

## 製造現場でのモノづくりCPSの構築に寄与する 作業情報の自動抽出手法

Automatic Work Recognition Method for Repeated Operations at Sites toward Realization of Manufacturing CPS

浪岡 保男 NAMIOKA Yasuo 前川 卓也 MAEKAWA Takuya

東芝グループは、モノづくりCPS(サイバーフィジカルシステム)の一環として、製造現場で作業者の行動をデータで取得するIoP(Internet of People)の仕組み構築を進めている。今回、事前に教師データの準備が不要な、繰り返し行われる工程からその要素作業を自動で抽出できる手法を開発した。この手法では、作業を観測したセンサーデータから特徴的な波形を自動的に複数選定し、それらの特徴的波形の間にある時間的な構造を推定した。また、要素作業の開始時刻はパーティクルフィルターで探索した。実際の製造工程で取得したセンサーデータを用いて要素作業を推定した結果、F値<sup>(注1)</sup>が平均で0.83という高い推定精度で推定できることを確認した。

As part of its efforts to construct manufacturing cyber-physical systems (CPS) for further improvement of productivity, the Toshiba Group is developing an Internet of People (IoP) system to obtain information on the behavior of individual workers from data gathered at manufacturing sites. We have now developed a method to automatically recognize elemental work from repeated operations in various processes without the use of teaching data. This method makes it possible to precisely recognize elemental work by employing several types of characteristic waveforms collected from sensor data and temporal structures constructed based on the temporal distances between such characteristic waveforms, while also tracking the starting time of each operation by means of a particle filter algorithm.

We have conducted evaluation experiments using actual operational data and confirmed that this method offers high recognition accuracy through results showing that it achieves an average F-measure of 0.83.

### 1. まえがき

モノづくりにおける生産プロセスの生産性を一層向上させるため、CPSの構築が進められている。これを、モノづくりCPSと呼ぶ。生産プロセスは、商品開発から、生産前準備、計画に基づく部材調達、製造、輸送、保守運用時のサービスまでを指す。この生産プロセスの中で、製造現場では様々な製造装置と作業者により、加工、組み立て、検査、輸送などが行われている。製造装置や製造現場の環境については、IoT(Internet of Things)などの仕組みにより細かなデータがタイムリーに取得されるようになってきた。一方、作業の生産性に関するデータの取得は、今でも多くの部分を、ビデオカメラやストップウォッチなどを用いたエンジニアによる計測に頼っている。

製造装置と作業者の協調により生産が行われていることから、製造現場の総合的な生産性を把握する上でも、作業の生産性に関するデータは重要であり、これを自動的に取得するIoPの仕組み構築は喫緊の課題である。IoP実現のために、カメラや、スマートウォッチ、スマートフォン、ビー

コン、GPS(全地球測位システム)などで、作業者の作業や行動についてのデータをセンシングする取り組みも行われている。これらのデータは、数次元から数百次元の時系列データとして記録される。

ここでは、時系列データから作業者の一連の作業や行動を、教師データなしで自動抽出する方法<sup>(1)</sup>について述べる。

### 2. 要素作業の自動抽出への取り組み

製造現場では、加工、組み立て、検査、梱包(こんぼう)などの工程が定義されている。また、各工程では、決められた手順と工程リードタイムに従って作業が進められる。この手順は、制御基板の取り付け、ねじ締め、切り取り、パッキングなどの要素作業で構成され、それぞれの要素作業には手順と標準の要素作業リードタイムがあらかじめ設定されている。

製造現場の進捗管理は、標準の工程リードタイムどおりに作業が進められているかどうかのモニタリングである。もし、進捗に異常があれば、工程リードタイムが標準から外れることが多く、異常の要因を突き止める際には、要素作業リードタイムの異変や標準外作業の発生が手掛かりとなる。製造現場の規模が大きくなると、こうした異常の発見と

(注1) 推定性能の評価に用いられる指標で、値が1に近いほど推定精度が高い。

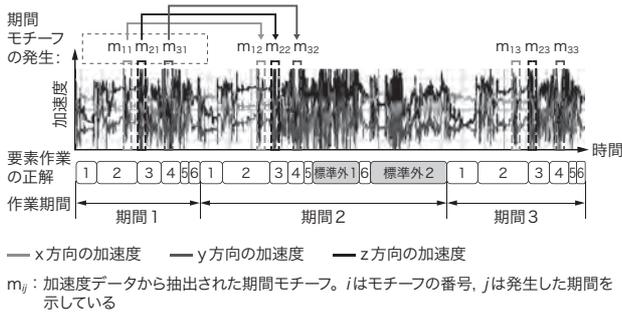


図1. 作業者から取得した加速度データの例

要素作業1～6の工程を3期間(回)行ったときの作業者の右手首の加速度を、可視化したものである。

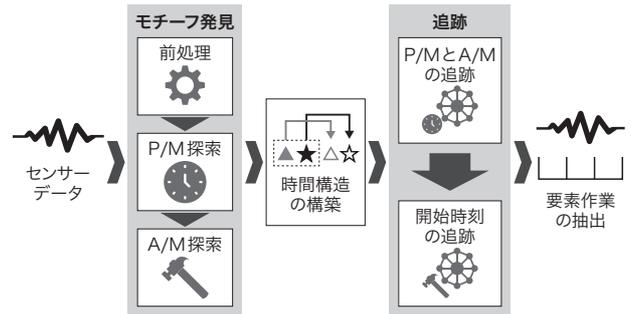
Example of acceleration data collected from worker

対策に必要な人的リソースも大きくなる。また、製造現場における生産性の改善活動では、要素作業がどのように行われているかを、リードタイムの標準と実際の差や、作業者間の違い、同一作業者の作業期間ごとのばらつき、標準外作業の発生頻度などから分析し、作業内容の配分や、作業の手順、使用する工具などを調整している。こうした改善活動も、製造現場が大きくなるほど、また活動回数が多くなるほど、時間と人的リソースの投入が必要になる。そこで、要素作業の抽出とリードタイムの計測が自動化できれば、人的リソースの投入を最小化したり、遠隔指導したりするなどの省力化が期待できる。

要素作業の抽出に使用できるデータの一つに、作業員の動きを示す加速度データがある。加速度データは、スマートウォッチやスマートフォンなどにより取得できる。図1は、六つの要素作業から成る工程の3期間(回)分の作業データを示している。この例では、期間2で2回の標準外作業が発生し、期間1と期間3に比べて工程リードタイムが長くなっていることが分かる。標準外作業は、実際の工程で時折発生するが、工程や作業環境に何らかの問題がある場合は頻繁になる。このように、標準外作業の発生は工程管理・改善上の重要な情報となり得ることから、適切に検出できることが望ましい。

### 3. 教師なしでの要素作業の自動抽出手法

図1の時系列データには、特徴的な波形であるモチーフが、幾つか含まれている。1回の工程作業で一度だけ発生するものを期間モチーフ、特定の要素作業に複数回発生し、その要素作業を特徴付けるものをアクションモチーフという。ここでは、これらのモチーフと各モチーフ間の時間構造を用いることで、あらかじめ定められた要素作業と標準外作業を容易に抽出する手法について述べる。



P/M: 期間モチーフ A/M: アクションモチーフ

図2. 作業情報の自動抽出手法の概要

センサーデータからモチーフを発見してモチーフ間の時間構造を構築し、これに基づいてモチーフを追跡することで、要素作業を抽出する。

Overview of automatic work recognition method

教師なしで要素作業を自動抽出する手法の概要を、図2に示す。この手法は、次の三つのフェーズから成る。

- (1) モチーフの発見 離散化、トレンド抽出などの前処理、期間モチーフの探索、アクションモチーフの探索を行う。これらのモチーフを、工程リードタイム程度の時間で、初期の時系列データの中から探索し、以降の時系列データの分析に適用する。
- (2) モチーフの時間構造の構築 発見した複数の期間モチーフ間の時間間隔を時間構造とし、以降の時系列データの分析に活用する。
- (3) 要素作業開始時刻を探すためのモチーフの追跡 パーティクルフィルターで、期間モチーフ、アクションモチーフを追跡して、要素作業開始時刻を探す。

#### 3.1 作業フローモデル

要素作業の抽出手法では、あらかじめ作成する作業フローモデル(図3)を用いる。作業フローモデルは、工程の作業標準から作成され、要素作業の標準的な順番、分岐/合流、要素作業リードタイムから成る。分岐/合流によって、複数のシーケンスを許容する表現ができる。

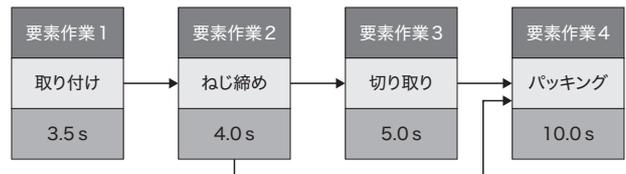


図3. 作業フローモデルの例

要素作業のフローと各要素作業の標準のリードタイムを設定する。この例では、要素作業1～4を連続して行う場合と、要素作業1, 2, 4を行う場合との二つのフローがあることを示している。

Example of operation flow model

## 3.2 モチーフの発見

### 3.2.1 センサーデータの前処理

計算量を削減するため、センサーデータを離散化(記号化)してから、時系列的なトレンドの変化点を抽出する。この変化点は、要素作業開始時刻の候補となる。トレンドの変化点を抽出するために、階層ディリクレ過程隠れマルコフモデル(HDP-HMM)を用いる。

### 3.2.2 期間モチーフの探索

センサーデータの分析開始点から工程リードタイム程度を経過するまでの期間の時系列データから、期間モチーフの候補をランダムに多数選択し、この中で、同期間に一度だけ出現するとともに、次の期間やそれ以降の期間においても一度だけ出現する候補を期間モチーフとして採用する。この採用では、期間モチーフの候補の波形を時系列データ上でスライドして類似度を求めて、この候補の波形の出現状況を確認している。

### 3.2.3 アクションモチーフの探索

センサーデータの分析開始点から工程リードタイム程度を経過するまでの期間の時系列データから、アクションモチーフの候補をランダムに多数選択し、この中で、モチーフが発生したときだけ突出して類似度が高くなるものを選定する。この採用においても、アクションモチーフの候補の波形を時系列データ上でスライドして類似度を求めて、この候補の波形の出現状況を確認している。アクションモチーフは、1工程中に複数回発生しても構わないが、発生したときと発生していないときにおける波形の類似度の変化が大きいものを選定する。

## 3.3 モチーフの時間構造の構築

発見した異なる期間モチーフの相互の時間間隔を記録しておき、これらをモチーフの時間構造とする。3.4節の期間モチーフの追跡では、この時間構造を基にスコアの一つを算出し、評価値に加えて推定精度の向上を図っている。

### 3.4 期間モチーフの追跡

パーティクルフィルターを用いて、時系列データ上で期間モチーフの追跡を行う。期間モチーフの探索で選定した全ての期間モチーフを追跡する。パーティクルフィルターは、(a)サンプリングと(b)重み付けを繰り返して、探索的に期間モチーフを追跡する。追跡では、時系列データ上の期間モチーフの発生時刻(パーティクル)を追跡する追跡木を作成する。期間モチーフは、一つの工程期間に1回発生するので、 $n$ 期間分の時系列データ上では、最終的に全ての期間モチーフの $n$ 回の発生を特定する。追跡木には、これら期間モチーフの発生の候補となるパーティクル列が多数内包される。

(a)サンプリングでは、工程リードタイムをランダムに加減した時点でパーティクル(期間モチーフの発生時刻の候補)を複数発生させる。(b)重み付けでは、各パーティクルに対して評価値を算出する。評価値は、次に示す二つの観点の組み合わせにより、算出する。

- (1) 類似性スコア パーティクルの波形と追跡中の期間モチーフの類似度
- (2) 一貫性スコア 一つ前の期間で最も評価値が高かったパーティクルに相当する期間モチーフと評価値を付与しようとしているパーティクルに相当する期間モチーフとの時間間隔と、モチーフの時間構造の時間間隔(3.3節)を比べたときの差の小ささ

次の期間に対するパーティクルのサンプリング(再サンプリング)は、評価値(重みの累計値)の最も大きいパーティクルを優先して行う。

## 3.5 要素作業の開始時刻の追跡

要素作業の開始時刻の追跡にも、パーティクルフィルターを使用する。この追跡では、①時系列データ上の期間モチーフの発生時刻、②HDP-HMMを用いて抽出した、センサーデータ上の時系列的なトレンドの変化点(時刻)、③作業フローモデルから得られる標準的な要素作業リードタイム、の三つの情報を用いる。まず、いずれかの連続する期間モチーフ間にある時系列的なトレンドの変化点から、作業フローの先頭における要素作業開始時刻の候補を選定し、これをパーティクルフィルターの起点として追跡を開始する。

サンプリングでは、基本的には作業フローモデルにおける要素作業の順序や分岐に従う。要素作業リードタイムをランダムに加減した時刻に、パーティクル(要素作業開始時刻の候補)を発生させる。

重み付けでは、次に示す三つのスコアの組み合わせにより、評価値を決定する。

- (1) 時系列的なトレンドに基づくスコア トレンド変化点とパーティクルとの時刻の近さを用いるスコアである。要素作業の開始時刻は、トレンド変化点の近傍なので、これらの時刻の近さからスコアを算出する。
- (2) 期間モチーフスコア(時間構造) 期間モチーフと要素作業の発生時刻との時間間隔によるスコアである。一つ前の期間の期間モチーフと追跡中の要素作業の発生時刻との時間間隔と、追跡中の期間における期間モチーフと評価値計算中のパーティクルとの時間間隔を比べたときの近さからスコアを算出する。
- (3) アクションモチーフスコア 要素作業の期間におけるアクションモチーフの発生パターンの類似性によるスコアである。一つ前の期間における期間モチーフや、

追跡中の要素作業の発生期間におけるアクションモチーフの発生頻度などから、スコアを算出する。

#### 4. 評価

組み立てや、ねじ締め、検査、梱包など、複数の工程と作業員から取得した、六つの加速度データセットに、開発した手法を適用した際の推定精度を表1に示す。加速度データは、市販のスマートウォッチを用いて計測した。工程により異なるが、平均すると、F値が0.83と高い推定精度が得られた。

期間モチーフスコア(時間構造)による推定精度の向上効果を、図4に示す。この例は、作業Fからの抜粋で、標準外作業が最も多く発生しており、推定精度が低下しやすいデータと考えられる。時間構造を用いて標準外作業を避けることで、要素作業を抽出している。

表1. 作業員から取得したデータセットと作業の推定精度

Dataset collected from worker and results of work recognition accuracy evaluation

作業	作業A	作業B	作業C	作業D	作業E	作業F
作業概要	基板検査	基板梱包	最終検査	最終検査	基板組立	基板組立
要素作業数	8	6	7	7	11	11
標準作業時間 (s)	130	59	53	50	55	50
作業期間数	10	9	14	13	12	11
データ記録時間 (s)	1,440	614	778	632	676	674
標準外作業の時間 (s)	0	76	51	14	0	79
推定結果のF値	0.83	0.81	0.76	0.88	0.86	0.86

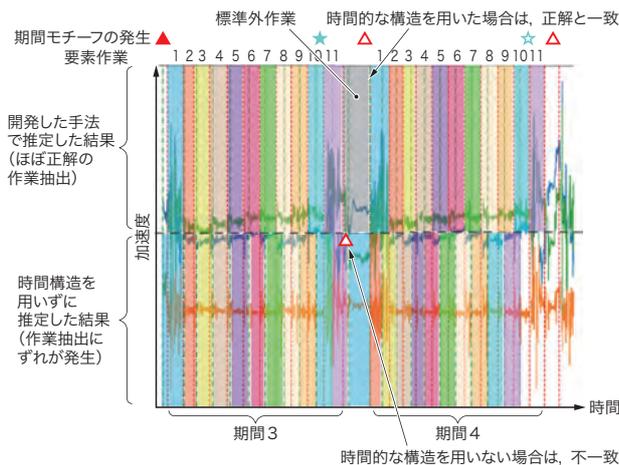


図4. 時間構造の適用による推定精度の向上例

一つ前の▲の期間モチーフにおける時間間隔だけを用いるスコアでは、下の△のように前にずれやすいが、他の期間モチーフや後続のモチーフとの時間構造などを用いると上の△が優先され、この区間を標準外作業として検出できる。

Example of improvement in work recognition accuracy through application of temporal structure

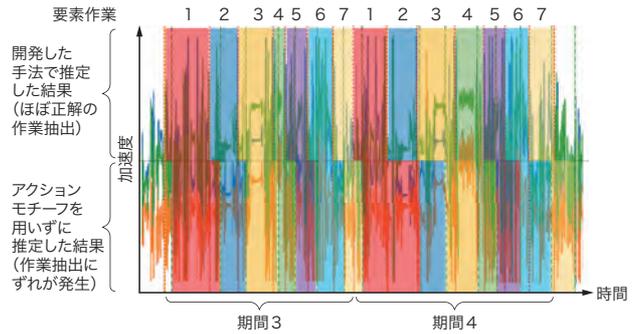


図5. アクションモチーフの適用による推定精度の向上例

アクションモチーフによる要素作業の波形的特徴を適用することで、要素作業の開始時刻の推定にずれが発生するのを抑制できる。

Example of improvement in work recognition accuracy through application of action motif

アクションモチーフによる推定精度の向上効果を、図5に示す。この例は、作業Cからの抜粋である。図中の期間3、4では同じ作業を行っているが、何らかの要因で要素作業に要する時間が異なっており、大きいところでは2倍程度の作業時間を要している。このような場合は、要素作業の開始時刻が正解からずれやすいが、アクションモチーフの発生パターンや波形的な特徴によるスコアを用いることで、こうしたずれを抑制できている。

#### 5. あとがき

モノづくりCPSに必要なデジタル生産技術の中で、作業員の作業情報を取得するために、製造工程で繰り返し行われる作業の要素作業を教師データなしで自動抽出する手法と、作業を観測したセンサーデータから十分な精度で要素作業を抽出できることを述べた。今後、この技術を適用してモノづくりCPSの構築に寄与していく。

#### 文献

- (1) Xia, Q. et al. Robust Unsupervised Factory Activity Recognition with Body-worn Accelerometer Using Temporal Structure of Multiple Sensor Data Motifs. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies. 2020, 4, 3, p.97:1-97:30.



浪岡 保男 NAMIOKA Yasuo, Ph.D.  
生産技術センター  
博士(工学) IEEE・電子情報通信学会・情報処理学会・  
人工知能学会・日本データベース学会会員  
Corporate Manufacturing Engineering Center



前川 卓也 MAEKAWA Takuya, Ph.D.  
大阪大学大学院 情報科学研究科准教授  
博士(情報科学) ACM・IEEE・情報処理学会・  
日本データベース学会・電気学会会員  
Graduate School of Information Science and Technology, Osaka Univ.