでは特徴が抽出しづらい。例えばレーキによる作業は、加速度計を用いた既存の HAR 手法では「歩行」やその一部として検出可能な項目であるように見えるが、実際にはレーキの使用者の体格や使い方の癖、ひいてはレーキを使用しているも単一の振る舞いをするわけではないため「歩行」の学習だけではこの作業を十分に分類できない。くわえて、「歩行」などの単純動作だけに焦点を当てると、歩行を伴う整地作業（歩行あり/作業あり）と重機を操作して土を敷き均す作業（歩行なし/作業あり）と現場から事務所への移動（歩行あり/作業なし）のように直接生産性に寄与する動作とそうでない動作を明確に区分することが難しい。

そのため判別の詳細度によらず、建設現場作業においては既存の HAR で行われているような単純な動作をそのまま表-1 に示した既存の生産性動作区分 3 項目とそれを構成する作業構成要素区分 9 項目に結び付けることは適切ではないと考えた。

(3) データ作成にかかわる課題と本研究における動作の定義

a) 大澤の分類

大澤の先行研究では動作を草柳の生産性動作判別に合わせるために、複数の数学的手法を組み合わせることで最終的な生産性動作区分に適切に分類されるような設計であった。分類に使用された特徴量は「変動の有無」「定常性の有無」「加速度の平均値」「加速度の標準偏差」「姿勢角（ピッチ角）」「加速度の FFT 解析」となっておりそれぞれ高精度となるように各データ算出の為に閾値の設定を都度行う必要があった。また、この方式はほぼ同一の振る舞いをした作業員であって

もその職種によって判別基準を変更しなければならず、その基準は観測者の主観によって判断をせざるを得ないため一定の基準で安定して精度を確保するのが困難であった。

b) 5種類の単純動作の組み合わせ

本研究では五艘ら、大澤らの研究にて構築された生産性動作判別システムの課題を解決する為、時系列の情報を保持し、可能な限り自動的かつ判別処理における主観的な判断を排除することで一定の信頼性を確保することを目指した。

しかし主観性の混在は、教師データ作成に際して「その動作が生産性動作区分のどの項目に該当するか」を判断するうえではある程度避けられないものであったため、教師データ作成時に撮影した映像を基に建設現場作業に共通する動作特徴を分析することである程度客観的な情報によって主観による影響を低減することを試みた。撮影した累計 60 時間超の映像には、路盤工と基層工の 2 つの工種が含まれるが、いずれにも共通し、また他の工種にもある程度適用可能な範囲で動作特徴を捉えるため、生産性動作区分に準拠しつつ、単純な動作に焦点を定めた。

まずは職種に依らず、「作業の有無」と「歩行の有無」でのみ動作を捉えた。作業を行っているかどうかについては生産性動作区分に則った基準に準拠しつつも、主観的にその結果を判断することとなるが、それに加えて原則として上肢、上体が一定以上の動きを有しておりかつそれがあくびやくしゃみなどの生理現象に由来しないものとした。また上肢・上体の動きを伴わない、ほぼ静止状態で行う確認行動などは「作業なし」とした。

「作業あり」に分類される動作の多くが上肢・上体の加速度変化で捉えられるものであるのに対し、図4の右端の作業員に見られるような確認作業などは何かしら上肢・上体の動きを伴う作業を一時的に停止して行う動作であること多かったため「作業なし」と判断することとした。

この基準で得られた作業と歩行の有無については取得した加速度データと紐づけて教師データを作成した後、予備実験として CNN の実用性検証に用いた。予備実験については5章で詳細をまとめるが、概ね8割程度の精度で歩行の有無と作業の有無を判別することができた。

また、この作業・歩行の有無だけでは直接生産動作に該当しない動作の分類が困難であることが推測されたため、建設現場作業のような複合的な動作であっても、その動作一つ一つには少なからず単純で特徴的な要素が存在する、という仮定の下、分類に影響を与えそうな単純動作を5つ設定した。設定した項目とその動作定義については表-2に示す。「歩行の有無 (walk)」「前傾姿勢の有無 (bent)」「周期的・規則的な動作

(repetitive motion)」「周期性を持たない特徴的

表-2 単純動作の5項目とその判別の基準

単純動作項目	判別の基準
歩行の有無 (walk)	その時間幅で歩行動作があったか 移動・運搬・作業に伴う歩行の区別を問わない
前傾姿勢の有無 (bent)	前傾姿勢かどうか、また首が下を向いている動作であるか 鉛直方向から 10 度以上の傾きがあるか
周期的・規則的な動作 (repetitive motion)	スコップやレーキ、ランマーなどの一定の小さい周期をもつ動作、また機械の影響で一定の小さな加速度を計測されると見込まれる作業動作
周期性を持たない特徴的な動作 (characteristic motion)	主として、直接生産動作かつ周期性が見込まれない動作 断続的ではあるが、その瞬間に作業していると判断できる動作
分類に寄与しないが大きい動作 (ineffective motion)	生産性動作区分に依らず、分類と関係なく加速度が記録されてしまう「あくび」「のび」「くしゃみ」などの生理現象に由来する動作など本来の判別にとってノイズになりうる動作

な動作 (characteristic motion)」「分類に寄与しないが大きい動作 (ineffective motion)」5つの単純な判別項目を設定した。

歩行の有無 (walk) については、その時間幅とその前後で歩行動作があったかを判別の基準とし、補助支援動作である移動・運搬と直接生産動作に伴う歩行動作の区別は行わないこととした。

前傾姿勢の有無 (bent) については、首または上体が一定以上の傾きを有している場合を対象とした。本研究では 10 度程度の傾きがある場合は前傾姿勢であるとしたが、これらの基準についてはより詳細な区別をすることで精度向上が見込める為、5.2 節において今後の検討内容として改めて考察を行った。

周期的・規則的な動作 (repetitive motion) については、極力あらゆる工種において適用できるレンジを持った判別項目になるように配慮しつつ、舗装工事に多く見られたスコップやレーキ、ランマーなどの一定の小さい周期をもつ動作から動作定義を行った。想定される他工種での具体的な作業例としては「コンクリートの流し込み」や「鉄筋の巻き立て」などが含まれる。また本項目では重機の搭乗・操作やコンクリートへのバイブレータなど、使用する建設機械や装置の影響で一定の小さな加速度を身体に受けると見込まれる作業動作についても該当するものとした。

周期性を持たない特徴的な動作（characteristic motion）については、周期性を持つ・繰り返し動作であると判断するには時間間隔の大きい動作や、連続的な作業の中で特に加速度変動が大きく検出されるような上体の動きがあったかどうかを動作の定義とした。これは主に直接生産動作を識別する意図を持った項目であり、現場映像から補助支援動作や作業遅延動作に該当する動作には大きな加速度変化が生じることがほとんど観測されなかったことから、直接生産動作をより詳細に判別するための特徴となることを期待して設定した。

分類に寄与しないが大きい動作（ineffective motion）については、長時間にわたる施工作業の間に発生する生理的な現象に由来する大きな動作を特定し、それを従事している生産性動作区分と切り分ける意図をもって設定した項目である。既往の研究では加速度変化が大きく検出された場合はすべて直接生産動作であるとしていたが、くしゃみや咳であったり、休憩中に大きくあくびをしたり、過度に緊張した体をリラックスさせるような動作についても一時的に大きな加速度変化が認められることから想定される数は少ないものの、判別に影響を与えてしまう。そのためこれらをノイズとして判断できるような項目を設けた。

既往研究から2値分類や焦点を絞った動作の分類はCNNやLSTMで高精度に行えることが示されていることから、同じ加速度情報から5つの単純な項目で2値分類を行い、それぞれ学習することで、同じ時間幅における動作に5つの特徴量を与えることとした。

(4) 既存の HAR 教師データとの違いと取扱いに関する問題点

既往の HAR では教師データの作成には一定時間以上連続して同一の動作を行い、それを複数箇所に取り付けた加速度計でモニタリングを行うことで精度の高い動作情報を得る。しかし建設現場での作業は常に一定の動作をすることはほとんどなく、また時系列で作業環境そのものが出来形とともに変化していくため既存の方法と同一の手法でサンプリングを行うことは不可能である。本研究では目視と撮影データによってマニュアルサンプリングを1秒ごとに行い、その動作のラベル付けを行う必要があった。これに伴う問題点として、その長時間のサンプリングを行ってもあらゆるデータを満遍なく収集することが困難であり、非常に偏差のあるデータ群となってしまうことが挙げられる。その為本研究においても一部の動作については学習データが不十分のため十分な検証が行えなかった。一方でこれらのデータは蓄積を行えるシステムの骨子を作成したため、今後サンプルが増えるにつれてその有用性が判断できるよ

うな枠組みとした。また、偏差が大きいデータであることが事前に判明している為、深層学習への適用の際は、過学習の抑制をするべくドロップアウト法を適用し、また複数人の作業員のデータを、時系列を保持したままシャッフルして学習を行うなどすることで最大限偏りが無くなるような調整を行った。

(5) 教師データの作成

教師データの作成にあたっては個人の主観が極力介入しないように、表-2の要件と実際の映像を例として協議のうえ一定の基準を設定し、クロスチェックを行いながら作成した。教師データは1秒間という短いピッチで作成しているほか、各窓幅に5つの正解ラベルを持つため加速度データとの時刻合わせが非常に重要となる。そのため作成にあたっては現場でのサンプリング時にラベル作成用の撮影データとロガーとなるスマートフォンの時刻を定期的に確認し、すべてが常に一致するように調整を行った。また舗装工事は時間と共に施工箇所が移動するため、撮影機材を複数用意し、多方向から撮影し定期的に位置を移動させることで撮影の死角が減るように最大限の調整を行った。

また正解ラベルの作成は各映像データを複数人で確認し、1秒ごとに前後動作の影響を加味しつつ5項目すべてについてラベルを作成した。フォーマットについてはPythonによってシステムの作成を行った関係から取り扱いのしやすい.csv形式とした。実際の教師データの一部は図-5に示す。

動画10035time	category	activity	walk	rep-motion	char-motion	ineff-motion	bent	
620 14分39秒	9:31:43	0	0	0	1	0	0	1
621 14分40秒	9:31:44	0	0	0	1	0	0	0
622 14分41秒	9:31:45	0	0	0	1	0	0	0
623 14分42秒	9:31:46	2	6	0	0	0	0	0
624 14分43秒	9:31:47	2	6	0	0	0	0	0
625 14分44秒	9:31:48	2	6	0	0	0	0	0
626 14分45秒	9:31:49	2	6	0	0	0	0	0
627 14分46秒	9:31:50	2	6	0	0	0	0	0
628 14分47秒	9:31:51	2	6	0	0	0	0	0
629 14分48秒	9:31:52	2	6	0	0	0	0	0
630 14分49秒	9:31:53	2	6	0	0	0	0	0
631 14分50秒	9:31:54	2	6	0	0	0	0	0
632 14分51秒	9:31:55	2	6	0	0	0	0	0
633 14分52秒	9:31:56	2	6	0	0	0	0	0
634 14分53秒	9:31:57	2	6	0	0	0	0	0
635 14分54秒	9:31:58	2	6	0	0	0	0	0
636 14分55秒	9:31:59	2	6	0	0	0	0	0
637 14分56秒	9:32:00	2	6	0	0	0	0	0
638 14分57秒	9:32:01	2	6	0	0	0	0	0
639 14分58秒	9:32:02	2	6	0	0	0	0	1
640 14分59秒	9:32:03	0	0	0	1	0	0	1
641 15分00秒	9:32:04	0	0	1	1	0	0	1
642 15分01秒	9:32:05	0	0	1	1	0	0	1
643 15分02秒	9:32:06	0	0	0	1	0	0	1
644 15分03秒	9:32:07	0	0	0	1	0	0	1
645 15分04秒	9:32:08	0	0	1	1	0	0	1

図-5 教師データの一部

5. 生産性動作システムの開発

(1) 既存システムの課題点

数学的手法を組み合わせた既存の判別システムでは70%近くの判別精度を記録したものの、作業種別ごとに手作業で閾値の調整を行うほか、適宜計算を行うなど判別に際して人手によるチューニ

ングを毎回行う必要があった。また、SVMによる2値分類では偏差のあるデータもある程度の精度をもって分類できていたが、3クラス以上になった際にはやや精度が落ちる懸念があった。また事前に策定したルールによって最後の生産性動作判別を行っていたため、例外的な動作への対応が難しく、客観的な判断材料として十分であると言えない部分もあり、加えてデータの蓄積が困難な問題も確認されていた。

(2) 生産性動作分類システムの新しい枠組みの作成

これまでの課題を解決しつつ、客観性を担保し、数学的に最適化が行えて、かつバックプロパゲーション（誤差逆伝播法）によって自動的にパラメタチューニング可能な深層学習手法としてCNNおよびLSTMを用いたシステムの作成を行った。数学的手法を組み合わせた判別のメリットはそのままに、アルゴリズムを、時系列情報を保持可能なCNNに置き換えることで課題の解決を目指した。

設計としてはCNNとLSTMのハイブリッド形式とし、それぞれの出力をAffineによって結合することで最終的な出力を得るモデルを採用した。これはCNN+LSTMを使用している既往の研究ではその適応箇所が明言されている例がなく、各アルゴリズムを絡めたモデルの詳細は秘匿されていたことから、2つのアルゴリズムをそれぞれ用いて最終的な出力に反映させる方法とした。本方式のほかに、畳み込み・プーリングを行ったデータを窓単位で時系列ごとに並べてスケーリングしたのちに、LSTMでより大きい窓幅ごとの出力を得る方法なども検討の余地があったため、その詳細は6章にて利点と共に示す。

(3) システムの考案とアルゴリズムの選択

a) 生産性動作判別システムの考案

先に述べた課題の解決のほかに、長期的な視点としてデータを蓄積して高精度に判別を行ううえで、アップデートしやすく、また加速度以外の情報として位置情報なども導入できるようなシステムが必要である。本研究では動作判別を行うモデルの生成までにとどまったが、それらを活用するシステムの骨子についても設計の提案を行う。図-6には本研究で構築したシステムの全体像を示した。

本研究は図-6における単純動作判別に該当するが、最終的には策定した5つの単純動作を出力とする同様のモデルを複数作成し、これによって得られる出力を入力としてさらにメタモデルに学習をさせることでアンサンブル学習の手法であるStackingによる高精度化を目指すものである。一般的なアンサンブル学習ではメタモデルの出力と

ベースモデルの出力は揃えることが多いが、本システムにおいてはよりベースモデルの単純動作5項目よりも出力数を絞った3項目の生産性動作区分という広いレンジで出力することを目指すため、実験的にこのような設計とした。またベースモデルと出力が異なる点を補足する情報として、位置情報など同時刻におけるその他の情報についても取込可能である設計とした。

b) 生産性動作判別システムの概念構築

単純動作判別には既存のHARでも積極的に導入されている深層学習手法であるCNNおよびLSTMを採用した。HARの判別モデルを構築する際、CNNやLSTMを活用することにはそれぞれ独自のメリットがある。

CNNは主に画像認識に優れた性能を発揮するが、3次元的な動作の抽出を行う必要があるHARにおいても利点が存在する。CNNは畳み込み層やプーリング層を通じて階層的な特徴抽出が可能であり、これは時系列データである動作データにも有効であるといえる。そのため一般に映像による動作認識手法で用いられるCNN手法を、加速度データにも適用するべく画像として取り扱い、時系列での動きを捉えるために、CNNを用いてセンサデータを畳み込むことで、HARの性能向上に寄与するような特徴量を抽出する。本研究ではそれを実現する前処理として加速度のセンサデータを画像データのように2Dに展開することでさらにCNNの長所を伸ばす方法を採用した。くわえて「時間情報を必要量維持する」「時系列・順序が正しく保たれる」「多量の時刻情報をできる限り簡素にまとめることで計算負荷を少なくする」という3点を満たす工夫を行った。

画像の生成手順は図-7に示すフローの通りである。加速度は本質的には連続的に変化するが、IMUから得られるデータはそのサンプリングレートの問題から、本研究では50Hzが限界であった。それに伴い得られるデータも離散データであり、これは一般的な解析では十分ななめらかさを有しているものの、建設現場の作業を生産性動作区分に応じて判別するうえでは、その動作の複雑さゆえに得られる特徴が少ないと考えた。このことから、「波形的特徴」を持ちながら、時系列の情報を広いレンジで特徴抽出できるような「画像的特徴」の両方をもつような画像の生成を行った。本来であればX,Y,Zの各軸の加速度の離散データから波形的特徴を得るために時系列でグラフ化する必要があるが、本研究では判別の窓幅の最初の時刻を t_1 、終端時刻を t_n とするようにトリミングを行ったのち、その時刻データを $\Delta t = 1$ セルずつずらして重ねてゆき、 t_n 行目までストライドを行う。これによって t_1 から t_n までの行と列が生成され、時間にして t_{2n} までの時間情報を一枚の画像とすることができる。この画像の特徴として、左上に

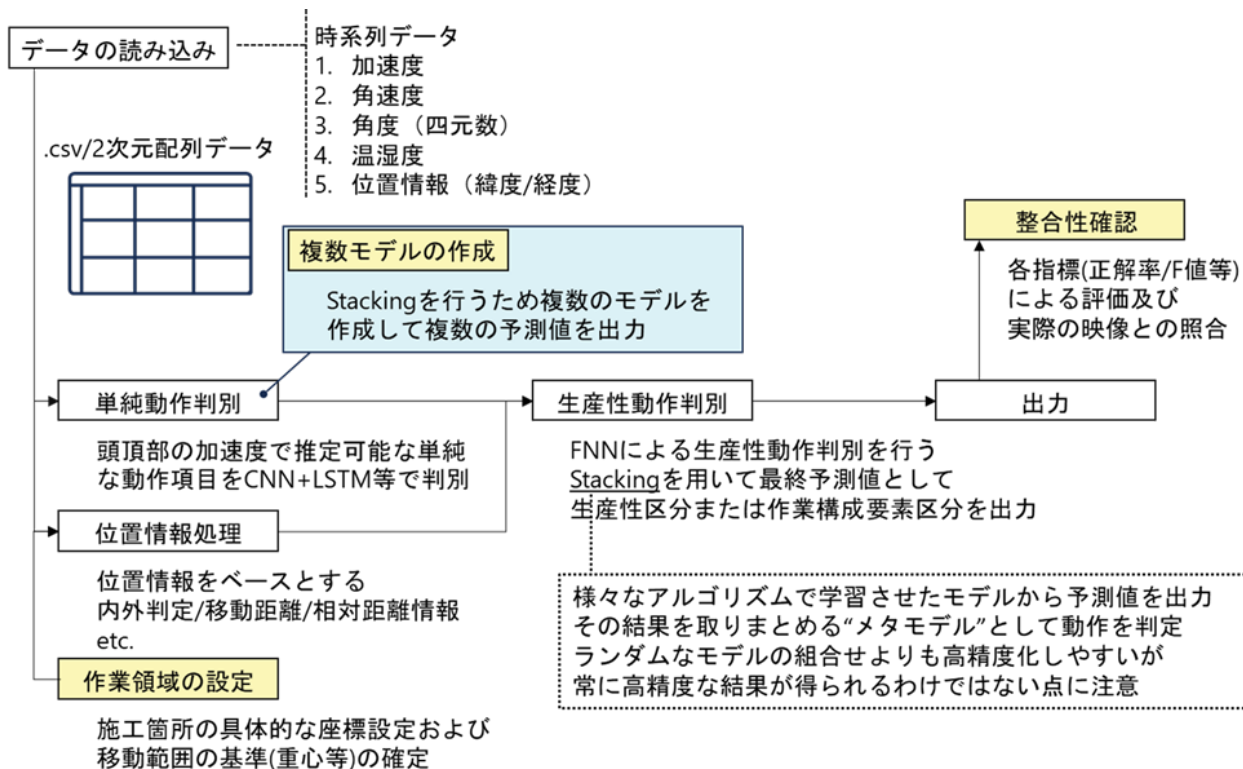


図-6 システムの全体像

起点となる時間情報が 1 セル分，そこから右下にかけて基点となる時刻 t_n が近付くにつれて情報量が 1 セルずつ増えていき， t_n を過ぎてからまた画像右下の t_{2n} に向けて 1 セル分ずつ情報が減っていくことにより前後の時間情報を，時間幅が離れるにつれて少なくなるようになっている．また，波形的特徴としては斜めに走る畝のように加速度の大きさに応じて濃淡が生成されるため，これを学習することで一定の波形的特徴を維持している．CNN の特性上，畳み込み処理において加速度変化を示すコントラスト（濃淡）の差を捉えることができ，特にエッジ処理と呼ばれるコントラストの大きい部分でこの特徴を顕著に把握することができるため本方式でも十分な活用が見込まれた．

加えて，単純なグラフからの特徴分析は人の手による閾値設定や各軸の相関などからの一定の類推が必要となるが，画像化によって軸ごとの情報がまとめられ，X 軸を Red，Y 軸を Green，Z 軸を Blue と対応させて色情報を持つテンソルであることみなすことで，3 軸の加速度の大きさが各軸で独立することなく包括的に扱えるほか，CNN での処理実行時にはバックプロパゲーションによるパラメタの自動調整が可能であるため人手による信頼度低下要因を低減可能である．

今回は加速度の前処理として 150 データ（3 秒ごと）の窓幅で切り取り画像として，150x150x3 のテンソルに変換した．その後，畳み込みを行って特徴を先鋭にしたのち，時系列特徴が損なわれないようにマックスプーリングを行った．さらに，50 データ（1 秒）ずつストライド幅を設けること

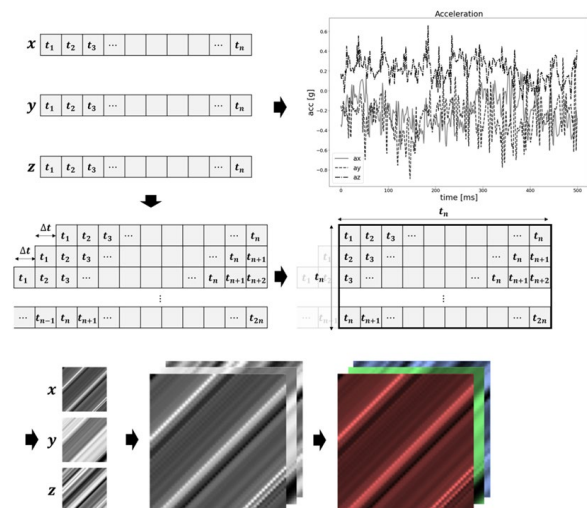


図-1 加速度データから生成する画像の生成手順

で画像化後の 3～5 秒の時間幅の情報を保持したまま LSTM での判別が行えるように調整し，時系列情報を保持したまま動作判別を行うモデルを実現した．

また汎用性を確保するべく，活性化関数には先行研究で活用されていた ReLU および Adam を用い，出力層を判別項目に併せて適宜設定し，アーキテクチャは判別項目（5 項目）で大きく変更せず学習させるラベルを変更するのみにとどめた．また中間層にはランダムにニューロンを消去し，一部のニューロンを非活性化させ，学習を行うことで一部の信号が伝播しなくなり，過学習を抑制することができるドロップアウト法を採用し，ま

た計算コストと精度の兼ね合いからニューロン数はそれぞれ 60、中間層を 2 層に留めた。

また LSTM 実装部について、2 章で軽く触れたように、LSTM は時系列データに特に適しており、過去の情報を長期的に保持することができるモデルであるため前後数秒間を考慮する回帰ネットを作成しそこに LSTM を適用した。記憶の保持については LSTM を用いることで、センサデータの時間的な依存関係を学習し、より複雑な時系列パターンを捉えることが可能となる。なお、具体的な実装についてはそのソースコードを巻末に付録した。

総括すると、CNN は時間的・空間的な多次元の特徴抽出に優れ、LSTM は時系列データの長期的な依存関係を考慮する点で優れているため、これらの手法を組み合わせることで、センサデータの系列情報を最大限に活用できるシステムを目指した。

(4) 深層学習を用いた単純動作分類

まず試験的に「歩行」と「作業」の有無を判別する CNN のみの判別モデルを作成した。学習に用いたデータは 6 名の人員に現場サンプリングと同じ装備を装着して、得られた 90,000 データ、約 30 分間の動作を畳み込み、学習、検証したものである。これはヘルメットに取り付けた単一の IMU データのみで CNN による建設現場作業員の動作判別を一定の精度で行えるのかをあらかじめ検証するものである。

得られた結果は図-8 に示すものとなった。作業ありかつ歩行あり (work with walking) 作業ありかつ歩行なし (work without walking) 歩行のみ

(walking) 作業・歩行ともになし (not much activity) の各項目で該当するセルのスコアに応じて色濃度が大きくなる。この予備実験の全体正解率は 87.5% となりある程度の精度で判別が行えたことから加速度を画像化したのちに畳み込みを行ってもある程度の HAR 性能が期待できることが判明した。次いで行った単純動作分類 5 項目については、実際の現場データを使用する都合から、先に加速度データの 10 分割交差検証を行った。この交差検証の結果データには偏りがあることがわかったため、十分な検証が可能である母数 (約 10,000 データ) を確保できた「前傾姿勢判別」と「歩行有無判別」のみを実施した。「周期的・規則的な動作 (repetitive motion)」「周期性を持たない特徴的な動作 (characteristic motion)」「分類に寄与しないが大きい動作 (ineffective motion)」についてはそれぞれが背反的な事象である側面を持つためか、今回のデータサンプリングのデータ量では教師データとして十分な量を確保できなかった。なおこの 3 動作についても簡易的な学習を試したものの、予測・正解データ共にネ




図-2 単純動作判別の結果




図-9 前傾姿勢判別の混同行列 (分類結果)




図-10 前傾姿勢判別モデルの学習曲線

ガティブである TN (True Negative) にほとんどが分類されたほか、学習量が足りず十分な精度が見込まれなかった。

試験の結果、前傾姿勢の判別については図-9 に示すような分類結果となった。正答率 92.1%、適合率 98.5%、再現率 93.4% となった。一方で図-10 に示すのはこのモデルの学習曲線である。モデルの訓練誤差が小さくなっているのに対して検証誤差が上昇している。このことから過学習の傾向が認められ、未知のデータに対する汎化性能がやや低下していることがうかがえる。

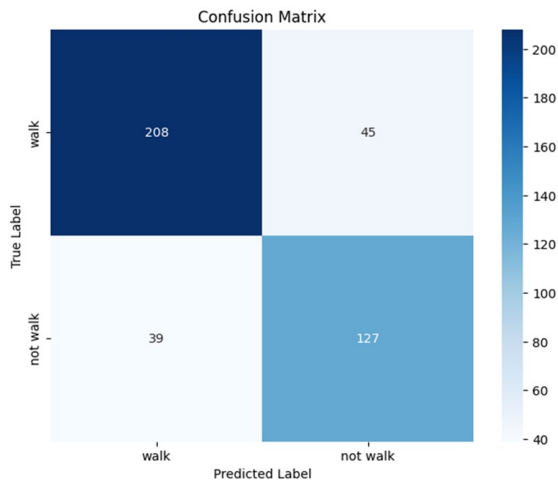


図-11 歩行有無判別の混同行列（分類結果）




図-12 歩行有無判別モデルの学習曲線

また、歩行判別については図-11 および 図-12 に示す通り、正答率 80.0%、適合率 82.2%、再現率 84.2%と概ね良好な数値を得た。しかし、前傾姿勢と同様に検証誤差については学習サイクルを経るごとに上昇傾向にあるため汎化性能はやや低いことが予想される。

今回は使用したモデルの変更は行わず、同一の加速度に紐づけた正解データを「歩行」か「前傾姿勢」かを切り替える形で学習を行ったため、アーキテクチャの構造は変化せずあくまでも学習によって得られるシード値以外は変わらないため、どちらも似たような学習曲線を得たものと推測される。また、単純動作であるがゆえに過学習を抑制し、汎化性能を高める必要があるため、この点については改善が必要であることがわかった。

(5) 深層学習を用いた生産性動作分類

前節に示す通り、十分な単純動作判別のデータが得られなかったことから、検証のために、作成した CNN+LSTM モデルを用いて生産性動作区分と作業構成要素についても分類を行った。図-13～16 はその分類結果および学習曲線である。生産性動作判別については正答率 73.3%を記録し、特に補助支援動作（Support）については一定の




図-13 生産性動作区分判別モデルの混同行列（分類結果）




図-14 生産性動作区分判別モデルの学習曲線




図-15 作業構成要素区分 5 項目の混同行列（分類結果）




図-16 作業構成要素区分 5 項目分類モデルの学習曲線

精度が確保でき、再現率 81.5%、適合率 84.6%となった。

また、作業構成要素区分での分類も行ったが、実際に記録された「0.直接生産動作」「1.図面や指示の確認動作」「2.作業員自身の移動動作」

「3.資機材の運搬動作」「6.待機」のみに絞って検証した。正答率は 64.0%となり単純動作と打って変わって低い水準となった。

いずれの場合も検証誤差が高くなったのは前述の通り過学習の傾向にあるためであると考えられる。また過学習が生じた原因としては、モデルの複雑さに対してデータ量が不足していることが考えられる。畳み込みニューラルネットワークは膨大な量の画像データであっても処理が行えるように本来は畳み込みとプーリングによって取り扱うデータを削減する「ダウンサンプリング」を行う過程が含まれる。本来の CNN では、例えば高画質の基準ともいえる 1920x1080 のサイズの画像から特徴を得るために 100px ごとに畳み込みとプーリングを行うことで膨大な画像データを削減する設計となっているが、それに対して今回作成した画像は窓幅が重要であるために 150x150 のサイズとしたため、畳み込む過程で特徴を過剰に学習したことが予想される。

このような理由から過学習の抑制をするためには、訓練データを増やすことで偏差を少なくするほか、CNN モデルのサイズを小さく、単純なモデルにすることや、重みの正則化、CNN においてもドロップアウトを追加するなどの対策が考えられる。また、3~5 秒の窓幅以外にも大きいレンジで画像を生成し、畳み込みのカーネルサイズを調整することなども効果的であるが、それに伴って生産性動作判別の窓幅も大きく変化してしまう他、前後の時系列に過剰に影響を受けてしまう可能性もあるためモデル生成に関わるハイパーパラメータの対照実験も必要となる。

(6) 分類試験結果の考察

分類試験の結果から、既往のシステムの利点をそのままに加速度を画像化するプロセスと深層学習を用いた場合でも同水準での判別が行えることが判明した。単純動作についてはすべてを検証できたわけではないが、高い水準で判別することができたが、過学習を抑制する工夫が要求されることも判明した。一方で生産性動作区分と作業構成要素区分における分類では、既存システムより高精度とならなかった。事前の予測通り、作業員の従事する作業は複雑で複合的な動作であるため判別に必要な特徴の境界があいまいとなり、そのまま十分な多クラス分類を行うことが難しいことがうかがえた。

また前傾姿勢の項目については正解率そのものが高くでたものの、建設現場の環境や工種・職種

によって大きな差が出ることが懸念される。前傾姿勢として記録される事項として「首の傾き」についても前傾姿勢の 1 つであるとしたが、これはヘルメットに装着した加速度計の情報と照合しやすくするための動作定義であった。しかし実際の作業において、施工箇所と作業員のアイレベルの違いによって視点が変化するため、それに合わせて首の傾きを検知することが多くなることが想定される。実際に今回対象とした舗装工事においては作業員の職種によって前傾姿勢の傾向が大きく異なった。

図-17 は実際の現場の様子である。建設機械に搭乗するオペレータは建設機械の操作盤がアイレベルよりもさらに下にあることで、作業中は手元確認のために前傾傾向にある。また舗装面を基準とすると建設機械は高さをもつため、路面の状況を確認する際には建設機械から大きく身を乗り出す必要がある。

一方で建設機械に搭乗しない作業員については前傾姿勢の他に、自分のアイレベルよりも上にいるオペレータとの連携をはかるうえで仰角が大きくなる瞬間が存在する。また、スコップ作業などは大きい動作を伴うものの、個人差が大きく作業のなかで首や前傾の程度が著しく変化する作業員もいれば、視点を敷材に固定して変化が少ない状態で作業する作業員も観測された。

また、作業間に生じる待機や休憩中には前傾姿勢はとらずにいる作業員が多く、打合せや作業指示の確認時は全体的に前傾ないし視線・首が下に傾く傾向も見られた。

先行研究においては、運動による認識を採用した HAR 手法においては、ウェアラブルセンサは胸部・大腿部・上腕・手首などが代表的な装着位置であり、本研究のようなヘルメットへの搭載では高精度化が期待できないとされていた。そのため作業員の行動を抑制しない範囲で、ヘルメット以外の装着位置から得られるデータでの追検証なども重要であると考えられる。



図-17 前傾姿勢をとる作業員

他方で、単純な作業動作であればヘルメットの単一の加速度データのみでもある程度判別可能であることが実証できたため、装着に伴う締め付けなどが生じず、作業員の作業を制限しないデバイスとして現場でも比較的高い受容度をもって導入が期待できる。

(7) 使用したアルゴリズム・教師データ等の評価

今回使用した CNN+LSTM モデルでは時系列情報の保持をしつつ、データの追加に伴って更なるモデルの強化が行えるシステムとして構築ができた。特に主として利用した CNN によって既存のシステムで課題として挙げられていた教師データの蓄積と増強、そして人手による操作の減少が実現した。精度については歩行動作と前傾姿勢の判別については既存手法と同程度の記録をしたものの、過学習の抑制が重要であるとわかった。また、生産性動作区分別と作業構成要素判別については既往の統計的手法の組合せの物よりもやや正答率が低下する結果となった。ただし、これは判別のピッチが異なっており、既往の研究では 1 分毎の生産性動作を判別するものであったものであるのに対し、本研究のシステムではさらに細かい 3 秒の時間幅での判別を行っている為、より詳細度の高い判別について同程度の正答率を維持できたとも考えられる。

なお判別処理にかかる時間については、既往のシステムと比較して大幅に縮減することができた。1 時間分の動作判別に要する時間が既往システムでは全体で 3 時間程度かかっていたのに対して、本方式では学習から判別まで 25 分とおよそ 96% の時間縮減が行えた。一般に LSTM をはじめとする回帰型ニューラルネットワークにおいては系列データのデータ数が増加するにつれて指数関数的に処理時間が増加することが報告されている。しかし、このような結果が得られた理由としては、加速度データの画像的处理によって 1 つのテンソルについて 3 秒の時間幅の特徴量を与えることによって、“時系列情報は保持しているが、全体のデータ数を縮減する”ことができたことに起因すると考えられる。生データであれば、3 秒のデータの処理には 150 データ×3 軸分の 450 データの処理が必要となるが、テンソルにすることでそれを一つのデータとして取り扱うことができ、結果的に回帰回数が大幅に削減されたことがうかがえる。同時に、本質的にはより多くの情報を入力として与えることを想定したアルゴリズムであるがゆえにやや過剰な判別モデルになっている側面もうかがえる。

また教師データについては客観性を確保できるようにさらに客観的な指標を組み込むほか、現在では不足している「周期的・規則的な動作

(repetitive motion)」「周期性を持たない特徴的な動作 (characteristic motion)」「分類に寄与しないが大きい動作 (ineffective motion)」の 3 項目についての有効なデータを継続的に集めて蓄積し、判別精度を確認していく必要がある。現段階の調査では新規に設定したこの単純動作 5 項目の妥当性を評価するには情報が不十分である。過学習の抑制の為に継続的にデータを収集・集積してモデルの高精度化を目指す。

6. 舗装工事に適した生産性動作システムの改良

(1) 教師データ作成と作成ルールの更新

a) 舗装工事における特徴的な動作の抽出 ～「特定作業動作」の定義～

舗装工事を対象としたシステム構築のために、生産性動作区分の中の「直接生産動作」を細分化した「特定作業動作」を新たに定義した。これは、舗装工事において、作業員がどのような内容の作業に従事しているかを抽出したものである。

舗装工事の作業員の「直接生産動作」の中には、様々な動作が存在する。スコップでアスファルト合材を運搬する作業員、アスファルト合材をレーキで均す作業員のほか、アスファルトフィニッシャーを操縦するオペレーターといった建設機械を操作する者など様々である。

このように、「直接生産動作」は職種ごとの従事内容によって特徴的な動きが異なる。実際に現場にて取得した加速度データをプロットしたグラフを比較すると加速度の特徴が異なっていることが確認できた。

図-18 はアスファルトフィニッシャーによって敷設したアスファルト合材を均し、厚さや敷均し面の調整といったレーキを使用するレーキマンと呼ばれる作業員の加速度データである。図-19 はアスファルトフィニッシャー後方にて、アスファルトフィニッシャーによって敷設されるアスファルト合材の横幅や敷均し厚さを調整するといった作業に従事する、アジャストマンと呼ばれる作業員の加速度データである。

グラフは縦軸が加速度 (m/s^2) で、横軸は時刻である。データは 50Hz で、グラフに示したものは 1 分間の動作であるため 3000 データがプロットされている。

この 2 つの動作を比較してみると、レーキマンの x 軸方向の加速度 (a_x) は、 -1 m/s^2 に到達している一方、アジャストマンは到達しないといった特徴がある。また、アジャストマンの y 軸方向の加速度 (a_y) においても、若干であるが大きな周期性を持っていることが可視化することによって確認できた。




図-18 レーキマンの動作加速度




図-19 フィニッシャーアジャストマンの動作加速度

このように「直接生産動作」に分類される作業であっても、従事する内容によって加速度の特徴も異なることが確認された。そこで「直接生産動作」を細分化することによって、それぞれの作業での特徴的な加速度を抽出可能と考えられる。

本研究では 17 項目の作業を抽出した。これらの作業項目は、一般的な舗装工事において行われる作業内容である。表-3は新たに設定した「特定作業動作」（直接生産動作 15 項目・補助支援動作 2 項目）を示す。表-3の各動作についての詳細は以下の通りである。

「1.1.1 レーキマン」

レーキマンは、レーキを使用してアスファルトフィニッシャーに続いて、アスファルト合材を高さや厚さが均一になるように敷き均しを行う作業員である。その後転圧することを考慮し、余盛と勾配やアスファルトの種類や温度を考えて仕上げる作業員である。作業員によってクセ等があるため、複数の作業員のデータを収集することが望ましい。

「1.1.2 スコップマン」

スコップマンは、レーキマンと同様にスコップでアスファルト合材を運搬する作業員である。アスファルトフィニッシャー後方のスクリードとい

表-3 「特定作業動作」一覧

1 直接生産動作		
1.1 直接生産動作		
1.1.1	レーキマン	
1.1.2	スコップマン	
1.1.3	ローラーオペレーター	
1.1.4	フィニッシャーオペレーター	
1.1.5	フィニッシャーアジャストマン	
1.1.6	型枠設置	
1.1.7	型枠撤去	
1.1.8	タイヤショベルオペレーター	
1.1.9	バックホウオペレーター	
1.1.10	乳剤散布	
1.2 準備工		
1.2.1	清掃	
1.2.2	散水	
1.2.3	養生作業	
1.2.4	付着防止作業	
1.2.5	ハンドスイーパー	
2 補助支援動作		
2.1 図面や指示の動作確認		
2.1.1	状況の確認・指示	
2.1.2	マーキング	

われる部分の余分なアスファルト合材の除去や、敷き均された合材の不足箇所やマンホール周辺といった細かい作業が必要な場所へ合材を運搬する作業でスコップを用いる作業員である。「1.1.3 ローラーオペレーター」

ローラーオペレーターは、敷き均された合材を転圧する作業を行うローラーを操縦する作業員のことを指す。マカダムローラーは自重が 10t 程度で、初期転圧が用いられる建設機械である。タイヤローラーは、二次転圧に使用される建設機械である。

「1.1.4 フィニッシャーオペレーター」

フィニッシャーオペレーターは、アスファルト舗装の施工において、アスファルト合材を敷き均すための建設機械のアスファルトフィニッシャーの運転者のことである。一定の速度で操縦する必要があり、小型特殊免許または大型特殊免許が必要である。舗装工事はフィニッシャーを先頭に組み合わせ施工が行われるため、キーパーソンの一人である。

「1.1.5 アジャストマン」

アジャストマンは、アスファルトフィニッシャーの後方で地上付近から敷き均された面をチェックし、幅員や厚さの調整を行い平滑に敷きならすよう機械を調整する作業員である。フィニッシャーオペレーターからは舗装面の状況が分からない為、アジャストマンが必要不可欠となる。

「1.1.6 型枠設置」「1.1.7 型枠撤去」

型枠設置・撤去は、舗装工事の際にアスファルト舗装の施工幅員になるよう合材を敷き均す範囲を決める枠を設置し、撤去する作業員である。型枠は一般的に 4m 程度の木材で、施工厚さに合わせた厚さの木材を使用する。型枠を使用することにより、アスファルト合材を敷設後、設計で求められている舗装の厚みや幅員を確保する目的がある。一方で、近年では型枠なしでの施工方法も開発されている。

「1.1.8 タイヤショベルオペレーター」

「1.1.9 バックホウオペレーター」

タイヤショベルオペレーターとバックホウオペレーターは、それぞれの建機を操縦する作業員である。アスファルトフィニッシャーによって敷き均ししない施工箇所にアスファルト合材を運搬するといった細かい作業に従事することが多い。

「1.1.10 乳剤散布」

乳剤散布（タックコート）は、新たに舗設するアスファルト混合物層とその下層の基層などとの接着および継目部や構造物との付着を良くするために行う。タックコートの施工は、通常ディストリビュータやエンジンスプレーヤで行う。

「1.2.1 清掃」

箒を使用して、施工箇所の表面上の砂埃等を掃く作業を清掃とした。

「1.2.2 散水」

散水は、舗装面の温度を下げ、工事中の道路の交通規制を早く解除する目的で行われる。その作業を散水とした。

「1.2.3 養生作業」

アスファルト合材が L 形側溝といった道路構造物に付着しないよう養生する作業のことである。

「1.2.4 付着防止作業」

作業員がレーキやスコップ、また作業員自身の靴の裏に噴霧器によって付着防止剤を散布する仕事を付着防止作業とした。この動作は現場でよく見られる。

「1.2.5 ハンドスイーパー」

ハンドスイーパーは、ハンドスイーパーを使用して清掃している作業員のことである。

「2.1.1 状況の確認・指示」

ローラオペレーターにむけ、転圧する範囲を指示するといった動作。

「2.1.2 マーキング」

マーキングは、アスファルト合材を敷き均しする幅や長さを目印をつける作業である。

以上の舗装工事において特徴的な動作として 17 項目を抽出し、新たに「特定作業動作」として定義した。

b) 教師データの作成方法の改訂

第 5 章までに構築してきたシステムでの教師データは、1 秒間という短い時間間隔で作成されて

いる。現場にてビデオカメラで撮影した時刻と、加速度データとの時刻合わせが非常に重要となる。そのため作成に当たっては、撮影データとロガーとなるスマートフォンの時刻を定期的に確認し、すべてが常に一致するように調整を行った。舗装工事の特性として、時間と共に施工箇所が移動するため、撮影機材を複数準備して多方向から撮影し、定期的にカメラの設置場所を移動することによって、撮影の死角が減らせるように最大限の調整を行った。教師データの正解ラベルの作成は、複数人で映像データを確認して作成した。

しかし、1 秒間では建設作業を特定の動作と判断することは困難であり、誤認識をする可能性がある。また、データが 1 秒間に対して生データ 50 データで比較しているが、実際には 1 秒間に 50 データ取得できていないこともあり、構築したシステムと分析作業が適合しないケースも確認できた。

また、複数人の作成者によってラベル付けの判断が大きく異なることも課題として挙げられた。そこで、作成者によってラベルの付けの判断の差がどの程度生じるのかを検証した。検証は以下の 1～3 の手順で行った。

検証対象：調査員 5 名が分類したデータ

検証映像：東京都晴海埠頭の舗装工事

1. 5 分間の現場の映像を各々で視聴し、教師データを個々に作成（300 データ）
2. ラベル付のルールを明確にするため新定義した
3. 5 人で作成した教師データを比較し差異を確認

検証した動画は、レーキ担当の作業員で主にフィニッシャーからはみ出た合材を均す基本的な作業が中心であった。教師データのラベル付のルールを舗装工事の専門家の知見を得て調査員間で事前に明確にした。既存のルールは、1 秒間のその瞬間の作業員の行動を切り取ってラベル付をしていた。例えば、直接生産動作の一連の行動の中で、作業員が一時的に体を休める姿勢を取った場合、直接生産動作ではなく待機の作業遅延動作と判断していた。

新しく定義したルールでは、同じ行動が 30 秒以上継続した場合に生産性動作区分の判断を行い、30 秒以内の行動であればその時点の前後の生産性区分の一部だと判断することにした。図-20 に判断イメージ図を示す。

当初作成した教師データのラベルと、新定義によるラベルを比較した。図-21 は生産性判別区分のラベルをプロットした図である。新定義では調査員 5 名中、1 名は全ての行動を直接生産動作と判別しているが、ほかの者はある程度一致した判断基準を持っていることが確認できた。表-4 は、新しく定義した教師データとラベル付したものが、どの程度一致しているかを確認した。当初ルール化以前においても 4 名の調査員は 8 割以上の精度で判断できていたことが確認された。



図-20 新ルールの判断イメージ




図-21 レーキマンの加速度と生産性判別区分のラベル

表-4 新ルールと調査員ごとの判断の一致率

調査員 1	調査員 2	調査員 3	調査員 4	調査員 5
86.67%	81.33%	99.33%	82.67%	48.00%

以上のように、作成者よっての判断は 8 割程度の精度が確認できた。これを踏まえ、従来通り複数人で教師データを作成することとした。

(2) 更新された手法による教師データでの精度検証

先述の通り定義した新たな教師データのラベル付によって、過去のデータを用いてどの程度精度が向上するか検証した。検証するデータの取得は 2023 年 10 月 11 日に東京都晴海埠頭での道路舗装施工現場にて行った。対象の作業員は 3 章で取り上げた作業員 1 名とし、データの取得時間は 5 時間である。サンプリング周波数を 50Hz とした。データは、作業員が重機などで対象者が見えない時には NaN 値(Not a Number)として扱い、欠損値(作業状況を目視で確認できなかった時間帯のデータ)の扱いは、プログラム上では映っている前後の値で補完する方法を選択した。映像で確認できていない間は、前後の動作を行っている可能性が高いと判断したためである。モデル性能を評価する混同行列から得られる TP, TN, FP, FN の 4 つの指標を使い、正解率(Accuracy)、適合率

(Precision)、再現率(Recall)、F 値(F score)の値を算出し、精度評価指標とした。精度評価指標は式(1)から式(4)で表される。1D-CNN モデル、2D-CNN、1D-CNN と LSTM のハイブリットモデルにてそれぞれ精度検証した。検証結果を表-5 から表-7 に示す。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN}$$

$$F\ score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

表-5 1D-CNN の結果

1D-CNN	生産性分析区分		作業構成要素区分	
	従来	新定義	従来	新定義
正解率 (%)	48.03	50.39	49.13	51.29
適合率 (%)	54.30	51.12	32.54	50.84
再現率 (%)	45.07	50.39	26.85	51.29
F 値 (%)	43.94	48.29	26.51	44.64

表-6 2D-CNN の結果

2D-CNN	生産性分析区分		作業構成要素区分	
	従来	新定義	従来	新定義
正解率 (%)	50.39	46.08	48.50	48.97
適合率 (%)	54.24	47.46	36.26	47.62
再現率 (%)	46.50	46.08	26.02	48.97
F 値 (%)	47.91	43.89	26.58	46.13

表-7 1D-CNN+LSTM の結果

1D-CNN+LSTM	生産性分析区分		作業構成要素区分	
	従来	新定義	従来	新定義
正解率 (%)	49.24	49.82	50.03	52.60
適合率 (%)	51.72	52.19	32.94	52.73
再現率 (%)	47.30	48.82	27.29	52.60
F 値 (%)	47.51	46.67	28.25	46.47

新定義にて精度検証を行ったが、9 区分ある作業要素区分において適合率、再現率、F 値においては 2~3 割の精度から 4~5 割の精度に向上した。これは新たな直接的な動作を定義し適用できたことが要因と考えられる。移動や資機材の準備といった 30 秒以内に完結する行動が、前後の行動とみなされるため細かな行動が除去されこのような結果になったものと考えられる。

(2) 舗装特有の作業動作を考慮した新たな生産性動作判別システムの改良

a) 舗装特有の作業動作を考慮したシステムの概要

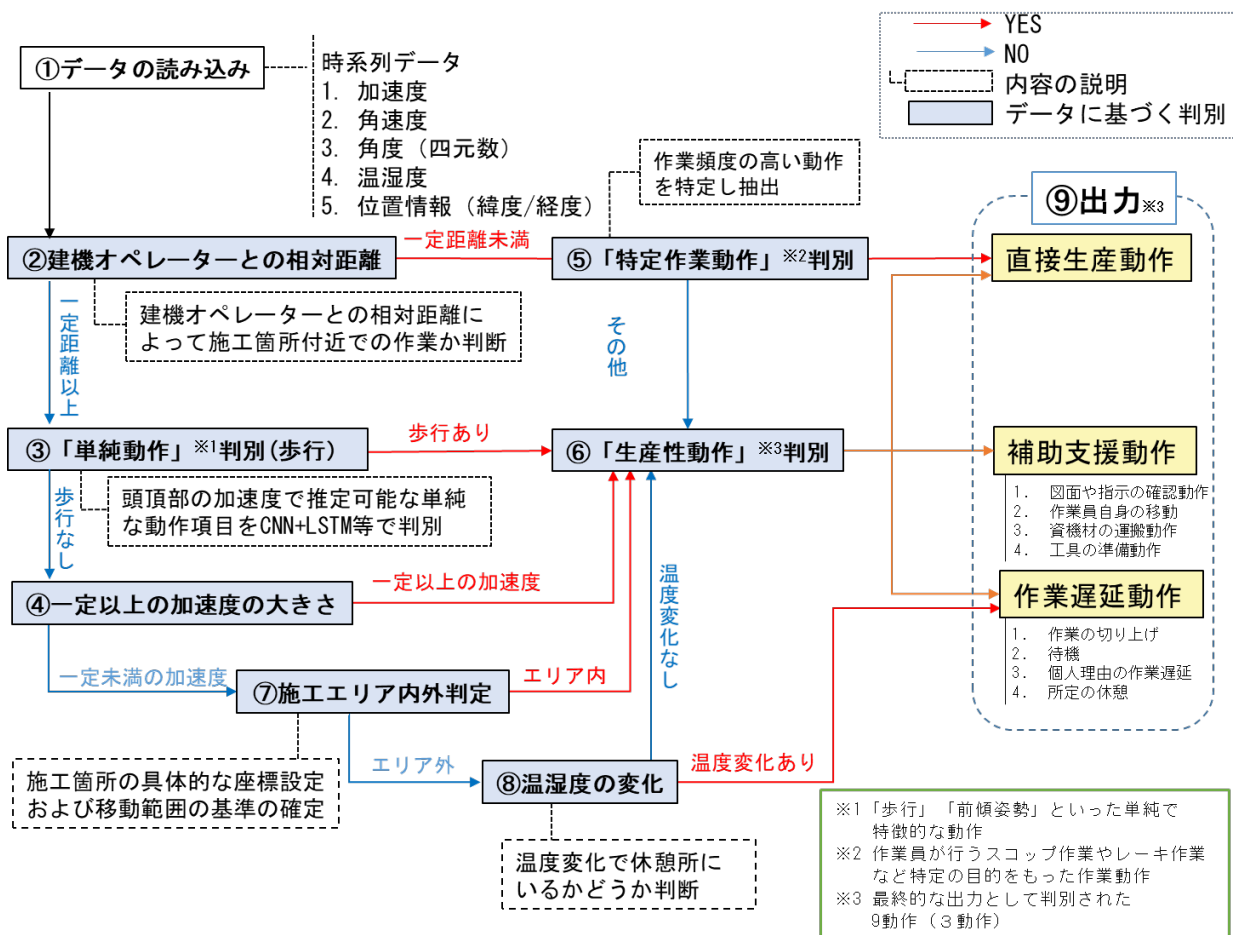


図-22 新たな舗装特有の作業動作を考慮したシステムの全体像

図-6 のシステムに舗装特有の作業動作を新たに考慮した生産性動作判別システムの全体フローを図-22 に示す。図-6 から、右上の枠内に示す事項が追記された形となっている。

新たに構築したシステムについて以下で詳細に説明する。説明事項は、図-22 で示しているように各種データに基づく判別（番号が振られている箇所、主に青背景部分）の部分である。

b) プロセス①データの読み込み

改良前システムと同様に、現場にて取得した「加速度」、「角加速度」、「角度」、「温湿度」、「位置情報」を入力値とする。

c) プロセス②建機オペレーターとの相対距離

この判断項目では、作業員が建設機械との相対距離が一定以上か、一定未満であるかどうかを判断する。この際の一定距離とは、建設機械のオペレーターから半径 4m 程度（イメージとして図-23）と設定した。この数値の根拠として、一般的に舗装工事は一車線ごとに施工されること、道路構造令第5条第4項に車線の幅員 3.5m と定められており、通常の 2 車線では 7.0m となることが挙げられる。また、舗装工事では、アスファルトフィニッシャーが中心となり施工が行われ、「フィニッシャーオペレーター」と「フィニッシャーアジャストマン」等の各作業員間の相対距離を想定する




図-23 オペレーターとの距離の考え方




図-24 オペレーターとの距離の考え方（施工場所真上）

としている。そのため、普通道路の 3.5m という幅員にさらに余裕を持たせてオペレーターを中心として直径 8m 程度と設定した。そのイメージを図-24 に示す。

これは仮に建設機械がバックホウであった場合でも、オペレーターと半径 4m 以内でスコップの作業員が作業をしていることを実際の現場にて多く確認できたため、この設定距離が適切であると判断した。

このように、建設機械のオペレーターより一定距離未満の場合は、建設機械付近でスコップといった直接生産動作を行っていると考え、直接生産動作を詳細に判別するプロセス⑤「特定作業動作」分析へと進む。一定距離以上の場合は、直接生産動作をしている可能性が低いと判断しプロセス③「単純動作」判別（歩行）へ進む。

d) プロセス③「単純動作」判別（歩行）

「単純動作」を判別するこの項目では、プロセス②建機オペレーターとの相対距離が一定以上の場合にのみ判断することになる。ここでは既構築システムにて、正答率、再現率、適合率がともに 80%以上の精度を持つ「歩行動作」の判別のみを採用する。

建設機械から離れているかつ、「歩行動作」も確認することはできない場合、生産性のある動作をしているとは考えにくい。しかし、「歩行動作」を伴うことなく生産性動作や補助支援動作を行っている可能性があるため、さらなる検討を進める必要がある。そこで、プロセス④一定以上の加速度の大きさの項目に進む。

一方で、建設機械から離れているが「歩行動作」をしていると認められた場合、作業員の自身の移動であったり、資機材の運搬や工具や材料の準備を行ったりしている可能性がある。よって、プロセス⑥「生産性動作」判別へと進む。

e) プロセス④一定以上の加速度の大きさ

「一定以上の加速度の大きさ」を判断するこの項目では、プロセス②建機オペレーターとの相対距離が一定以上あり、かつ、プロセス③単純動作判別（歩行動作）を伴わない動作をこの項目で判断する。

一定以上の加速度の設定は、x 軸、y 軸、z 軸のそれぞれの加速度(ax, ay, az)の合成をとることとした。

図-25 と図-26 は、「スコップマン」と「歩行動作」の合成加速度のグラフを示す。グラフの見方は、縦軸が加速度(m/s^2)、横軸が 1/50 s の回数である。

図-25 と図-26 から、通常時の合成加速度は $0.5 \sim 1.5 \text{ m/s}^2$ の範囲内におさまっていることが確認できる。




図-25 スコップマンの合成加速度

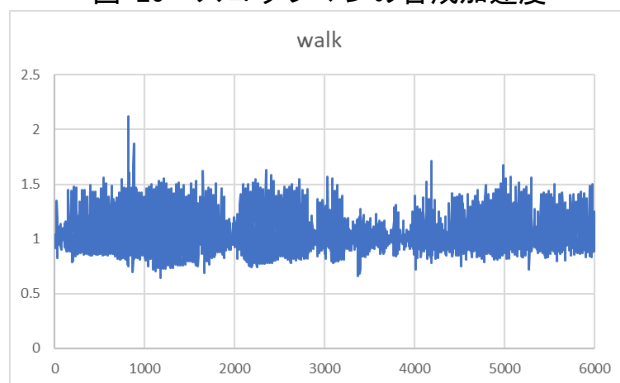


図-26 「歩行動作」の合成加速度

したがって、一定の加速度の大きさを、合成加速度が 0.5 m/s^2 以下、 1.5 m/s^2 以上と設定した。

建設機械から一定以上の距離があるかつ、「歩行動作」を伴わないが一定以上の加速度（合成加速度が 0.5 m/s^2 以下、 1.5 m/s^2 以上）が確認できた場合、何らかの作業を行っている想定し、プロセス⑥「生産性動作」判別へと進む。

一定加速度未満（合成加速度が 0.5 m/s^2 より大きく 1.5 m/s^2 未満）の場合、休憩といった作業遅延動作と考えるが、更なる裏付けとしてプロセス⑦施工エリア内外判定に進む。

f) プロセス⑤「特定作業動作」判別

「特定作業動作」判別では、プロセス②建機オペレーターと相対距離が一定未満での動作を判別する。

建設機械と一定距離未満にいる場合、作業頻度が高い「特定作業動作」を行っていると考えられる。舗装工事のような組み合わせ施工場合、アスファルトフィニッシャーを中心に「レーキマン」、 「スコップマン」といった敷き均しを行う作業員を想定している。「マカダムローラーオペレーター」周辺では、転圧を補助する「プレートコンパクター」といった作業員や、転圧範囲を指示する作業員を想定している。

この判断項目で、「特定作業動作」と判断される特徴を持った動作は、生産性動作区分において「直接生産動作」とプロセス⑨出力する。

「待機」といった「特定作業動作」以外の動作をしていると判断した場合、プロセス⑥「生産性

動作」判別に進む。

g) プロセス⑥「生産性動作」判別

「生産性動作」判別では、既に構築されているシステムを活用し、生産性動作をプロセス⑨出力する。ここでは、「直接生産動作」、「補助支援動作」、「作業遅延動作」の3つの生産性動作区分に分けられる。既構築の生産性動作判別システムで、深層学習を用いてプロセス⑨出力する。

h) プロセス⑦施工エリア内外判定

施工エリア内外判定では、作業員が施工エリアの中にいるのか、それとも離れているのかを判断する。この際、施工エリアをあらかじめ設定する必要がある。位置情報はスマートフォンで取得されている。出力されたデータを Google Earth で確認する、または施工エリアの緯度、経度を抽出し、csv ファイルにてエリア内外を判定することを想定している。

施工エリア内外判定は、プロセス②建機オペレーターから一定以上の距離であり、プロセス③「単純動作」判別にて「歩行動作」も認められず、プロセス④一定以上の加速度が認められない場合に判断する。エリア内にいると判断された場合は、プロセス⑥「生産性動作」判別へ進む。エリア外にいると判断された場合は、プロセス⑧温湿度の変化に進む。

h) プロセス⑧温湿度の変化

温湿度の変化は、プロセス②建機オペレーターから一定以上の距離であり、プロセス③「単純動作」判別にて「歩行動作」も認められず、プロセス④一定以上の加速度が認められないかつ、施工エリア外にて活動している時に判断する。

ここでは、主に位置情報の補完的な役割をする。特に、作業員の休憩時に役割を発揮する。舗装工事では、高温のアスファルト合材を扱うことから、作業員は作業中に常時熱にさらされる環境下にある。このことから休憩時には、高温の環境下から離れると予測した。季節限定になってしまうが、夏場の作業では炎天下の作業の場所から離れて、冷房が効いた環境下で休息をとることを想定した。また冬場は、寒い環境ではなく、温かい場所に身を置くと考えた。

しかし、春や秋といった季節では温度変化が認められない場合もあるので注意する必要がある。以上の理由から、明らかな温度変化が認められた場合は休憩をとっていると判断し、「作業遅延動作」としてプロセス⑨出力する。温度変化が確認できなかった場合はプロセス⑥「生産性動作」判別に進み判断することになる。

i) プロセス⑨出力

このシステムの最終目標は、「生産性動作」、「補助支援動作」、「作業遅延動作」の大まかな3区分、あるいはさらに細分化した「作業構成要素区分」を判断することである。プロセス①で入

力されたデータを、プロセス②から⑧まで様々なプロセスを経て出力をする。そこで、今後は、これらのプロセスを統合するシステムの開発が必須となる。現状は部分的なシステム構築のみに留まっている。

(3) 温湿度計の活用による可能性

これまでデータ取得は行っていたものの、分析に考慮していなかった新たな判断指標として温湿度データを活用することを検討した。温湿度データは、作業員がどのような労働環境の下で作業を行っているかを把握するためのみにデータサンプリングを行っていた。

システム改良にあたり、「作業遅延動作」の「休憩・定められた小休止」において、判断指標の一つになる可能性あると考え、温度変化の活用が有効であるか検証した。

検証方法は、収集した温度データをグラフにして可視化した。図-27は、2022年12月23日の作業員ヘルメットに装着された温湿度計の温度変化をプロットしたものである。このデータは12月下旬に取得されたデータであるため、屋外はかなり冷え込んでいることがわかる。気象庁のデータ（図-27の下点線）によると、羽田の温度は10℃付近を記録している。




図-27 2022年12月23日の作業員の温度変化

一方で現場事務所は、暖房の効果で温かい環境であると考えられる。したがって、作業開始前と終了後のタイミングで、温度は上昇傾向にあると考えられる。読み取れることとして作業開始前のタイミングと、昼休憩のタイミングで明らかな温度変化を確認することができる。

したがって、冬季の建設現場においては温度変化が明らかに確認できた。これより、位置情報を補完できる可能性が示唆された。

図-28は、2023年3月29日の作業員の温度変化をプロットしたものである。作業開始と切り上げのタイミングで温度が各作業員ほぼ一致していることがわかる。

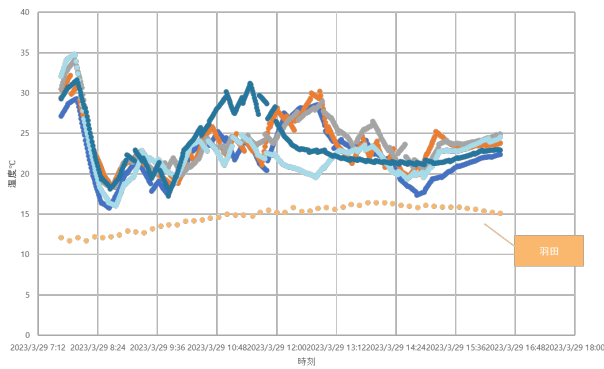


図-28 2023年3月29日の作業員の温度変化

しかし、昼休憩のタイミング（12時から13時）のタイミングで温度が上昇している作業員がいる一方で、明らかな変化が認められない作業員も確認できた。

以上より、春季の工事現場において昼休憩のタイミング把握することは温度データだけでは判断できない場合があることも確認された。しかし、位置情報データと組み合わせることによってデータを補完したり、作業開始や切り上げといったタイミングを把握したりするには有効となる可能性もある。

(4) データ取得 Android アプリケーションの開発

これまでの現場でのデータサンプリングにて、様々なデータ取得作業の失敗を繰り返してきた。このため、失敗しない方法を確立し、マニュアルの作成と改良を実施してきた。

また、現場にてデータサンプリングの際、時刻合わせやセンサ類とスマートフォンの Bluetooth 接続の手間や確認作業に時間を要していた。さらにヘルメットにセンサ類を装着するなどの作業で、作業員に時間を割いてもらう必要があった。さらに休憩時には、接続に問題がないか、いったん回収して確認し、午後の作業に向けて再度装着するといった作業も生じていた。

データサンプリングを行った後も、データの出力作業にも時間と人手を要した。サンプリングする作業員が多いとその分作業コストもかかった。

このような問題を受け、一つのアプリケーションでセンサ類の Bluetooth 接続とファイルの出力が可能で Android アプリケーション開発を実施した。

加速度センサ、温湿度計、GPS の3つが同時にデータ記録を開始し、同時に記録を停止できる。

また、センサ類との Bluetooth 接続が切断された場合は、再接続を試行する。切断と同時にアラームとバイブレーションで作業員に知らせる仕様となっている。

図-29 はアプリケーションの概要を示すものである。市販モーションセンサーから加速度と角速

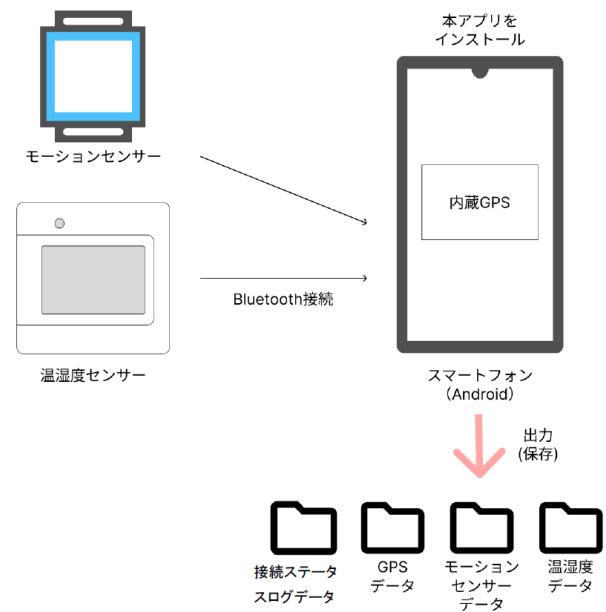


図-29 開発した Android アプリケーション

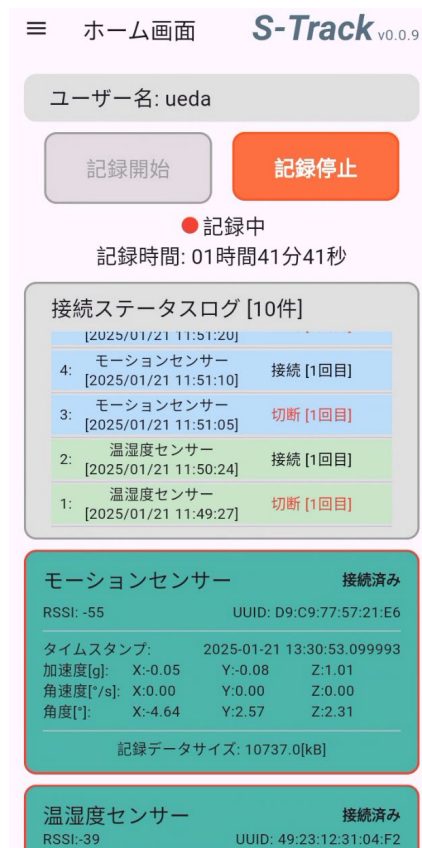


図-30 アプリケーションのホーム画面

度情報を Android スマートフォンのデータロガーに保存する。また、温湿度センサーの記録も同様に保存する。位置情報についてはスマートフォンに内蔵されている機能を活用して、これも同様に記録する。これらの記録はスマートフォンの時刻情報に一元化されて保存されるため、各データの時刻歴に齟齬がでることはない。併せて、上記の再接続やアラーム機能に加えて接続データのログも取得しており、万一切断されてしまった場合の

原因追及にも資するものとなっている。

図-30 はアプリケーションのホーム画面である。図に示す通り、操作者はそれぞれ接続している端末と記録しているデータを確認することができる。

Android アプリケーションの基本設計書、詳細設計書および仕様書は別途参考資料として添付する。

(5) 改良システムによる動作分類と課題

新たに構築した舗装特有の作業動作を考慮した生産性動作判別システムに沿って動作分類を試みた。プロセス②建機オペレーターとの相対距離を出力した。位置情報データでは、緯度と経度を取得している。地球の半径を 6371km とし、計算処理がしやすいため地球を真球とした。表-4 は、図-23 と図-24 の作業のフィニッシャーアジャストマンとレーキマンの位置から計算された距離情報の一部である。

表-4 作業員の同士の距離の一例

時刻	アジャストマン		レーキマン		両者の距離 単位 (m)
	北緯	東経	北緯	東経	
11:03:57	36.05779	139.53022	36.05780	139.53021	1.82
11:03:58	36.05781	139.53023	36.05780	139.53021	2.46
11:03:59	36.05780	139.53024	36.05780	139.53021	2.46
11:04:00	36.05780	139.53024	36.05780	139.53021	2.58
11:04:01	36.05780	139.53024	36.05780	139.53021	2.55
11:04:02	36.05780	139.53024	36.05780	139.53021	2.70

このデータはスマートフォンに搭載される GPS データを独自開発したデータ統合用アプリケーションにて取り込んだものである。このように、別センサで取得された加速度データや温湿度データと並列してデータを分析する基盤が整えられていることが確認された。

データ統合用アプリケーションの仕様上は 1 秒間ごとに 1 データ取得することとなっている。しかし、表-4 に示すようにすべてのデータが均等に 1 秒間ごとに取得できているわけではなく、不定期なデータ欠損があることも確認された。また、明らかに遠方で異常値と考えられる位置情報を取得しているケースも見受けられた。概ね、作業中はプロセス②で設定したオペレーターから半径 4m 以内という閾値内に作業員が位置していることが確認されたが、一部、そうではない（作業状況を撮影した動画によると明らかに 4m 以内にいるものの、データ上は 5m 以上離れていると示された）データも確認された。道路構造令による道路仕様から、既存システムでは 4m 以内という閾値を設定したが、スマートフォンの GPS データを使う場合はその精度の限界を考慮して閾値の設定を今後見直したり、異常値の排除を行う余地がある。

次にプロセス⑦施工エリアの内外判定をおこなうシステムを作成し、運用を試みた。運用においては施工エリアの座標を抽出し、各作業員が施工エリア内にいるかいないかを判定する内外判定を行った。運用を試みたデータは 2023 年 10 月 11 日に実施された晴海における作業エリアであり、これを図-31 の紫色で囲んだ部分として示す。なお、上述の位置情報データの誤差も考慮して、道路幅と同等の余裕を持った形で設定した。注意すべき点は、舗装工事は時間経過とともに作業場所が異なってくるため、施工エリア内にいると判断されても、実際の施工場所ではない可能性があるため、他の作業員や建設機械との距離も並行して確認する必要もある。

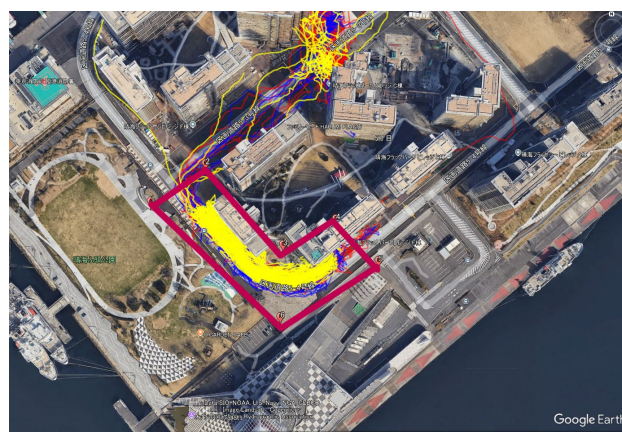


図-31 設定した施工エリア（紫色枠線内）

(6) 新システムの構築状況のまとめ

ここまでに構築されたサブシステムのそれぞれのプロセスを統合する必要がある。これまで述べてきた各サブシステムの開発・運用状況を図-32 に追記する形で述べる。

②建機オペレーターとの相対距離の把握については、データ統合用アプリケーションに取り込めることが確認された。この出力を⑤「特定動作」判別に入力することになる。

③「単純動作」判別については、笠井よって構築されたサブシステムを、2023 年 10 月 11 日に実施された晴海で取得されたデータを使って分析することができることが改めて確認された（表-5）

表-5 歩行の精度検証結果

1D-CNN	歩行 (walk)	
	従来	新定義
正解率 (%)	69.75	71.17
適合率 (%)	40.19	72.91
再現率 (%)	54.63	71.17
F値 (%)	46.31	71.91

④一定以上の加速度の大きさの判別については、試行的に 3 軸合成加速度が 0.5 m/s^2 以下、 1.5 m/s^2 以上として設定して運用したところ、サブシステムの正常稼働が確認された（図-25、図-26 に示した）

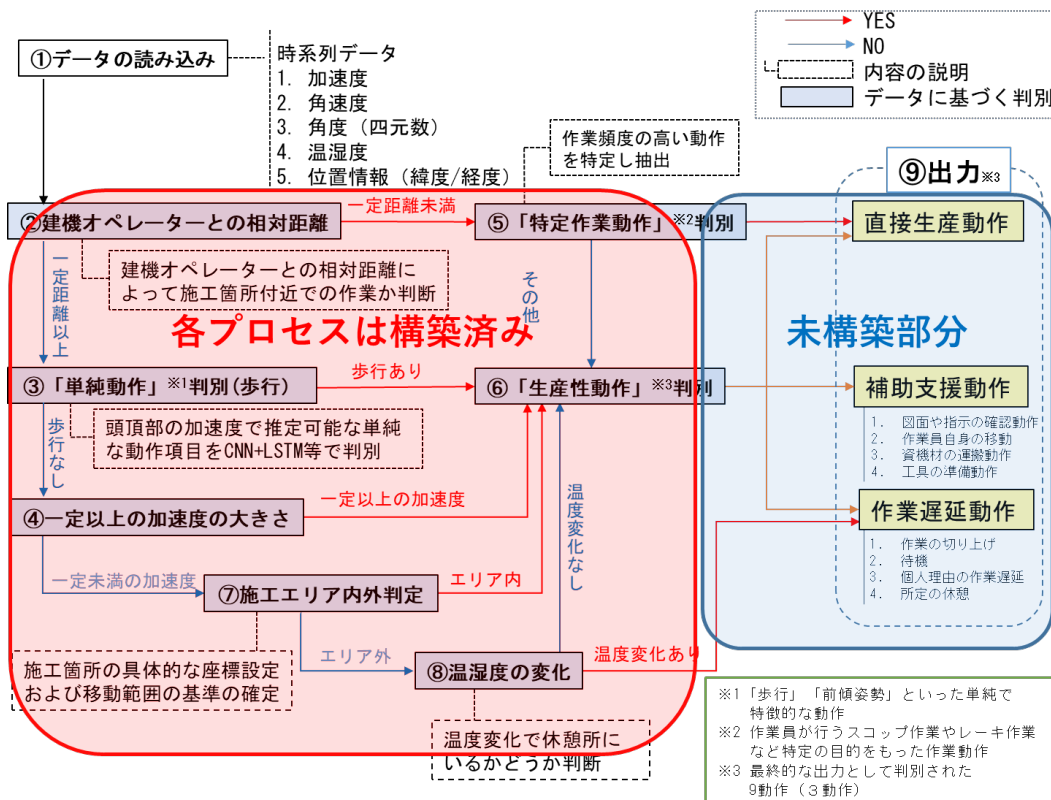


図-32 システムの構築状況まとめ

⑤特定作業動作判別については 2024 年 8 月に実施した鴻巣での試験施工データに基づいて分析しており、部分的にだが正常稼働が確認された。図-33 は特定作業動作判別を精度検証の混同行列の結果である。

タイヤショベル	102	12	1	4	19	25
マカダム	21	87	17	11	13	7
レーキ	0	5	96	26	1	9
スコップ	1	4	29	79	8	15
停止	21	10	2	5	72	24
歩行	20	3	8	9	20	84
	タイヤショベル	マカダム	レーキ	スコップ	停止	歩行

図-33 「特定作業動作」分類の混同行列

⑥生産性動作判別については、現システムではサブシステムが構築されているが、本研究で新たに設定した④⑤⑦⑧に対応するシステム構築には至らなかった。

⑦施工エリア内外判定については、正常稼働が確認された。

⑧温湿度の変化については、正常稼働とデータ活用の有効性と課題が示された。

本研究では、舗装工事に対する改良を加える以前 (5 章の段階) の状況では稼働していた図中の青枠線部分で示したプロセスについては、舗装工事を対象とする形で改良したプロセスを反映するシステム構築の完成には至らなかった。

これらのプロセスを実現するシステムの構築には、時刻データの取り扱いが重要になってくる。プロセス③「単純動作」判別、⑥生産性動作判別については既に笠井により構築済みである。これは、時刻歴を持った加速度データを入力値として、プロセス③にて「単純動作」を出力する。この段階では時刻データが維持されている。出力された「単純動作」をプロセス⑥にて分析し、出力の際は、時刻データを持たない形の分析結果としての混同行列が得られる形となっている。本研究で構築したサブシステムのプロセス②④⑤⑦⑧はいずれも時刻データを持っており、⑥生産性動作判別の入力値として活用されることになる。現状のプロセス⑥の入力値は時刻データを持つ③のみであるが、これにプロセス②④⑤⑦⑧も入力値として加える必要がある。その際は、時刻データを揃える必要があるが、そのことについては独自開発したデータ統合用アプリケーションにてカバーされている。今後は、この基盤において、プロセス⑥を複数のデータを入力値として設定することので

きるサブシステムとして構築する必要がある。また、判断プロセスを確認し、改良を加えてゆくためには、時刻毎の判断結果も得られる形の出力ができるように変更する必要が考えられ、今後の課題として残される形となった。

7. まとめと今後の展望

(1) 個別の要素（教師データラベル・データ取得方法・アルゴリズム）設定と精度向上にむけた改善の必要性

本研究では、単一 IMU から得られる加速度データを深層学習のアルゴリズムである CNN と LSTM を用いて生産性動作区分判別を行う HAR 手法についての基礎となる単純動作の分類を行った。また、教師データラベルについては当初は秒間 50 データの加速度データと紐づける都合から、1 秒ごとにラベルを作成したが、1 日を通しての出来形と出来高や従事した直接生産動作を比較・検討するにはより適切な時間幅で教師データラベルを定義する必要があると判断し、30 秒ごとの連続した動作を考慮する形で改良も加えた。

なお、既存の HAR 研究のように一定の動作を繰り返し続けて教師データを作成することは「複合的な建設現場作業」の再現とは性質の異なるものになってしまう懸念があるため、教師データの作成方法については継続的に実際の現場で作業員のデータを地道に収集する必要がある。

本研究で使用したアルゴリズムは CNN および LSTM であったが、これは時系列データ処理が行えることから注目したものである。同様に系列データを処理できるアルゴリズムとして

Transformer や GBDT が挙げられるがこれらの手法によっても判別が期待できる。しかし、一般に使用するアルゴリズムは線形モデル様であれば計算コストが低下し高速化が見込める。また SVM やそれに準ずるアルゴリズムは二値分類を高精度で行える一方で非常に計算コストが高く処理に時間を要する。GBDT や Transformer はこれらのちょうど中間位の速度であり、CNN などと比較すると計算が早いとされている。現段階ではリアルタイムの生産性把握は検討していないが、リアルタイム性を求める場合は精度と同時に計算速度についても追求する必要がある。

(2) 今後の展望

本研究では、加速度の画像化プロセスと深層学習アルゴリズムの導入によって生産性動作判別が行えるかどうかの検証が主となった。この点はシステム構築は実現できたと考えられ、今後はデータ取得を蓄積し、設計の妥当性を評価し、改善を続ける必要がある。

これまでに観測できた現場の特徴の例としては、作業パーティによる作業の考慮が挙げられる。建設現場における作業はユニットごと・パーティごとに一定の人数と建設機械をセットとして動くことが基本となっている。そのため作業員個別の作業従事情報に留まらず、作業員同士のインタラクションや建設機械とのインタラクションなどを考慮することでより高精度に現場全体の生産性を計測できる余地が残されている。こういった情報を特徴量に落とし込む上では、特に位置情報の活用は非常に有用であり、屋外であれば GNSS（Global Navigation Satellite System）による測位を行ったり、ロガーとして使用しているスマートフォン同士を Bluetooth など通信することで作業員同士の近接度合いを検出したりすることで、より建設現場の作業実態に適合したデータの取得が可能になると考えられる。本研究では位置情報の取得と把握については実現できたため、今後のデータ取得による洗練を図る。

加えて IMU には加速度以外に、磁気・角度などもサンプリングできる機能が統合されているため、それらのデータを使用することで精度の向上が見込める。

成果としては、加速度を画像的に処理することによって深層学習手法を十分に適用させることができることが確認された。歩行と前傾姿勢については、前傾姿勢の分類が正答率 92.1%、適合率 98.5%、再現率 93.4% の高水準となり、また、歩行については正答率 80.0%、適合率 82.2%、再現率 84.2% と概ね良好な精度で判別可能なことが示された。その一方で過学習傾向の抑制や学習データの増強などの新たな課題も見つかった。

また、既存の生産性動作区分と深層学習によって判別しやすい動作を紐づけるべく、新しい動作定義として「歩行の有無（walk）」「前傾姿勢の有無（bent）」「周期的・規則的な動作（repetitive motion）」「周期性を持たない特徴的な動作

（characteristic motion）」「分類に寄与しないが大きい動作（ineffective motion）」5 つの単純な判別項目を設定した。

そのうえで、教師データの作成のルールを再考し分析の時間間隔を 1 秒から 30 秒という余裕を持った時間幅で作業員の動作にラベル付を行った。これにより、正解率においては精度向上とはならなかったものの、適合率、再現率、F 値においては 2～3 割の精度から 4～5 割の精度に向上した。

また、「直接生産動作」と一つの括りになっていたものを舗装工事に特化する形で細分化することも試み、17 の「特定作業動作」を新たに定義した。「特定作業動作」を定義することによって、それぞれ動作の特徴を把握し、「直接生産動作」の精度が向上することが期待できる。

位置情報を活用することによって、作業員の位

置や作業員同士の距離を把握することで生産的な活動を行っているのか、または「作業遅延動作」なのかを特定した。

位置情報の更なる裏付ける情報として、温度データを活用し、作業員の温度変化を確認することで休憩といった行動を把握することに成功した。

データサンプリングの際、手間取っていたセンサの接続や、ファイルの出力をより簡単に分かりやすく作業できるようにアプリケーションの開発を実施した。これにより、今後の現場データ取得の効率性が飛躍的に高まることとなる。

こういった取り組みを行ってきたが、精度向上の課題もあり、システムも未完成の部分がある。

「生産性動作判別」や「単純動作判別」といったシステムは構築済みであるが、さらに「特定作業動作判別」や位置情報を統合する環境を構築する事項が開発上の課題として残されることとなった。

精度向上においては、センサ類を増やす方法もあるが、本研究では現場においては必ず装着することが義務となるヘルメットに埋め込むことを想定し、作業員への負担も考慮してその方法をとらなかった。既往の HAR で高精度に動作認識を行っていた理由の一つは、大腿部や胸部、手首などに取り付けすることで精度を担保していたことによる。これに対して、これらの装着位置では建設作業員の関節や筋の動作を制限しかねない。そのため、データ量を増加させることやコードを改良することで精度向上を目指すこととなる。

スポーツのように自由意思で行っている活動や、医療のように自分自身のために行われることが明白な事項については、各種センサを身体に装着することに対して忌避感を感じることはない。しかしながら、本研究のように、使用者の指示の下で行われる「労働」という活動において、各種センサを複数、しかも四肢や胸部に装着され、データを取得されることに対して、作業員は大変な忌避感を感じるであろうことは明白である。こういったことに配慮して、本研究では、現場においては必ず装着することが義務となるヘルメットに埋め込むことを想定して、ヘルメットのみへのセンサ装着を作業員に依頼した。それでも、趣旨説明等については十分な配慮が必要であった。

しかしこの条件でもある程度の精度が確保できたことから、今後のウェアラブルセンサの発展と、社会変化によるセンサ類への忌避感の変化によっては、センサの装着位置や装着個数の違いによってより高精度化が実現されることが期待される。現に、西暦 2000 年より以前は市街地や職場内に監視カメラを置いたり、GPS での位置情報を把握されることに対する忌避感は小さなものではなかったが、2020 年代には治安維持やエビデンス確保の一環として一定の利用が社会的に許容されるようになった。こういった社会的常識の変化

により、複数センサを装着することが許容される環境が成立すれば、さらなる精度の向上が期待できる。

映像データから行動を分析する方法は、建築工事といった施工場所が固定されている現場であれば可能だが、舗装工事といった施工場所が変化する工種では適用が難しい。本研究グループでは、教師データを作成するために撮影している映像データより、教師データの作成を自動化するという目的で、映像データからの動作推定することに着手している。

このように、本研究助成により、データを取得、分析しつつ端末開発ができたことから今後のデータ蓄積の基盤が整えられた。本助成に深く感謝する次第である。今後はデータ蓄積、分析、システム改良を繰り返す段階となる。本成果の活用による成果拡大に今後も努めたい。

謝辞：本研究においては、機器動作に関するアプリケーション制作において、株式会社トアックの全面的なご協力をいただきました。また、本研究には修士研究として笠井琉司氏と秋山瑞樹氏に組みんでいただきました。心より感謝いたします。

参考文献

- 1) 草柳俊二：国際建設プロジェクトの生産性向上プログラムに関する研究，土木学会論文集 No. 528/VI-29, pp. 143-154, 1995.
- 2) Tomoyuki Gondo, Reiji Miura : Accelerometer-Based Activity Recognition of Workers at Construction Sites, Frontiers in Built Environment. 6, 563353. 10.3389/fbuil.2020.563353., 2020.
- 3) 楠本雅博, Ayiguli AINI, 全邦釘：建設現場における人工知能の活用事例, AI・データサイエンス論文集, 2020, 1 巻, J1 号, p. 301-306, 2020/11/18.
- 4) Takenaka Corporation 2016 System to track the location of elevating vehicles and workers in the construction site (Available at: <https://www.takenaka.co.jp/news/2016/02/01/index.html> Accessed 10.05.2022).
- 5) 五艘隆志, 越智淳, 草柳俊二：建設現場における先端情報技術を活用した生産性管理データ収集・分析システムの構築に関する研究, 土木学会論文集 F4 (建設マネジメント) 特集号 Vol. 66 No. 1, pp317-328, 2010.
- 6) 五艘隆志, 弘光太郎：建設現場における ZigBee と加速度センサの活用による生産性管理データの収集・分析システム, 月刊自動認識, 巻 28 号, pp25-30, 2015.
- 7) GOSO Takashi : Development and improvement of labor productivity assessment system in

- construction site by using Information Technology, Journal of Society for Social Management Systems (Peer-reviewed), pp. SMS11-9178, 2012.
- 8) 草柳俊二, 五艘隆志: 建設マネジメント分野の可視化～プロジェクトの遂行過程を可視化する～, 土木学会誌 Vol. 96, pp. 30-32, 2011.
 - 9) 大澤 徹郎, 五艘隆志: 建設現場における作業判別の自動化プログラムの構築, 第 75 回土木学会年次学術講演会講演概要集, VI-783, 2020. 9
 - 10) 大澤 徹郎, 五艘隆志: 事前分類と機械学習の組み合わせによる生産性区分分類システムの構築, 第 46 回土木情報学シンポジウム, 1-4, 2021. 9
 - 11) 五艘隆志, 武藤一伸, 濱野満, 大澤徹郎, 笠井琉司: 機械学習を用いた建設現場の労働環境・生産性データ収集分析システムの開発, 舗装 57 巻 6 号, pp. 3-8, 2022.
 - 12) 橋本信歩, 高前田伸也: 機械学習ベースの動画像処理における近似計算手法の検討, IEICE Technical Re-port CPSY2021-59, DC2021-93, 2022.
 - 13) Mohammad Helal Uddin, Jannat Mir Kanon Ara, Md Hafizur Rahman, S.H. Yang: A Study of Real-Time Physical Activity Recognition from Motion Sensors via Smartphone Using Deep Neural Network, 5th International Conference on Electrical Information and Communication Technology (EICT), 2021.
 - 14) KangHo Lee, SangUk Han: Convolutional neural network modeling strategy for fall-related motion recognition using acceleration features of a scaffolding structure, Automation in Construction Volume 130, October 2021, 103857, 2021.
 - 15) 今井龍一, 神谷大介, 井上晴可, 田中成典, 櫻井淳, 坂本一磨, 藤井琢哉, 三村健太郎, 伊藤誠: 建設現場の安全管理に向けた人物識別の試行に関する研究, 土木情報学シンポジウム講演集, Vol. 43, No. 37, pp. 145-148, 2018.
 - 16) Ryan Sanford, Siavash Gorji, Luiz G. Hafemann, Bahareh Pourbabaei, Mehrsan Javan: Group Activity Detection from Trajectory and Video Data in Soccer, 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020.
 - 17) Yuuki Jin, Genki Suzuki, Hiroyuki Shioya: Detecting and Visualizing Stops in Dance Training by Neural Network Based on Velocity and Acceleration, Sensors 2022, 22, 5402., 2022.
 - 18) Mst. Alema Khatun, Mohammad Abu Yousuf, Sabbir Ahmed, Md. Zia Uddin, Salem A. Al-yami, Samer Al-Ashhab, Hanan F. Akhdar, Asaduzzaman Khan, Akm Azad, Mohammad Ali Moni: Deep CNN-LSTM With Self-Attention Model for Human Activity Recognition Using Wearable Sensor, IEEE Journal of Translational Engineering in Health and Medicine (Volume: 10), 2022.
 - 19) Shreehar Joshi, Eman Abdelfattah: Deep Neural Networks for Time Series Classification in Human Activity Recognition, 2021 IEEE 12th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), pp. 559-566, 2021.
 - 20) Zhai Wenzheng: Human Activity Recognition based on Acceleration sensor and Neural Network, 2020 8th International Conference on Orange Technology (ICOT), 2020.
 - 21) Meenakshi Kandpal, Rabindra K. Barik, Sudhansu Shekhar Patra, Bhisham Sharma, Subrata Chowdhury, Imed Ben Dhaou: Human Activity Recognition in Smart Cities from Smart Watch Data using LSTM Recurrent Neural Networks, 2023 1st International Conference on Advanced Innovations in Smart Cities (ICAISC), 2023.
 - 22) Chrisogonas O. Odhiambo, Sanjoy Saha, Corby K. Martin, Homayoun Valafar: Human Activity Recognition on Time Series Accelerometer Sensor Data using LSTM Recurrent Neural Networks, CSCE Conference SPRING NATURE, <https://doi.org/10.48550/arXiv.2206.07654>, 2022.
 - 23) Schalk Wilhelm Pienaar, Reza Malekian: Human Activity Recognition using LSTM-RNN Deep Neural Network Architecture, 2019 IEEE 2nd Wireless Africa Conference (WAC), 2019.
 - 24) Yoshihaya Takahashi, Kosuke Nakamura, Takeshi Kamiyama, Masato Oguchi, Saneyasu Yamaguchi: Person Identification Based on Accelerations Sensed in Smartphones with LSTM, Journal of Information Processing Vol. 29 707-716 (Oct. 2021), 2021.10.
 - 25) Sai Siddarth Vakacherla, Prakyath Kantharaju, Meet Mevada, Myunghee Kim: Single Accelerometer to Recognize Human Activities Using Neural Networks, J Biomech Eng. 2023 Jun 1;145(6):061005. doi: 10.1115/1.4056767. PMID: 36695756., 2023.
 - 26) Tessai Hayama, Rena Arakawa: Walking-posture Classification from Single-acceleration sensor Data using Deep Learning and its Evaluation, International Journal of Service and Knowledge Management International Institute of Applied Informatics 2021, Vol. 5, No. 2, pp. 23-36, 2021.
 - 27) 大井健矢, 松下光範, 堀寛史, 高岡良行: ウェ

- アラブルセンサによる歩行データからの転倒動作検出の試み, 人工知能学会第28回インタラクティブ情報アクセスと可視化マイニング研究会予稿集, pp.1-8, 2022.
- 28) 河村知輝, 土田修平, 寺田努, 塚本昌彦: ウェアラブルセンサを用いた動作計測実験における機器装着バイアスの検証, 情報処理学会インタラクシオン2021, pp.21-30, 2021.
 - 29) 嘉本敬樹, 洗光範: 建設機械の予防安全技術—マシンモニタリングシステムの開発—, 竹中技術研究報告 No.67, 2011.
 - 30) 北村和也, 小高知宏, 黒岩丈介, 諏訪いずみ, 白井治彦: 加速度データからの機械学習による行動認識, Mem. Grad. Eng. Univ. Fukui, Vol. 68, pp.59-65, 2020.
 - 31) 相原伸平, 石部開, 佐武陸史, 岩田浩康: 慣性センサデータを用いたディープラーニングによる空手動作識別手法の開発, 日本機械学会論文集 Vol.78, No.903, 2021.
 - 32) 中原英里, 塩田哲哉, 豊田真智子: 説明可能な多変量時系列異常検知手法, The Institute of Electronics, Information and Communication Engineers Forum on Information Technology 2021 (FIT), 講演集第2分冊 pp.423-429, 2021.
 - 33) 張凱峰, 梅澤猛, 大澤範高: 特徴量次元と時系列予測モデルが日常動作識別精度に与える影響の評価, The Institute of Electronics, Information and Communication Engineers Forum on Information Technology 2019 (FIT), 講演集第2分冊 pp.287-288, 2019.
 - 34) 平澤直之, 清水大地: 深層学習を利用したブレイクダンスにおける動作の判別・可視化システムの開発とその応用, 情報処理学会研究報告 IPSJ SIG Technical Report Vol.2018-HCI-179 No.4, 2018.
 - 35) Fahima Hajjej, Madiha Javeed, Amel Ksibi, Mohammed Alarfaj, Khaled Alnowaiser, Ahmad Jalal, Nawal Alsu-fyani, Mohammad Shor-fuzzaman, Jeongmin Park: Deep Human Motion Detection and Multi-Features Analysis for Smart Healthcare Learning Tools, IEEE Access (Volume: 10), 2022.
 - 36) 我妻正太郎, 中川真史, 小野智義, 高橋伸, 志築文太郎, 嵯峨智: 無線型加速度センサと畳み込みニューラルネットワークを用いた触対象の分類, ロボティクス・メカトロニクス講演会講演概要集 2018 (0), 1P1-K14-, 2018.
 - 37) 西田拓也, 瀬戸康平, 矢吹信喜, 藤島崇: 生産性向上支援システムの映像認識 AI を用いた建設現場の可視化, 土木情報学シンポジウム講演集 vol.44, pp.177-180, 2019.
 - 38) 田中陸人, 矢吹信喜, 福田知弘: ヘルメット装着型端末を用いた OWAS 法に基づく建設作業員の姿勢推定システムの開発, 土木学会論文集 F3 (土木情報学), Vol.77, No.2, pp.114-123, 2021.
 - 39) 笠原弘樹, 伊藤智則, 吉井英樹, 鶴丸和宏, 小松尚久: 加速度データの周期性に着目した歩行状態の識別に関する一考察, 電子情報通信学会技術研究報告 = IEICE technical report: 信学技報 111(50) 2011.5.19・20, pp.1-6, 2011.
 - 40) 村尾和哉, 寺田努: 加速度センサの定常性判定による動作認識手法, 情報処理学会論文誌 vol.52, No.6, pp.1968-1979, 2011.
 - 41) Lin Liao, Dieter Fox, Henry Kautz: Location-based Activity Recognition, Advances in Neural Information Processing Systems 18 [Neural Information Processing Systems, NIPS 2005], 2005.
 - 42) Hao Chena, Seung Hyun Cha, Tae Wan Kim: A framework for group activity detection and recognition using smartphone sensors and beacons, (SD)Building and Environment Volume 158, pp.205-216, 2019.
 - 43) Chris Sabillon, Abbas, Rashidi, Biswanath Samanta., Mark A.Davenport, David V.Anderson: Audio-based bayesian model for productivity estimation of cyclic construction activities, Journal of Computing in Civil Engineering, Vol.34, No.1, 2020.
 - 44) Chieh-Feng Cheng, Abbas Rashidi, Mark A.Davenport, David V. Anderson: Activity analysis of construction equipment using audio signals and support vector machines. Automation in Construction, Vol.81, pp.240-253.2017.
 - 45) Liju Joshua, Koshy Varghese: Construction Activity Classification Using Accelerometers, Construction Research Congress 2010. pp.61-70, 2010.
 - 46) Carlos Hernandez, Trevor Salton, Vahid Balali, Reza Akhavian: A Deep Learning Framework for Construction Equipment Activity Analysis, Journal of Computing in Civil Engineering, pp.479-486, 2019.
 - 47) Khandakar Mamunur Rashid, Joseph Louis: Automated Activity Identification for Construction Equipment Using Motion Data From Articulated Members, Frontiers in Built Environment, Vol.5, article 144, January 2020.
 - 48) 倉沢央, 川原圭博, 森川博之, 青山友紀: センサ装着場所を考慮した3軸加速度センサを用いた姿勢推定手法, 情報処理学会研究報告 IPSJ SIG Technical Report Vol.2006-UBI-11 No.3, 2006.
 - 49) 佐藤僚太, 波部斉, 満上育久, 佐竹聡, 鷺見和彦, 八木康史: 行動の一部に見られる特徴に着目する歩行者グループ検出, 知能と情報, 2016, 28 巻, 6 号, pp.920-931, 2017.