

コンシューマ・デバイス論文

# 製造現場の作業分析結果を利用した カメラと深層学習による作業手順の リアルタイム監視システム

村井 浩一<sup>1,a)</sup> 今井 哲郎<sup>2</sup> 荒井 研一<sup>2</sup> 小林 透<sup>2</sup>

受付日 2020年2月25日, 採録日 2020年6月22日

**概要:** これまで製造現場の品質向上を目的として, 作業ミスをリアルタイムに検知するシステムが提案されているが, 検知した作業ミスに対して, 正しい手順での作業のやり直しまで指示するような汎用的なシステムは報告されていない. そこで我々は, 作業改善のための作業分析結果を利用して作業手順をリアルタイムに監視し, 誤りがあった場合には正しい手順をティーチングできる汎用的な作業手順リアルタイム監視システムを開発した. 本システムでは, 作業分析結果である標準作業と標準作業時間および, 分析時の作業動画から学習された深層学習モデルを監視基準に用いることにより, 作業手順の誤りや作業時間の乖離が検知された際に, 分析時の模範となった正しい作業手順で作業員へティーチングを行うことを可能とした. さらに, この深層学習に用いる学習データについて作業分析結果と作業時の動画から自動的に生成することにより, 深層学習を利用する際の課題とされる学習データの準備にかかる労力と時間を大幅に削減することを可能とした. 本システムについて組立作業の模擬環境で実験評価を行い, 有効性について明らかにした.

**キーワード:** 作業分析, リアルタイム監視, 深層学習, Web カメラ, インダストリアル・エンジニアリング

## Real-time Work Procedure Monitoring System by Deep Learning and Web Camera Using Results of Work Analysis at Manufacturing

KOICHI MURAI<sup>1,a)</sup> TETSUO IMAI<sup>2</sup> KENICHI ARAI<sup>2</sup> TORU KOBAYASHI<sup>2</sup>

Received: February 25, 2020, Accepted: June 22, 2020

**Abstract:** The systems to detect work errors in real time have been proposed for the purpose of quality improvement at manufacturing sites, however it has not been reported a generic system that instructs to rework detected work errors in a correct procedure. Therefore, we have developed a generic system that monitors work procedures in real time and conducts a teaching in correct procedures, if there are any errors, using results of work analysis for improvement. This system enables to perform a teaching to workers in a correct procedure which is a model in the analysis, when it detects errors in work procedures or deviations of work hours by using a deep learning model learned from standard work and working hours and videos of working in the analysis. Furthermore, by automatically generating learning data used for this deep learning from results of work analysis and videos recording workers' working, the system can remarkably reduce time and labor required for preparation of learning data which is considered as a problem in using deep learning. We conducted an experimental evaluation of this system in a simulated environment of assembly work and clarified its effectiveness.

**Keywords:** work analysis, real-time monitoring, deep learning, web camera, industrial engineering

<sup>1</sup> 株式会社システック井上  
Systec Inoue Corporation, Nagasaki 852-8011, Japan

<sup>2</sup> 長崎大学大学院工学研究科  
Graduate School of Engineering, Nagasaki University, Nagasaki 852-8521, Japan

<sup>a)</sup> murai@sys-inoue.co.jp

### 1. はじめに

2019年度版ものづくり白書によると, 製造業における人材不足が深刻な課題とされ, その対策として製造現場での労働生産性向上が必要であるとされている [1]. 製造業

ではそのための手段の1つとして、インダストリアル・エンジニアリング (IE) [2] による改善活動が行われており、筆者はこれまで IE ツールの1つである作業分析ソフトの導入に携わってきた。作業分析ソフトとは、製造現場での作業状況を撮影した映像を使用してストップ・ウォッチ法による分析 [3] やサブリグ分析 [4] を行い、非効率な点や問題点を見つけ出し改善を図ることを主な目的としたソフトウェアである。分析された結果は標準作業や標準作業時間として製造現場へ展開される。従来はこれらが製造現場で正しく守られているかを把握する方法としては日報での確認や現場監督者による見回りが中心であったため、手間や時間がかかるうえに客観性や正確さが課題とされていた。近年、映像やセンサを利用して作業者の作業ミスを自動検知するシステムは考案されているが、今後は作業ミスの検知に加え、作業改善による生産性向上を目的とした作業手順監視システムが必要とされるものと考えられる。

そこで本研究では、作業分析ソフトで分析された結果から定められた標準作業と標準作業時間を監視用の基準として製造現場での作業をリアルタイムで監視し、異常が検知された際にその場で作業者へ正しい作業手順をティーチングするシステムを開発した。本システムでは製造現場での作業状況を画像から認識する方法に、畳み込みニューラルネット (CNN) を利用する。CNN などの深層学習を利用する際は大量の学習データが必要となるためにその準備に多大な労力と時間を要することが課題とされており、学習データ準備の省力化を目的とした研究も行われている [5]。筆者らはこの課題を解決するために、作業分析ソフトで分析した結果とその際に使用した動画から学習データを自動的に生成する手法を開発し、学習データの準備にかかる労力と時間を大幅に削減した。また、これらによって多くの製造現場で利用できる汎用性の高いシステムを目指した。2章で関連研究について述べ、3章で本システムの特徴を説明する。4章で開発したシステム構成について述べた後、製造現場の組立作業を模擬した環境での評価実験結果を5章で述べ、6章で考察し、7章でまとめを行う。

## 2. 関連研究

製造現場での作業手順の監視システムとしては、岩手県立大学大学院の宇田らがピッキング工程における作業ミスの検知を目的として Microsoft 社の Kinect を使用したシステムの研究を行っている [6]。この研究ではピッキング時の手の位置について、Kinect で撮影した画像および深度センサでとらえており、その際に作業時に着用する軍手の色情報を利用しているため、作業環境に合わせた軍手の色の選定が必要とされている。また、ピッキング動作については物品そのものの取り出しではなく、棚の間口と手の位置関係から判断しており、“手の移動”と“物品そのものの取り出し”に対する誤認識を避けるためには作業者の動作に

も一定の制約が必要とされている。一方、筆者らは CNN で作業の認識を行うため、上記のような場合でも“手の移動”と“物品そのものの取り出し”をそれぞれの画像から学習することにより正しい認識が可能であると考えられる。

作業ミスの検知システムに関しては、岐阜県情報技術研究所の清水らがオプティカルフローを用いてネジの締め付けミスを検出するシステムについて開発を行った [7]。このシステムではネジ締め時の「締める」、「戻す」の反復動作をオプティカルフローから抽出した動作特徴量のシーケンスから求め、トルクレンチの締め付け完了信号とあわせて締め付け忘れを判断している。そのため、対象となる作業動作ごとに動作特徴量抽出およびシーケンスの設計が必要となる。一方、筆者らの手法はこのような設計を行う必要がなく、正しい作業手順の画像により学習した CNN だけでネジ締め作業ミスを検知することを可能とし汎用性を高めた。

また、パドヴァ大学の Faccio らは 3D カメラを用いた組み立て作業のリアルタイム作業手順監視および支援システムについて研究を行った [8]。この研究では作業者の骨格のトラッキング (モーション情報) と Control Volume と呼ばれる監視対象エリア内の三次元位置情報に基づき、ピッキングや部品取り付けの動作を監視し、作業手順について支援する仕組みを提案している。Faccio らは従来のピッキング支援システムと比べ、低価格で柔軟性の高い方法として本手法を提案している。本提案では作業者のモーション情報に基づいて監視を行っているために、使用している工具や部品などの情報は無視されることになる。一例として溶接工程をあげると、作業者のモーションだけでは溶接作業を認識することは難しいと考えられ、使用中の工具とあわせて作業として認識する必要がある。したがって、幅広い製造現場での利用を想定した場合、課題が生じる可能性が考えられる。一方、筆者らは CNN を用いることにより、溶接作業のような現場でも工具や溶接の際の光源などの特徴から作業を認識することが可能である。また、作業支援の仕組みについて、Faccio らの提案ではあらかじめ設計された Control Volume のエリアを正しい作業手順における作業領域として画面などで可視化する仕組みであるが、筆者らは作業分析ソフトで分析を行った模範となる動画をそのまま利用することにより、汎用性とティーチングとしての利用を可能としている点が異なっている。

## 3. リアルタイム作業手順監視システムの特徴

### 3.1 要求条件

- 本作業手順監視システムの要件について以下にあげる。
- 要件 1: 作業改善を目的とした監視基準であること
  - 要件 2: CNN の学習データの準備が容易であること
  - 要件 3: 作業手順誤りや時間乖離を正確に検知できること
  - 要件 4: 製造現場をリアルタイムで監視可能であること

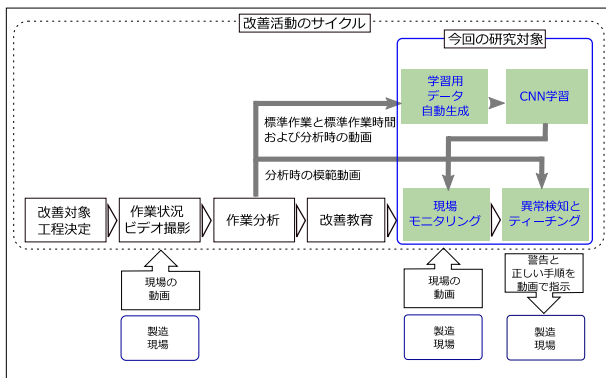


図 1 リアルタイム作業手順監視方式

Fig. 1 Method of work procedure monitoring in real time.

作業改善を目的とした監視のためには、その監視基準は IE として分析評価され、定められたものである必要がある (要件 1)。また、製造現場では IE 活動によるサイクルが回され、監視基準についても頻繁に見直される。したがって作業の認識に使用する CNN についても IE 活動のサイクルのなかで再学習が必要となるため、その学習データは容易に準備できる必要がある (要件 2)。また、製造現場で作業手順の誤りや作業時間の乖離が発生した場合に、生産性や品質へ与える影響を考慮するとその検知は正確である必要があり (要件 3)、影響を最小限にとどめるためには問題発生時点でただちに警告し、作業員へ正しい作業手順でティーチングする必要がある (要件 4)。

### 3.2 作業手順監視方式

3.1 節で示した要件を満足するリアルタイム作業手順監視システムの方式を図 1 に示す。本方式では、市販の作業分析ソフトで分析した結果である標準作業と標準作業時間および分析の際に使用した動画により学習した CNN を、監視の際の基準および作業認識の仕組みとして利用することにより、作業改善を目的とした監視基準とした (要件 1)。また、作業分析結果と動画から CNN の学習データを自動的に生成することにより学習用データの準備を容易にした (要件 2)。監視のリアルタイム性と検知精度については、比較的スループットが高いとされる学習済の CNN ネットワークを選定し、転移学習して利用することにより、限られた学習データで検知精度を高めた (要件 3, 4)。

### 3.3 ユースケース

本方式に基づいたユースケースを図 2 に示す。作業分析の担当者は作業分析ソフトで分析を行い、改善のための作業手順や作業時間の見直しが必要となる場合は、作業手順書を改訂し製造現場の担当者へ教育を行う。その際の作業分析結果である標準作業と標準作業時間および動画は、リアルタイム作業手順監視システムへ取り込まれる。同システムはこれらの情報から学習用のデータを自動的に生成

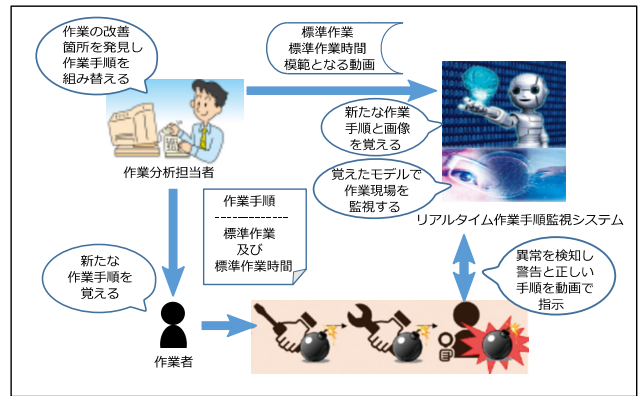


図 2 ユースケース

Fig. 2 Use case.

し、CNN の学習を行うことにより監視用のモデルを作成または更新し監視を行う。作業員は与えられた作業手順にしたがって作業を行うが、標準作業と異なる順番で作業を行った場合や作業のムダにより標準作業時間に対して実際にかかった作業時間が一定以上異なる場合は同システムが異常として検知し、警告とともに正しい作業手順を動画で作業員へ示す。つまり、本システムが標準作業と標準作業時間および作業時の模範となる画像を覚え、その内容に基づいて製造現場の監視を行い、手順や時間に相違や乖離が検知された際には作業員へ作業手順のティーチングを行う仕組みである。

本ユースケースにおいてポイントとなるのは、作業分析結果から作成され製造現場へ展開される作業手順書と、本システムで製造現場を監視する際の基準およびティーチングの際の作業手順を同一の内容にできる点であり、作業分析結果と同期をとりながら IE 改善サイクルを回すことが可能となることである。

### 3.4 市販の作業分析ソフトでの分析結果の利用

作業分析ソフトについては市販の製品 A を使用した。製品 A では撮影したビデオ映像を簡単なマウス操作で作業単位に分割し、正確な時間測定や動作の分析が可能である。さらに、ムダな作業の排除や作業手順の組み換えを行い、その結果として標準作業と各作業の標準作業時間が出力される。この分析結果と分析の際に使用された作業動画を本システムで利用する。

### 3.5 リアルタイム性の高い CNN モデルの採用

本システムでは限られた学習データで CNN を効果的に利用できるよう、学習済ネットワークを転移学習として利用する。CNN の学習済ネットワークモデルとしては多くの種類が存在するが、今回はリアルタイム性を要件としているため、Canziani らの評価結果 [9] を参考に、比較的スループットが高いとされている Alexnet [10] を採用した。





図 3 ハードウェア構成

Fig. 3 Hardware configuration.

表 1 作業分析ソフトでの出力結果

Table 1 Result in work analysis software.

No.	計測時間 (秒)	作業分類
1	8.9	①金具を運ぶ
2	25.8	②仮止め
3	21.1	③ボルト締め付け
4	22	④マット貼り付け
5	18.2	⑤プレート拭き上げ
6	20.7	⑥金具固定
合計	116.7	

## 4. リアルタイム作業手順監視システムの構成

### 4.1 ハードウェア構成およびシステム環境

本システムのハードウェア構成は図 3 のとおりである。CNN の学習およびリアルタイム監視はノートパソコン上で実行され、Web カメラについては小型の一般的な市販品を利用し USB ケーブルでパソコンに接続する。また、アプリケーションについては Mathworks 社の MATLAB R2019a とそのオプション製品である Deep Learning Toolbox を利用して開発した [11]。

### 4.2 アプリケーション

#### (1) 作業分析ソフトからのデータ取り込み

製品 A では、作業分析結果を Excel ファイルまたは CSV として出力することができる。表 1 にそのサンプルイメージを示す。今回はこの情報をシステムに取り込み、標準作業および標準作業時間として監視の基準値とする。また、作業分析時に使用した作業動画から CNN の学習用の静止画を抽出する際の条件としても本分析結果を利用する。

#### (2) CNN 学習用データの生成

CNN の学習用データを生成する際は、表 1 にある作業順番 (No.) と計測時間、作業分類に基づいて動画から静止画を抽出する (図 4)。具体的には、作業分析結果内の各作業に対する計測時間 (各作業の経過秒数) と動画のビデオフレームのタイムスタンプを比較しながら、該当する計測時間内のフレームを静止画として抽出し、各作業の名称を付けたフォルダに保存する処理をシステム化する。これにより、作業分析結果から学習用データを生成する処理の自動化を実現する。

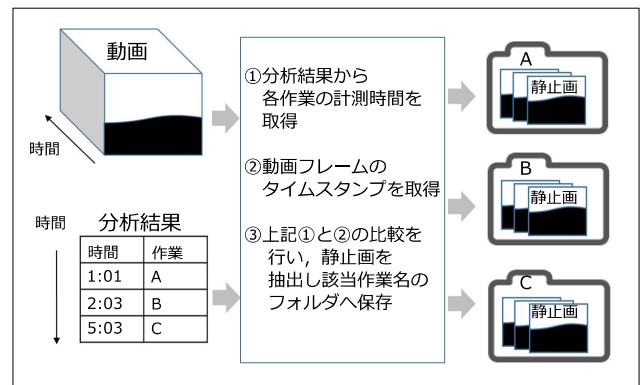


図 4 動画からの静止画の抽出処理

Fig. 4 Extraction of still images from videos.

### (3) CNN 転移学習

Alexnet の最後の全結合層および Softmax 層、出力層について今回の作業分類対象にあわせて分類クラス数の変更を行い、生成した学習用データにより転移学習させることにより、作業認識用のネットワークとする。

### (4) 撮影中の製造現場の作業分類と作業時間集計

製造現場の作業については、カメラで撮影中の画像をフレームごとに静止画として抽出し CNN により分類する。また、作業時間については、各作業に分類された際の時刻から経過時間を集計する。

### (5) 作業手順誤り検知およびティーチング

作業手順誤りの検知については、標準作業に対する作業の順番と CNN で分類された撮影中の作業の順番を比較することで判断を行う。

また、監視対象となる作業において標準作業から大きく逸脱した動作や標準作業とはまったく異なる部品配置など、CNN の学習時に想定していなかった状況が発生した場合、該当作業に対しても手順の誤りとして検知の対象とする。これを判断するために、CNN の分類時の確率スコアを利用する。CNN の softmax 層から出力された結果は、分類対象となるクラスのなかで最もスコアが高いクラスへ分類されるため、学習データに含まれていない画像に対してもいずれかのクラスへ分類されてしまう。そこで分類時の確率スコアを参照し、一定スコア以下の場合は想定外作業として取り扱う。確率スコアの算出は式 (1) に示すが、 $K$  は分類クラスの数、 $s(x)$  はインスタンス  $x$  に対する各クラスのスコアからなるベクトル、 $p_k$  はインスタンスに対する各クラスのスコアから推計されたインスタンスがクラス  $k$  に属する確率となる。この  $p_k$  が一定の閾値以下となる場合に、いずれの作業に対してもあてはまる確率が低い想定外作業として扱う。

$$p_k = \sigma(s(x))_k = \frac{\exp(s_k(x))}{\sum_{j=1}^k \exp(s_j(x))} \quad (1)$$

作業時間の乖離に関する検知については、標準作業時間

と分類結果から集計された経過時間の比較を行い判断する。  
 作業手順の誤りもしくは作業時間の乖離が検知された際は、正しい作業の順番と該当する作業手順の動画（作業分析時に使用した模範の動画）をパソコンで再生することにより作業員へのティーチングを行う。

## 5. 評価実験

### 5.1 実験環境

設備の耐震固定に使われる金具の組立作業について、作業のサイクル全体とそのなかの特定作業内の動作を対象に、監視対象の粒度が異なる2種類の模擬環境を準備した。

#### (1) 金具組立作業のサイクル全体に対する実験環境

金具組立作業としては、2種類の金具をボルトで組み立て、底面に設備と床を固定するための耐震用のマットを貼り付けた後、床を模擬したプレートに固定するという6つの作業で構成される実験環境を準備した（図5）。

#### (2) サイクル中の1作業内に対する実験環境

1作業内の動作に関する実験環境としては、本組立作業の中で最も重要な作業とされるボルト締め付けを対象とした。図6は作業員を対面方向からカメラで撮影した画像であるが、組み立てる際に金具の間に歪や狂いが生じると、地震の力によりボルトのせん断や引き抜き、金具の破断が生じる恐れがあり、金具を正しく組み立てるためには、ボルトの締め付け順が重要とされている。

### 5.2 実験対象

本システムに対する実験対象については、以下の3点とした。1点目は、CNNにおける静止画の分類精度である。今回の要件の1つである作業手順の誤りおよび作業時間の乖離を正確に検知するためには、対象となる静止画に対する高い分類精度が求められる。本システムで自動生成された静止画で学習したAlexnetを用いて分類精度に関する実験を行った。2点目は、作業手順や作業時間の乖離に対する検知精度であり、作業手順の誤りや手順の逸脱、標準作業時間との乖離が発生した際の検知の正確さについて実験した。3点目は、処理のリアルタイム性である。本システムにおいて、CNNで1秒間に分類処理できる静止画数について求めることにより、その処理性能について把握するための実験を行った。あわせて、異常検知時のティーチング用動画再生までのリアルタイム性についても実験を行った。

### 5.3 実験準備

#### (1) 学習データの生成

実験を行うにあたり、金具組立作業とボルト締め付け作業の各動画に対して作業分析ソフトで分析を行い、学習データを準備した。先に、作業時の動画から学習用の静止画を準備する際の所要時間に関する評価を目的として、ボルト締め付け作業を対象に被験者3名の動画を用いて、本




図5 金具組立作業

Fig. 5 Bracket assembly work.




図6 ボルト締め付け作業

Fig. 6 Bolt tightening work.

表2 学習用データの生成処理性能

Table 2 Generation processing performance of data for learning.

	動画時間 (秒)	静止画 (枚)	本システムでの学習データ準備時間 (秒)			手作業での学習データ準備時間 (秒)		
			作業分析ソフトでの分析	学習データ生成	合計	動画から静止画抽出	手作業でのラベル付け	合計
被験者A	22.39	667	56	19	75	17	334	351
被験者B	20.26	604	54	15	69	15	310	325
被験者C	29.07	866	69	25	94	23	391	414
平均	23.91	712.33	59.67	19.67	79.33	18.33	345.00	363.33

システムを利用して学習データを準備した場合と、従来の手作業で学習データを準備した場合のそれぞれの所要時間について計測を行った結果を表2に示す。平均23.91秒の動画に対して本システムを利用した場合の所要時間は、作業分析ソフトでの分析時間とそれを利用した学習データ生成時間を合計して平均79.33秒となった。これに対して手作業で学習データを準備する際は、動画から静止画を抽出し、手作業でラベル付けを行う必要があるため、要した合計時間は平均363.33秒となった。本システムを利用することにより従来の手作業による学習データの準備と比較すると78%程度の時間削減が可能となった。

次に、今回の実験に使用した金具組立作業の学習データの準備方法について示す。はじめに、熟練者にあたる被験者2名（被験者A, B）をモデルに3サイクル分の作業を分析し、各サイクルに対してそれぞれ6つの作業に分類した。その分析結果と分析時の動画を本システムに取り込

表 3 金具組立作業の学習用データ画像数 (枚)

Table 3 Learning data for bracket assembly work.

	データの区分	①金具を運ぶ ②仮止め ③ボルト締め付け ④マット貼り付け ⑤プレート拭き上げ ⑥金具固定						合計
		①	②	③	④	⑤	⑥	
被験者A	静止画像	819	3,312	2,704	2,068	1,889	3,560	14,352
	学習用画像数	1,490	1,722	1,812	1,654	1,587	2,029	10,294
被験者B	静止画像	830	2,458	1,773	1,683	1,682	1,704	10,130
	学習用画像数	1,510	1,278	1,188	1,346	1,413	971	7,706
合計	静止画像	1,649	5,770	4,477	3,751	3,571	5,264	24,482
	学習用画像採用率	182%	52%	67%	80%	84%	57%	-
	学習用画像数	3,000	3,000	3,000	3,000	3,000	3,000	18,000

表 4 ボルト締め付け作業の学習用データ画像数 (枚)

Table 4 Learning data for bolt tightening work.

	データの区分	①左上 ②右下 ③右上 ④左下 ⑤その他					合計
		①	②	③	④	⑤	
被験者A	静止画像	1,430	1,350	1,520	1,480	4,012	9,792
	学習用画像採用率	210%	222%	197%	203%	75%	-
	学習用画像数	3,000	3,000	3,000	3,000	3,000	15,000

み, 図 5 のような静止画を生成した. この動画から生成された静止画の数について表 3 の静止画数として示す. 次に作業ごとに 2 名の静止画数の合計と今回作業ごとに準備する学習用画像数である 3,000 枚との比率を求め, 表 3 の学習用画像採用率とした. この学習用画像採用率とそれぞれの作業者の作業ごとの静止画数を掛け合わせて表 3 の被験者ごとの学習用画像数を算出した. 学習画像については, 学習用画像採用率が 100%未満の場合はそれぞれの作業者の作業ごとの静止画から学習用画像数の画像を無作為標本によりランダムに抽出し, 100%を超える場合は同じく無作為標本により静止画からランダムに画像を選び学習用画像数となるようコピーを行った. また, このような方法で準備した学習データに対する画像の類似性や重複を緩和するために, MATLAB のデータ拡張機能を利用して学習用の画像に対して水平方向と垂直方向へそれぞれ 20 ピクセルの範囲内でランダムに移動させた. 被験者 A と被験者 B の間で学習用画像数に差が生じているが, これは各作業者の作業ごとの作業時間が異なっていたことにより静止画数にも違いが生じたことが原因であり, 被験者ごとの静止画数に対して均一の割合で学習用の画像を抽出したことによるものである.

また, ボルト締め付け作業の学習データについては手元の画像を対象としているため, 被験者間で動作や特徴にバラツキが少ないものと仮定し, 熟練者である被験者 1 名 (被験者 A) をモデルに 10 作業分を対象とした. 分析結果に基づいて表 4 のとおり, 4 カ所のボルト締めの動作と, ボルト締め対象箇所間の手や工具の移動を“その他”とした計 5 つのクラスに分類し, 図 6 のような学習用の静止画をそれぞれ 3,000 枚準備した. その際, 金具組立作業同様に被験者の静止画に対して無作為標本によりランダムに抽出またはコピー, および MATLAB によるデータ拡張処理を適用した. “その他”をクラスに追加した理由は, それぞれの位置に対するボルト締め付けの動作と, それ以外の手の移動などの動作を明確に分けるためである.

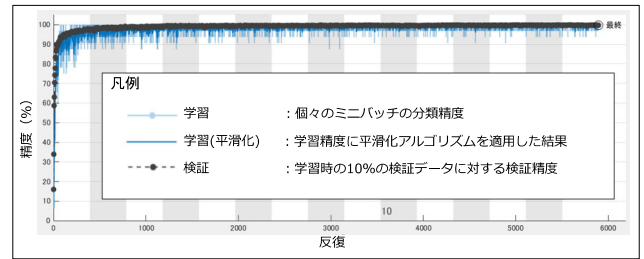


図 7 金具組立の静止画学習結果

Fig. 7 Learning result of bracket assembly.

## (2) CNN の学習

CNN の転移学習については金具組立作業, ボルト締め付け作業ともに, ミニバッチサイズ 32 で 15 エポック学習した. 学習時のデータの 10%を検証データに使用して学習時の検証精度を確認したところ, 金具組立作業は 99.72%, ボルト締め付け作業は 99.53%であった. 図 7 に金具組立作業に関する学習曲線について示す. ボルト締め付け作業についても同様の学習曲線となった.

## 5.4 実験内容

### (1) 静止画に対する分類精度

金具組立作業のサイクルに対して, 学習データに含まれていない非熟練である被験者 2 名 (被験者 C, D) の 1 サイクル目の作業をテストデータとして静止画に対する分類精度を評価することを実験内容とした. このテストデータについては学習データ同様にあらかじめ作業分析ソフトで生成したものを利用し, Alexnet での分類結果と正解ラベルを比較することにより分類精度を求める. ボルト締め付け作業についても, 学習データに含まれない非熟練の被験者 2 名 (被験者 C, D) の作業をテストデータとして準備した.

### (2) 作業手順誤りおよび作業時間乖離に対する検知精度

作業手順の誤りおよび作業時間の乖離に対する検知精度の実験については, 実際に作業手順の誤りが生じる恐れがあるボルト締め付け作業内の手順を対象とした. ボルト締め付けには締め付け箇所の順番 (左上 → 右下 → 右上 → 左下) が決まっておき, 図 8 のとおりとなる.

作業手順の誤りに対する検知については, 被験者 A および学習時に参加していない非熟練の被験者 2 名 (被験者 C, D) の作業状況をカメラで撮影しながら, 実際に作業手順の誤りが発生した際の検知の正確さについて評価することを実験内容とした. また, 標準作業から大きく逸脱した想定外作業に対する検知については, 既定の作業と想定外作業の分類時の確率スコアの傾向から異常検知のための閾値を定めることが可能であるかを評価することを実験内容とした. 尚, 想定外作業については金具組立作業に対してプレートと工具の位置を左右逆にした状況を模擬的に作り出すために, テスト用の画像を左右反転させた画像を 100 枚






図 8 ボルト締め付けの順番  
Fig. 8 Bolt tightening sequence.

準備して分類スコアの評価を行った。

標準作業時間と実際の作業時間の乖離に関する検知については、熟練者の作業分析結果から定めた標準作業時間に対して、本システムで計測・集計された時間を比較することを実験内容とした。実験の際は作業手順の誤りに対する検知と同様、被験者3名の作業をカメラで撮影しながら実施した。

なお、CNNにおける分類精度が100%には至らないことを想定し、瞬間的な誤分類を対象として同一分類結果が  $N$  フレーム連続しなかった場合に、その前の  $N \times 2$  フレーム間での最頻値で分類結果の置き換えを行うスライディングウィンドウ方式によるフィルタ処理を加えた。なお、今回は  $N = 5$  の条件で評価実験を行った。

(3) リアルタイム性

処理のリアルタイム性評価については、CNNでの作業分類処理と、異常検知時のティーチング用動画再生までの処理を実験対象とした。CNNでの分類処理に関しては、5.4節“(1) 静止画に対する分類精度”の際に利用した動画を使用して Alexnet で分類する際に要した処理時間と処理画像数から1秒あたりの平均処理画像数を算出した。異常検知時のティーチング用動画再生までの処理時間については、対象の作業を模範となる作業動画から検索し、該当フレームから再生を開始するまでの処理時間を計測した。

5.5 実験結果

(1) 静止画に対する分類精度

金具組立作業の静止画に対する分類精度の実験結果を表5に示す。この表は分類結果を混同行列で表したもので、行(縦)は実際の正解ラベルのクラス、列(横)はCNNで予測されたクラスであり、各クラスの正解率を対角要素で示したものである。全体の結果として、2名平均の分類精度については93.08%であった。

ただし、被験者Cの“①金具を運ぶ”や“⑤プレート拭き上げ”のように、一部の作業において分類精度が低い箇所が見られた。これらは正解の作業に対してその前後の作業に誤分類しているため、作業間で類似した静止画が存在していることが原因である。図9に被験者Cの“④マッ

表 5 金具組立作業の分類精度

Table 5 Classification accuracy of bracket assembly work.

被験者C	①金具を運ぶ	②板止め	③ボルト締め付け	④マット貼り付け	⑤プレート拭き上げ	⑥金型固定
①金具を運ぶ	81.17%	17.86%	0.97%	0.00%	0.00%	0.00%
②板止め	0.00%	93.89%	6.11%	0.00%	0.00%	0.00%
③ボルト締め付け	0.00%	0.00%	97.39%	2.61%	0.00%	0.00%
④マット貼り付け	0.00%	0.24%	7.77%	91.99%	0.00%	0.00%
⑤プレート拭き上げ	0.00%	0.00%	0.00%	8.01%	84.44%	7.55%
⑥固定	0.00%	0.00%	0.00%	0.00%	4.03%	95.97%
平均						90.81%

被験者D	①金具を運ぶ	②板止め	③ボルト締め付け	④マット貼り付け	⑤プレート拭き上げ	⑥金型固定
①金具を運ぶ	100%	0.00%	0.00%	0.00%	0.00%	0.00%
②板止め	3%	96.98%	0.00%	0.00%	0.00%	0.00%
③ボルト締め付け	0%	1.27%	96.91%	1.82%	0.00%	0.00%
④マット貼り付け	0%	0.16%	0.78%	96.43%	2.48%	0.00%
⑤プレート拭き上げ	7%	0.00%	0.00%	7.41%	85.19%	0.74%
⑥固定	0%	0.00%	0.00%	0.00%	3.47%	96.53%
平均						95.34%




図 9 前後の作業への誤分類ケース  
Fig. 9 Misclassification case between work.

表 6 ボルト締め付け作業に対する分類精度

Table 6 Classification accuracy of bolt tightening work.

被験者C	その他	右下	右上	左下	左上
その他	90.13%	3.95%	1.97%	3.95%	0.00%
右下	0.78%	99.22%	0.00%	0.00%	0.00%
右上	3.36%	0.00%	96.64%	0.00%	0.00%
左下	0.98%	0.00%	0.00%	99.02%	0.00%
左上	0.98%	0.00%	0.00%	2.94%	96.08%
平均					96.22%

被験者D	その他	右下	右上	左下	左上
その他	91.79%	4.35%	1.45%	0.97%	1.45%
右下	0.00%	100.00%	0.00%	0.00%	0.00%
右上	1.22%	0.00%	98.78%	0.00%	0.00%
左下	2.99%	0.00%	0.00%	97.01%	0.00%
左上	0.63%	0.00%	0.00%	1.27%	98.10%
平均					97.14%

ト貼り付け”に誤分類した“⑤プレート拭き上げ”の画像と“④マット貼り付け”の終了時点の画像を一例として示す。

また、ボルト締め付け作業の分類結果を表6に示す。

2名平均の分類精度は96.68%であった。各ボルト締めの対象箇所と“その他”として定義した対象箇所間の移動動作との間で誤分類が見られるが、この原因は前記のとおり類似した静止画が両方に含まれているためである。

(2) 作業手順誤りおよび作業時間乖離に対する検知精度

被験者3名をWebカメラで撮影しながら、4カ所のボルトの締め付け手順を表7のとおり7パターンで評価した。これは4カ所のボルト締め付け手順全24パターンのなかから、正常1パターンと、誤った手順が最初に検知される6パターンである。この6パターンを異常パターンとしてあげた理由は、本システムでは一連の作業手順のなかで最初に誤りが認められた時点を検知対象としているためであ

表 7 ボルト締め作業手順確認パターン

Table 7 Bolting procedure check pattern.

パターン	手順 1	手順 2	手順 3	手順 4	最初に異常を検知する手順
1	左上	右下	右上	左下	正常のため検知せず
2	左上	左下	-	-	手順 2 の左下
3	左上	右上	-	-	手順 2 の右上
4	左上	右下	左下	-	手順 3 の左下
5	左下	-	-	-	手順 1 の左下
6	右上	-	-	-	手順 1 の右上
7	右下	-	-	-	手順 1 の右下

表 9 Alexnet での静止画分類処理数

Table 9 Number of still images classified by Alexnet.

	所要時間 (秒)	分類処理数 (回)	分類処理数@秒
被験者A	260	3761	14.47
被験者B	214	3322	15.52
被験者C	239	3499	14.64
平均	237.67	3527.33	14.88




図 10 確率スコア比較

Fig. 10 Comparing probability scores.

表 8 標準作業時間と実作業時間比較

Table 8 Comparison of standard time and actual time.

	手順 1 (秒)	手順 2 (秒)	手順 3 (秒)	手順 4 (秒)	平均 (秒)
標準作業時間	4.5	4.5	4.5	4.5	4.5
被験者A	3.83	3.62	4.11	5.09	4.16
被験者C	4.86	4.08	4.48	5.17	4.65
被験者D	4.90	3.83	4.56	4.67	4.49
平均	4.53	3.84	4.38	4.98	4.43

る。実験の結果、3名の被験者ともに、正常1パターンは正しい手順として判断し、誤った6パターンについては最初に誤りが発生した作業を対象として異常として100%検知することができた。

また、既定の正しい作業と想定外の逸脱した作業に関する確率スコアの比較結果を図10に示す。ヒストグラムa)は既定の作業で平均の確率スコアは98.14%、同じくb)は想定外の作業で平均の確率スコアは67.47%となった。このヒストグラムで示されたとおり、両者の確率スコアには大きな開きが見られた。

標準作業時間に対する実際の作業時間の乖離の比較については表8に示す。今回、標準作業時間をボルト締め1カ所あたり4.5秒に定め、実際の作業時間の算出については、Webカメラで撮影中の画像に対してCNNで各作業に分類された際のそれぞれの作業の作業開始時刻から作業終了時刻までの経過時間を用いた。

監視のための閾値については本作業に従事している担当者に対してヒアリングを行い、ボルト締め付け不足や作業に無駄が含まれない範囲として標準作業時間に対して±50%とした。具体的には、標準作業時間の50%以下の時間で作業が完了する場合は、作業が不完全でボルトの締め付けが甘い可能性が考えられるため異常として判断し、標準作業時間の150%以上の時間を要する場合は、作業に無

駄があると考えられるため異常として判断するという理由からである。評価の結果、被験者3名ともにそれを超えることはなかった。

(3) リアルタイム性

Alexnetでの分類に関するリアルタイム性を確認するために、動画をフレームごとに抽出しながらAlexnetで分類した際の1秒あたりの処理数について確認した結果を表9に示す。1秒あたり15回弱の処理が可能であることが確認できた。

また、ティーチング用動画再生までの処理時間については、ボルト締め付け作業の4カ所に対する異常検知から対象作業の作業動画再生までの処理時間を10回計測したところ、いずれも1秒未満であった。

6. 考察

3.1節で示した4つの要求条件に関して、4章のシステム構成および5章で示した評価実験結果を基に考察する。

(1) 作業改善を目的とした監視基準であること

作業改善のための分析結果である標準作業と標準作業時間および分析の際の動画を、CNNの学習用データ、監視基準およびティーチングの際の正しい作業手順として利用することにより、本要件をシステムとして実現した。

(2) CNNの学習データの準備が容易であること

実験の準備段階で、製品Aの作業分析結果とその際に使用した動画から学習データの準備を行った。本システムを利用して学習データを準備した場合と、従来の手作業で学習データを準備した場合の作業時間について評価した結果、本システムを利用することにより従来に比べ78%程度の時間削減が可能であることが確認できた。従来の方法である手作業でのラベル付けに時間を要した理由は、連続した静止画を目視で見比べながら作業の区切りとなる画像を見つけることが煩雑なためである。一方、筆者らの方法であれば作業分析ソフトとの組合せによりこれらの作業を効率的に行うことが可能であり、学習データの準備を容易にした。

製品Aでは分析結果がExcelとCSVで出力されるが、外部にデータを出力する仕組みがないような作業分析ソフトについてもRPAを利用することにより分析結果の表示画面から情報の抽出は可能である。本研究の手法を利用することにより、容易に学習データを準備することが可能である。



### (3) 作業手順誤りや時間乖離を正確に検知できること

CNN による静止画の分類精度が平均 90%以上であったこと、および作業手順ミスの検知が正確であったことにより、本要件を満たすことが確認できた。

標準作業から大きく逸脱した想定外作業を検知する方法については、既定作業と想定外作業に関する確率スコアに大きく開きが見られたため、閾値の設定も可能であると考えられる。今回は閾値を定めたうえでの評価は行わなかったため、今後は閾値の妥当性の評価を行いたい。

また今回、CNN の瞬間的な誤分類に対してはスライディングウィンドウでフィルタをかけ、影響を抑えることができた。連続した一連の動作を正しく分類する方法として、画像を時系列シーケンスデータとして取り扱うリカレントニューラルネットワーク (RNN) の利用があげられるため、今後の検討に加えたい。

### (4) 製造現場をリアルタイムで監視可能であること

Alexnet を利用した際の分類については、毎秒 15 フレーム弱の処理ができることが確認された。本システムを製造現場で利用する場合、Web カメラで撮影しながら約 0.07 秒周期で画像を分類することができる。誤分類抑制のためのフィルタ処理におけるウィンドウ数  $N = 5$  に指定した場合、判断が 5 フレーム分遅れることになるが、その場合でも 0.35 秒遅れで異常の検知を行うことが可能である。また、異常検知時のティーチング用動画の再生についても、1 秒未満で処理が可能である。したがって、製造現場で重大な作業ミスが発生した場合においても、即時に誤りを検知し、ティーチングを行うことが可能である。

上記のとおり、本システムの要件に対する有効性は確認できたと考えられるが、リアルタイム性の観点からは、カメラのフレームレートが毎秒 30 フレームの場合は 0.03 秒周期で画像を取得することも可能であるため、引き続き CNN モデルの軽量化などによりリアルタイム性の改善をはかりたい。

## 7. まとめと今後の課題

本研究では作業分析ソフトでの分析結果を利用して、製造現場の作業手順を監視するためのシステムを開発した。作業改善を目的とした作業分析の結果を監視基準として利用する点、その際の模範となった作業動画から監視用 CNN の学習データを自動的に生成する点、それらを利用してリアルタイムに作業手順および作業時間の異常検知を行い、異常発生時に正しい作業手順でのティーチングを行う点を特徴としている。本稿では、金具の組立作業の模擬環境で作業分析を行い、分析結果と分析時の動画から生成されたデータで学習した CNN による静止画に対する分類精度、作業手順および作業時間に対する異常検知精度、処理のリアルタイム性について評価実験を実施し、その有効性について示した。


本研究については、量産品に対する部品組み立て作業や同一製品に対する溶接作業のように、繰り返し行われるルーチン作業に対して応用することは可能であると考えられるが、複雑な製造現場での利用を考慮した場合、画像全体の特徴に基づく検知だけでは十分ではないケースも考えられる。具体的な例をあげると、対象となる製造物の形状がとど異なる場合や、手や工具の移動距離が短い作業、動作に違いが少ない作業などのように、繰り返される作業の中で共通した特徴が存在しないケースや、特徴自体が見出しにくいケースが想定される。これらのようなケースに対応するために、対象となる製造物や工具、作業者の手先など身体の一部を物体として検出し、作業分類のための特徴として組み合わせる方法が考えられる。今後はさらに検知精度を向上させるための深層学習の検討や、複雑な製造現場での利用を想定した際に生じる課題およびその解決策について検討を行いたい。

本研究内容を応用することにより、熟練者の作業手順をデジタル化した技能伝承や人材育成に役立てることが期待される。そのために、熟練者の技能を抽出する方法や、作業者にとって分かりやすいティーチングの仕組みとして三次元画像モデルの利用などについても研究を行う予定である。

## 参考文献

- [1] 経済産業省：2019 年版ものづくり白書, p.17, 入手先 ([https://www.meti.go.jp/report/whitepaper/mono/2019/honbun.pdf/pdf/honbun\\_01\\_01.pdf](https://www.meti.go.jp/report/whitepaper/mono/2019/honbun.pdf/pdf/honbun_01_01.pdf)) (参照 2019-07-10).
- [2] 日本インダストリアル・エンジニアリング協会：IE とは, 日本インダストリアル・エンジニアリング協会, 入手先 (<http://www.j-ie.com/about/about-ie/>) (参照 2019-07-10).
- [3] 中村茂弘：現場力を高める簡単 IE 実践マニュアル, p.114, 日刊工業新聞社 (2011).
- [4] 中村茂弘：現場力を高める簡単 IE 実践マニュアル, p.36, 日刊工業新聞社 (2011).
- [5] 小林尚生, 南野充則：食事画像のラベル付け作業の省力化に関する考察, 第 33 回人工知能学会全国大会 (2019).
- [6] 宇田吉広, 吉田和広, 村田嘉利：深度カメラを用いたピッキング工程における作業ミス検知システム, 情報処理学会論文誌, Vol.6, No.1, pp.63-74 (2016).
- [7] 清水早苗, 平湯秀和, 浅井博次：カメラを用いたものづくり現場における締め付け作業のボカヨケシステムの開発, 電気学会論文誌 C, Vol.129, No.5, pp.916-922 (2009).
- [8] Faccio, M., Ferrari, E., Galizia, G.F., et al.: Real-time assistance to manual assembly through depth camera and visual feedback, *Proc. 52nd CIRP Conference on Manufacturing Systems*, pp.1254-1259 (2019).
- [9] Canziani, A., Culurciello, E. and Paszke, A.: An Analysis of Deep Neural Network Models for Practical Applications, *Proc. 29th Conference on Neural Information Processing Systems*, p.6 (2016).
- [10] Krizhevsky, A., Sutskever, I. and Hinton, E.G.: ImageNet Classification with Deep Convolutional Neural Networks, *Proc. Advances in Neural Information Processing Systems 25* (2012).

- [11] Mathworks : MATLAB-計算技術言語, Mathworks, 入手先 (<https://jp.mathworks.com/products/matlab.html>) (参照 2019-07-10).



村井 浩一 (正会員)

1990年長崎総合科学大学電気工学科電子工学コース卒業。同年株式会社システック井上へ入社。現在, IoTとAIによる製造業向けのソリューションの開発に従事。2019年10月に長崎大学大学院工学研究科博士後期課程へ入学し, 現在在席中。人工知能学会会員。



今井 哲郎

2000年北海道大学工学部情報工学科卒業。2002年同大学大学院工学研究科博士前期課程修了。同年NEC入社, 主に通信NWに関する研究開発に従事。2012年山形大学大学院理工学研究科博士後期課程修了。博士(工学)。

以来, 複雑ネットワークに関する研究に従事。理化学研究所計算科学研究機構特別研究員, 東京情報大学助教, 同大学博士研究員を経て, 2018年9月より長崎大学大学院工学研究科助教。電子情報通信学会, IEEE, APS, 日本医療情報学会, 日本看護研究学会, 日本看護理工学会各会員。



荒井 研一 (正会員)

2004年信州大学工学部情報工学科卒業。2006年同大学大学院工学系研究科博士前期課程修了。2010年同大学院総合工学系研究科博士課程修了。博士(工学)。以来, 情報セキュリティに関する研究に従事。2011年東京理科大学理工学部嘱託助教。2015年長崎大学大学院工学研究科助教。2020年より同大学情報データ科学部准教授。電子情報通信学会, 日本応用数理学会各会員。

以来, 複雑ネットワークに関する研究に従事。理化学研究所計算科学研究機構特別研究員, 東京情報大学助教, 同大学博士研究員を経て, 2018年9月より長崎大学大学院工学研究科助教。電子情報通信学会, IEEE, APS, 日本医療情報学会, 日本看護研究学会, 日本看護理工学会各会員。



小林 透 (正会員)

1985年東北大学工学部精密機械工学卒業。1987年同大学院工学研究科修士課程修了。博士(工学)。同年NTT入社。以来, ソフトウェア生産技術, 情報セキュリティ, データマイニング, Web技術等の研究開発に従事。1998

年から2002年までドイツ, デュッセルドルフに駐在し欧州研究機関とWeb技術, セキュリティ技術に関する共同研究開発, およびスマートカードに関する標準化活動に従事。2013年長崎大学大学院工学研究科教授, 2017年から情報担当副学長, IEEE(シニア), 電子情報通信学会(シニア)各会員。本会シニア会員。