

IoT 実証ラボに指定された実験・実習工場における 学生への教育効果

野口 就平*1・熊澤 典良*1・奈良 大作*1・上谷 俊平*1・近藤 英二*1

Email: kumazawa@mech.kagoshima-u.ac.jp

*1: 鹿児島大学大学院理工学研究科

◎Key Words IoT, 実験・実習工場, 機械学習

1. はじめに

本学大学院理工学研究科には「地域コトづくりセンター中央実験工場（以下、実験工場と呼ぶ）」と呼ばれる実験・実習工場が設置されている。実験工場は旋盤・ボール盤・フライス盤などの種々の工作機械を保有しており、研究・実験に必要な部品や機器の設計製作、部品の設計や加工方法に関する相談、工作機械の操作方法の指導を請け負っている。

実験工場に設置されている種々の工作機械を使用するとき、その操作方法を誤ると重大な事故につながる恐れがある。実験工場では事故を未然に防ぐため、職員による安全教育や巡視が行われている。これまで工作機械の設定、利用者の作業内容および作業方法を確認することで事故防止に努めてきたが、すべての利用者に対して常に目を配ることは困難であり、新たな事故予防と安全対策の導入が望まれている。

先行研究⁽¹⁾⁽²⁾では実験工場に設置されている数台の工作機械を対象として IoT 化が進められ、紙面による利用および機器の稼働情報は自動的にデータベースに記録されるようになった。この度、実験工場が IoT 実証ラボに指定されたことで、工作機械の IoT 化に関する技術と知識の提供を通じた、地方企業の生産性の向上に対する寄与が求められる。実験工場を IoT 実証ラボにするにあたって工場内の全ての工作機械の IoT 化が必要になるが、システムの処理能力と冗長性の低さゆえ、システムの再構築が不可欠である。本報告は、再構築した実験工場の IoT システムについて述べ、IoT 実証ラボのデータが企業の生産性の向上を見据えたものであるが、機械学習を用いることによって学生の教育にも生かすことができることを示す。

2. 再構築したシステム

先行研究⁽¹⁾でなされた実験工場の IoT 化は Raspberry Pi 3 と AVR マイコンの組み合わせによる小規模なものであった。今回、全ての工作機械が IoT 化の対象になることから、先行研究のサーバ機の処理能力の不足とシステムの冗長性を高めるために、本研究では図 1 に示すシステムを構築した。構成したシステムには全ての工作機械にカードリーダーが設置され、USB 接続された Raspberry Pi 3 によって利用者に関する情報をネットワークを介してサーバ機の MySQL データベースに記録する。工作機械の稼働情報は配電盤内に設置したクランプ式電流センサによって消費電力の傾向を

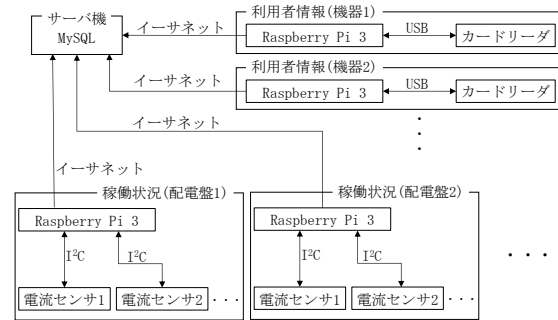


図 1 新たに構成したシステムの構成図

示す電力指標として取得されて、サーバ機の MySQL データベースに記録される。本研究では、これまで工作機械および配電盤内に設置されていたマイコンを Raspberry Pi 3 に換装することでシステムの冗長化を図った。

3. 機械学習による情報の解析

3.1 訓練データの作成

本研究では IoT 実証ラボの保有する情報を用いて、学生に対する教育効果についての解析を行う。解析には機械学習を用いて、フライス盤による機械加工の習熟度を検討する。図 2 および図 3 はそれぞれ職員および学生がフライス盤を操作しているときの電力指標の推移を示している。グラフの縦軸は電力指標、横軸は時間であり、10 分間の電力指標の推移を示している。図中の A の部分ではフライス盤は停止しているが、B の部分では作業が開始されてフライス盤のモータの始動のために短時間に上昇している。C の部分ではフライス盤の主軸は回転しているが切削は行われていない。D の部分では切削が行われており、C の部分に比べて切削抵抗による電力指標の上昇が確認できる。図 2, 3 の比較より職員と学生では C の時間に違いがあることが分かる。これは、学生は職員と比べて機械の操作や加工の手順の習熟度が低く、作業中に迷ったり考える時間が長くなる傾向があるからである。本研究では図 2 の職員が作業を行っている例のように、効率よく作業が実施されているデータを習熟度の高いデータとし、図 3 のような切削を行っていない、C の時間が長いデータは習熟度が低いとして訓練データを作成した。

訓練用のデータはニューラルネットワークの入力となる機器の電力データと、その時の作業者の習熟度の高低を記録した正解データによって構成される。電力




図2 職員がフライス盤を利用している時の電力指標の推移




図3 学生がフライス盤を利用しているときの電力指標の推移

データは毎秒取得される10分間の時系列データであり、そのデータ数は600となる。訓練用の電力データは作業者の習熟度の高いものおよび習熟度の低いものからなり、それらはいずれも250組、合計500組である。用意した500組の訓練データはランダムに375組の学習用データと125組の確認用データに分けられ、学習用データはニューラルネットワークのパラメータの更新に、確認用データは認識精度と推定内容の確認のために用いられる。

3.2 ニューラルネットワークによる解析

機械学習によって電力指標の推移から作業者の習熟度を推定するためにニューラルネットワークを構築⁽³⁾した。入力には10分間の電力指標の推移である時系列データなので入力層のノード数は600、出力層は習熟度の高低に対応する2つの出力ニューロンとした。入出力間には100個のニューロンをもつ隠れ層を設定し、入力層と隠れ層の結合にはバイアスを与えた。今回構成したニューラルネットワークでは活性化関数としてシグモイド関数、損失関数として交差エントロピー誤差を用い、バッチ数を50、学習率を0.01とした。

ニューラルネットワークによる推定には、習熟度の高い作業者のデータを70組、習熟度の低い作業者のデータを50組、合計120組のデータを用いた。ニューラルネットワークによる推定の結果を表1に示す。表から分かるように、職員による機械加工のデータに対して98%の確率で高い習熟度であると判定された。作業者が学生の場合でも、課外活動等で機械加工に慣れており習熟度の高い対象者に対してニューラルネットワークによる推定を行うと、100%の確率で高い習熟度であると推定された。一方、習熟度の低いデータに関して正しく推定できているのは32%のみであったが、推定結

表1 ニューラルネットワークによる推定結果

作業者	習熟度	推定結果 (推定精度)
職員	高	高 (98%)
		低 (2%)
学生	高	高 (100%)
		低 (0%)
	低	高 (68%)
		低 (32%)

果の習熟度が低いと判定された作業者は確実に習熟度は低いといえる。

表1に示すニューラルネットワークによる解析結果から分かるように、学生の習熟度の高低を確実に認識することはできず、習熟度の低い作業者の認識率は32%に留まった。この原因は訓練に用いた電力指標のデータが時系列データであるにも関わらず、単純な構造のニューラルネットワークを用いたからである。しかし、推定を繰り返す行うことによって、試行回数は増加して習熟度の高低は確定される。例えば推定結果の高を“1”、低を“0”として判定を繰り返し、結果の平均を取ることによってその高低は確定できる。習熟度が低いと判定された学生に対して目を配ることで、操作ミスや事故予防のみならず技術向上につながるアドバイスを適切なタイミングで与えることができる。習熟度の推定精度をより高めるためには、時系列データに含まれる図2のCのような特徴を学習することが可能な、畳み込みニューラルネットワークや再起型ニューラルネットワーク⁽⁴⁾の適用が有効であろう。

4. おわりに

本研究ではIoT実証ラボに指定された実験工場において、すべての工作機械をIoT化するためにシステムの再構築を行った。IoT実証ラボのもつ時系列データに対してニューラルネットワークを適用することで教育現場においては工作機械の操作や加工手順に関する習熟度の低い学生の検出が可能となった。このことは実験工場における事故の予防はもちろん、習熟度の評価を通じた教育効果の向上を示唆している。

参考文献

- (1) 熊澤典良, 奈良大作, 近藤英二: “実験・実習工場における教育研究施設としてのIoT化への取り組み”, CIEC 2017 PCカンファレンス論文集, pp.197-198 (2017)
- (2) 野口就平, 熊澤典良, 奈良大作, 近藤英二: “実験・実習工場のIoT化—安全対策に寄与するアプリケーションの開発—”, CIEC九州支部2017九州PCカンファレンス論文集 (2017)
- (3) 例えば, 斎藤康毅: “ゼロから作るDeep Learning—Pythonで学ぶディープラーニングの理論と実装—”, 株式会社オライリー・ジャパン (2016)
- (4) 山室冨, 松原靖子, 川畑光希, 井手優介, 梅田裕平, 古川忠延, 大川佳寛, 丸橋弘治, 稲越宏弥, 櫻井保志: “深層学習を用いた時系列データの要約と分類”, DEIM Forum 2018 データ工学と情報マネジメントに関するフォーラム論文集, C3-3 (2018)