

(16) 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

大澤 徹郎¹・五艘 隆志²

¹学生会員 東京都市大学 大学院総合理工学研究科 (〒158-8557 東京都世田谷区玉堤1丁目28番1号)

E-mail:g2081604@tcu.ac.jp

²正会員 東京都市大学准教授 建築都市デザイン学部 (〒158-8557 東京都世田谷区玉堤1丁目28番1号)

E-mail:tgoto@tcu.ac.jp

建設産業における労働環境改善や生産性向上には、データ取得者の主観を含まない自動モニタリングシステムが必要である。本研究では、多様な建設現場で活用可能な生産性区分分類システムの構築を目指し、作業員の加速度と位置情報から事前分類を行い、機械学習を用いる段階的なシステムフローを考案した。本論文ではシステム内の加速度を扱うフェーズの検証結果について記しており、建設現場作業を目視で確認した作業状況を6つのクラスに分類し、提案システムで分類した結果と比較することで精度検証を行った。検証の結果、事前分類は機能したが精度向上には新たな分類項目が必要なことも明らかになった。

Key Words : *productivity data, machine learning, kinematic-based methods, accelerometer*

1. はじめに

我が国における建設プロジェクトのマネジメントの生産性管理データは現場の技術者達が、出面（出勤）記録と出来形記録にもとづき個人データとして収集・分析されているものを活用している状況である。また、出面記録と出来形記録については、近年一部の大型現場では顔認証等のシステムが導入されているものの、基本的には手動で取られており、一定の精度による取得という点で限界がある。公的組織によるアンケート方式の歩掛調査においては情報提供者の主観が入る余地を残す点で、労働環境や生産性の分析、業務改善項目の抽出には課題が残る旨の指摘もなされている¹⁾。筆者らはこういった主観を含まない生産性管理データを収集・分析できるシステムの構築に取り組んでいる²⁾。

国内外においてウェアラブル端末を使って作業員の動向を調査・分析する手法や事例が報告されている³⁾⁴⁾。作業員の動作を判別する事例も多いが、スマートフォンと手首・腿に装着したジャイロセンサから運動強度を精密に計測する実験的研究³⁾や、安全管理のための全体フレームワーク提示⁴⁾といった内容であり、本研究で目指す継続的に取得したデータに基づき労働環境と生産性を一体的に改善する方向性とは異なる。

近年、動作認識技術には機械学習が広く用いられて

いる。主な建設現場の機械学習による動作認識手法は、「運動による認識(kinematic-based methods)」と「映像による認識(computer vision-based methods)」である。Kimら⁴⁾は建設現場のカメラ映像から、作業員と建設機械の位置関係などを把握することで安全度を可視化する研究を実施した。映像による作業判別は幅広い動作に対して応用可能な一方、背景の違いや光量の違いによって精度に影響があることから、安定した分類ができにくい欠点があることも指摘されている。

本研究では、労働環境と生産性を一体的に把握可能なシステムの構築を目的とし、データ取得には環境に左右されずに安定的なデータ解析が可能なことから加速度と位置情報を用いることを検討した。続いて、多くの建設現場に適用可能なシステム構築を検討し、データの前段階での分類と機械学習の組み合わせの可能性について検証した。

2. 提案システム

(1) システムの概要

本研究では建設現場における多様な作業を分類することを目的としており、全ての作業の教師データを準備し、機械学習により分類することは現実的ではない。




図-1 提案システムの概要

村尾ら⁵⁾の研究によると、「歩く」や「走る」などの単純動作はあるデータの繰り返しからなることに着目し、加速度データの自己相関関数を求めることで運動の定常性を判定していた。変動有無の検出と定常性判定の段階を組み込むことで姿勢、運動、ジェスチャの判定が機械学習のみで判別を行う場合よりも精度が向上していた。この研究結果を参考にし、変動検出と定常性判定のフェーズを組み込むことでより汎用性の高いシステムを構築することを目指している。本研究で提案するシステムの概要は図-1に示す。本論文では現在までに構築が完了している特徴量の抽出以降の検証結果について述べていく。

(2) 変動検出に関して

加速度に何らかの動作のための変化がみられることを「変動」と定義する。既往研究⁵⁾において変動検出は現在時刻を $t=T$ とすると、時刻 $t=T$ から過去10サンプル（1秒）のセンシングデータの移動平均 $\bar{x}(T)$ と現在のセンシングデータ $x(T)$ の差の絶対値が閾値 ε を超えた場合に、装着者に動きがあったと判定していた。この手法を用いることでセンサのノイズや意図しない小さな変動を除去できるため、本研究でもこの手法を用いた。加速度の正負が切り替わる際など、運動中でも現在のデータ $x(T)$ が一時的に ε の範囲内に存在する場合や、静止中でも接触などの衝撃によって現在のデータ $x(T)$ が一時的に ε の範囲外に出る場合のデータについては図-1の「変動検出イメージ」に示しているように補正を行う。これらの値は既往研究の値を参考にした。ある時刻のセンシングデータと過去10サンプルの差の絶対値が ε の範囲内にとどまっている間は何かの姿勢を継続していると判断して、姿勢を保った動作のみを学習した分類器を用いて動作を認識する。姿勢を保った動作には

その姿勢が認識に有効であるため、特徴量には平均値、標準偏差に加えて、鉛直方向からのピッチ角を用いた。センシングデータに変動性が検出された場合は定常性有無判別フェーズに移行する。本研究では予備実験より $\varepsilon=0.02(\text{G})$ を変動検出の閾値に設定した。

(3) 定常性有無判別

動作に一定の繰り返しがあることを「定常性」と定義する。定常性有無判別フェーズでは、自己相関関数(ACF: Auto-Correlation Function)を用いて装着者の動作の定常性を検出する。離散入力信号 $x(t)$ のずれ τ におけるACFは式(1)のように、系列自身のある時刻のデータとずれ τ の時刻のデータの共分散で定義され、自己相関関数を用いることで自己相関係数 $R_{xx}(\tau)$ が算出される。

自己相関係数とはある入力信号において、現在の信号をずらしたときにどれほど過去の信号と一致するかを表す係数である。入力信号が周期的であれば、入力信号に繰り返しがある部分で自己相関係数の値が大きくなる。自己相関係数の値の大小から装着者が定常性のある動作をしているかが判別できる。

$$R_{xx}(\tau) = \sum_{t=0}^{N-\tau-1} (x(t) - \bar{x}(t)) \cdot (x(t - \tau) - \bar{x}(t)) \quad (1)$$

N はACFを計算するウィンドウサイズで、本論文ではシステム全体でのウィンドウサイズと同様に50サンプル（5.0秒）とした。自己相関は、ずれ $\tau=0$ において最大値を示すため、式(2)に従い $[-1, +1]$ に正規化した。

$$R'_{xx}(\tau) = \frac{R_{xx}(\tau)}{R_{xx}(0)} \quad (2)$$

n を第1のピークが検出される τ の値とすると、正弦波などの完全な周期波形の自己相関係数のピーク高さは、 $(1-n/N)$ となる。本研究では自己相関関数の算出結果

表-1 既往の取得データ概要

【現場データ概要】	
作業現場	稲城市内現場
期間	2017年11月15日～11月16日 (2日間)
作業内容	道路舗装工事
作業員人数	5名
取得データ (取得方法/サン プリング間隔)	加速度 (データロガー/0.1秒)
	温湿度 (データロガー/10分)
	位置情報 (GPS/5秒)
	マニュアルサンプリングデータ (目視/1分)

表-2 現場作業の分類項目

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
② 補助支援動作 (Support)	②-1 図面や指示の確認動作
	②-2 作業員自身の移動動作
	②-3 資器材の運搬動作
	②-4 工具・材料の準備動作
③ 作業遅延動作 (Delay)	③-1 作業開始遅延/切上終了
	③-2 待機
	③-3 個人的理由での作業遅延
	③-4 定められた小休止・休憩

表-3 各分類モデルの構築内容

	動作区分判別①	動作区分判別②	動作区分判別③
モデル構築に用いた動作	図面や指示の確認、待機（休憩を含む）	歩行、運搬	直接生産動作、工具・材料の準備
訓練データ数	各 10,000 サンプル	各 10,000 サンプル	20,000/10,000 サンプル
交差検証結果	82.5%	76.5%	81.3%
使用した特徴量	各軸の平均値、標準偏差、ピッチ角	各軸の平均値、標準偏差、ピッチ角、周波数、パワースペクトル値	各軸の平均値、標準偏差、ピッチ角

からそのピークを検出し、式(3)を満たす場合に定常性ありと判断する。

$$R'_{xx}(n) > \alpha \cdot (1 - n/N) \quad (n > 0) \quad (3)$$

ただし、 $\alpha(0 \leq \alpha \leq 1)$ は係数であり、完全に一致する場合のピーク高さの何割であれば定常性があるかを判断するかという基準である。本研究では予備実験により、この係数を $\alpha=0.8$ に設定した。

(4) 機械学習の利用

機械学習は各作業のモデルを構築できることが可能であり、建設工事作業員の動作推定のモデル構築ということには適していると考えられる。

本研究における機械学習のアルゴリズムにはSVM(Support Vector Machine)を使用した。SVMは近年、クラス分類、回帰などの分野で多く使われており、建設現場における動作認識の分野においてもSVMを用いている事例がある³⁾。SVMは訓練データを正確に分類する汎化誤差が最も小さくなるような解を求めるために、マージン(margin)という概念を用いる。マージンとは分類境界と訓練データの最短距離を表す。訓練データの特徴空間でマージンを最大化するような超平面を求めることで、その際のパラメータが求まる。分類境界の位置はマージンを最大化する位置で定まるので、その際に使用する訓練データ点をサポートベクトルと呼ぶ。分類境界を求めるには一部の訓練データだけを利用するため処理速度が速くなり、多次元のデータ、少ないサンプル数でもより良い分類を行うことができる。

3. 提案システムの検証実験

(1) データ取得概要

前章で述べたシステムを Mithworks 社の MATLAB R2020b で実装した。表-1 に利用したデータの詳細を示す。ヘルメットに3軸加速度センサと温湿度計を搭載したデータロガー（株式会社トアックによる試作品）を装着し、加速度と温湿度のデータを取得した。また、作業員のポケットにGPS(canmore製 GT-730FL-S)を携帯してもらい、位置情報を取得した。マニュアルサンプリングデータは5名の作業員の作業内容を目視で確認し、文献⁹⁾を参考にした分類項目(表-2)を基に手記入でデータ取得を行った。また、建設現場の加速度データは1日分の就業時間（8時30分～17時、計8時間31分）で1人1日あたり300,600サンプルを取得した。

(2) 機械学習モデルの構築

以上の結果を用いて提案システム内で利用する機械学習モデルの構築を行い、詳細を表-3に示す。マニュアルサンプリングデータを基に加速度データにラベル付けをし、教師データの作成を行った。教師データのうち作業員2名から半分ずつデータを抽出し、訓練データ用のデータセットを作成した。変動がない動作には「図面や指示の確認」と「待機」が該当し、「機械学習を用いた作業判別①」の判別対象とした。現段階では休憩を分類するフェーズを確立できていないため、「待機」の中に「休憩」を含めることとした。定常性がある動作は「歩行」と「運搬」が該当し、「機械学

表-4 提案システムの分類結果

		システムによる分類結果						各クラスの再現率 (%)
		直接生産	図面確認	移動	運搬	工具準備	待機	
真のクラス	直接生産	197	17	67	19	18		61.9
	図面確認	10		9		2		
	移動	8	1	6	5	4		25.0
	運搬	5			1			16.7
	工具準備	3		5		4		33.3
	待機	22	50	34	3	8	3	2.5

習を用いた作業判別②」の判別対象とした。

「歩行」の教師データには理想的なデータセットが必要であるため歩行単体で取得した10,000サンプルを用いた。変動があり、定常性がない動作には「直接生産動作」と「工具・材料の準備」が該当し、「機械学習を用いた作業判別③」の判別対象とした。直接生産動作には複数のパターンの動作があるため、様々な作業のデータが含まれるように20,000サンプルと工具・材料の準備のデータよりも多くなるように調整した。ウィンドウサイズはシステム内で判別を実行する際と同様に50サンプル（5秒間）とした。訓練データの精度検証には5分割交差検証を用いた。

(3) 建設現場データの分類試験

構築した教師データを組み込んだ提案システムを用いて、作業員1名の1日分のデータで分類試験を実施した。判別は5秒間を1ウィンドウとして行っているが、現場の生産性管理データは最小単位が1分であるため、マニュアルサンプリングデータとの比較を行うためにも1分間で結果を出力するようにした。1分間の内には12ウィンドウの判定結果が存在するがそのうち最も多い判定結果をその1分間での判定結果とした。最も多い判定結果が2種類存在する場合は、現場での作業割合から各作業分類フェーズにおいて「待機」，「移動」，「直接生産動作」に分類することとした。

(4) 試験結果

提案システムによる分類結果を表-4、提案システムの精度評価を表-5に示す。まんべんなくデータが分類され変動検出フェーズや定常性有無判別フェーズが機能していることが確認された。一方で「図面の指示や確認」は全て変動のあるクラスに判別された。当初は変動が検出されないという前提で検証を進めたが、実際は変動が検出されるということが明らかになった。

表-5 提案システムの精度評価

精度の指標	値(%)
正解率(Accuracy)	42.1
再現率(Recall)	23.2
適合率(Precision)	33.4

移動動作の再現率は25.0%となり、運搬動作に分類されてしまった結果と合わせると約半数で定常性が検出できていることが分かった。「待機・休憩」では再現率が2.5%となり、そのほかは各クラスに分類されたことから、「待機・休憩」には定まった動作がないことがわかり、加速度のみを単純に機械学習にかけける分類では正確に分類できないことが確認された。

4. おわりに

本研究では、建設現場の生産性管理データを自動収集する方法として、加速度データの事前判定のフェーズを組み込み、機械学習を用いることで多様な現場作業に応用可能なシステムを提案した。今後は位置情報の活用から作業パーティごとの動作や現場内のエリアから作業内容を予測することなどを予定している。

謝辞：本研究を遂行するにあたり、株式会社大成ロテック及び株式会社トアックの関係者には、データ提供やセンサの提供を賜った。ここに謝意を記す。

参考文献

- 1) 國島正彦：工事日報を活用した新しい施工プロセス検査及び歩掛り調査方法の開発，（財）日本建設情報総合センター研究助成事業報告書，2016。
- 2) 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, pp.317-328, 2010。
- 3) Yang, Z., Yuan, Y., Zhang, M., Zhao, X. and Tian, B.: Assessment of Construction Workers' Labor Intensity Based on Wearable Smartphone System, *Journal of Construction Engineering and Management*, Vol.145, No.7, 2019。
- 4) Kim, H., Kim, K. and Kim, H.: Vision-Based Object-Centric Safety Assessment Using Fuzzy Inference: Monitoring Struck-By Accidents with Moving Objects, *Journal of Computing in Civil Engineering*, Vol.30, No.4, 2016。
- 5) 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，情報処理学科論文誌，No.6, pp.1968-1979, 2011。
- 6) 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。