# 故障予測および作業内容予測機能を持つ

# カスタマエンジニアの学習支援システムの提案

中村伊吹<sup>\*1</sup>, 左座祐之助<sup>\*1</sup>, 增田武史<sup>\*1</sup>, 広瀬啓雄<sup>\*1</sup>, 三代沢正<sup>\*1</sup>
\*1 公立諏訪東京理科大学

Proposal for a customer engineer learning support system with failure prediction and work content prediction functions.

Ibuki Nakamura\*1, Yuunosuke Zouza \*1, Takeshi Masuda\*1, Hiroo Hirose\*1, Tadashi Miyosawa\*1
\*1 Suwa University of Science

保守業務において,問題の原因を特定し対処方法を検討するスキルと,部品交換の適切な時期を予測するスキルが重要となる.本研究ではこれらスキルの獲得を目的とした学習支援システムの提案と,システムの中核となる部品交換予測モデル,作業内容予測モデルの構築を行う.提案システムでは,各予測モデルの予測値を参考に保守業務へ取り組むことで,2 つのスキル習得を効率的に行うことを期待している.部品交換予測モデルの構築では,インクヘッド交換の予測を行い,交換日から30日以内に6回中3回のヘッド交換を検出した.作業内容予測モデルの構築では,問題発生時の現象記録から作業カテゴリを予測し,82.3%の正解率であった.今後は各予測モデルの精度向上と提案した学習支援システムを実装する.

キーワード: 学習支援システム, 大判インクジェットプリンタ, 故障予測, 作業内容予測

# 1. はじめに

A 社では大判インクジェットプリンタの製造販売と保守サービスを実施している.大判インクジェットプリンタは,顧客が販売する製品のシールやラベル作成といった業務で利用されている.機器に問題が発生した際には,顧客業務の生産性を低下させる恐れがあり、早急な保守業務の遂行が求められている.A 社では保守業務において,保守作業者の減少による業務の遅延と新人育成が問題視されている.

業務の遅延について、A 社では問題発生時に顧客からの通報を受け、客先に出向き保守作業を行っている(図1).通常であれば、問題発生の通報を受けてから1~3日の間で機器を復旧させることが出来る.しかし、保守作業者が既に他の現場に出向いている等の理由により不在であった場合、機器が復旧するまでに7~10日程経過してしまう.その間、顧客は機器を用いた業務が行えなくなってしまう.そこでA社では業務の遅延を解消するために保守に必要な人員の確保が重要となる.

次に新人育成について,A社での保守業務には必要なスキルが2点ある.1点目は,問題発生時の対処方法を検討するスキルである.対処方法を検討するには,問

題発生時の限られた情報から原因を特定する必要があ り、この調査には時間がかかってしまう.ただし熟練作 業者は、この作業を自身の経験や勘を基に省略するこ とがある.例えば,機器から異音が聞こえた場合,熟練作 業者は過去の似た事例を基に故障原因等を判断し,短 時間で対処を行うことが出来る.作業者がこのスキル を習得するには、長期間の実務を通して得られる経験 や知識といったノウハウを獲得することが重要である. そのため、十分なノウハウを有していない新人作業者 にとって,問題発生時の対策を早急に検討することは 困難である.2点目は,事前に問題発生を予測するスキ ルである.保守業務の際,部品の清掃や設置調整等を行 っているが,部品に何らかの異常がみられた場合は対 象の部品を交換する.保守業務における部品交換は,A 社での負担となるため,部品交換の必要性を見極める ことは重要である.熟練作業者は,業務を通して得られ たノウハウを基に各部品の状態を見極め,適切なタイ ミングで部品交換を行うことが可能である.しかし,新 人作業者は,部品の状態を把握するノウハウを有して おらず,不適切なタイミングで部品交換を行ってしま う.結果として,本来稼働できたはずの部品が稼働でき なくなってしまい,無駄なコストの増加につながる.

いずれも、これら技術の習得には長期間の業務を通して得られるノウハウの獲得が欠かせない。A 社での、ノウハウの獲得には、実務をこなすしかなく、ノウハウの学習に関する有用な学習基盤がない。ゆえに、新人作業者の育成には多くのコストが必要となる。新人作業者が熟練作業者のノウハウを効率的に学ぶための仕組みがあれば、新人作業者の教育にかかる時間を抑え、より短期間で作業者を育成することが可能になる。

しかし,ノウハウの伝承には様々な問題が挙げられる.ノウハウには音や感覚のような言語化の難しい情報が含まれていることや,作業者自身がノウハウに対する自覚が薄いことで,形式知化することが困難であることが多い.ノウハウをテキストや動画で蓄積することが出来たとしても,膨大なデータから必要な情報のみを抽出するためには,多くのコストを要する.また,近年では製造業の現場における技能人材の不足が深刻化しており,熟練作業者が直接ノウハウを伝承しようにも,普段の業務が多忙で技術伝承の時間を確保することが困難になっている.

以上より,本研究で提案する学習支援システムには, 熟練作業者が技術伝承にかける時間を最小限に抑えつつ,新人作業者が効率的にノウハウを学習する機能が 求められる.中でも,問題解決のための作業内容を決定 するスキルと問題発生を予測するスキルの学習支援が 重要である.

そこで,本研究の目的は熟練作業者のノウハウを効率的に獲得するための学習支援システムの提案を行い,システムの中核となる作業内容予測モデルと部品交換予測モデルの構築を行う.

提案する学習支援システムは,作業内容予測機能と 故障予測機能からなり,各予測モデルから出力される 予測結果を参考に保守業務に取り組ませる.その結果, 新人作業者は予測モデルから新たな視点や気づきを得 ることができ,短期間で業務に必要なノウハウを身に 着けることが期待される.さらに,このシステムを活用 することで保守業務の技術支援につながることも期待 される.保守業務での技術支援の取り組みとして,故障 予測機能では,保守に必要なリソースの確保や予知保 全の実施,作業内容予測機能では故障原因の推定等を 行う.詳細については3章で述べる.

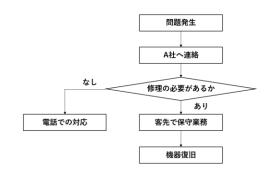


図 1:A 社における保守対応

# 2. 関連研究

近年の製造業における予知保全では IoT 技術の発展に伴い,工場設備や機器に設置されたセンサーデータに対して機械学習を用いて分析する方法が行われている[2].データの分析に機械学習を用いる利点として,データの解析や予測において,専門的な知識を必要としないことが挙げられる[3][4].最近では Automated Machine Learning と呼ばれる,機械学習のモデル構築を自動化するサービスも提供されており,機械学習の活用が容易になってきている[5].これは,多くの企業にとって,データ分析への敷居を下げ,新たなシステムやサービスの提供に繋がる.

機械学習を用いた故障予測を予知保全へ活用しようとする研究も報告されている.宇宙機の故障予兆検知では、教師なし学習の異常検知を用いて X 線天文衛星の電源系機器の故障予兆検知を試み,一定条件下で故障の予兆を検出することが出来ている[6].教師あり学習のクラス分類を用いた工場機器の故障予測では、化学プラントに取り付けられたセンサーデータから機械学習を用いてモデル作成,評価実験を行い,発生頻度の高い故障に対して高い予測精度を得ている[7].これらの先行研究では発生頻度が高い故障への予測や特定条件下での予測には成功しているものの,発生頻度が低い故障の予測精度が低い問題を抱えている.

他にも、本研究で扱うプリンター機器の保守作業を支援するシステムへの取り組みも行われている.[8]のリコーでは全世界の 200 の国と地域に MFP (Multifunction Printer)の販売・サービスを展開しており、日本国内だけでも 400 か所のサービス拠点を有し、数千名の保守担当者が MFP の保守サポートを行っている.リコーでは蓄積されたビッグデータを解析

することで,故障の予兆検知と検知後のアクションを 定めたシステム開発を行い,故障予測の現場での活用 を実現させている.

教師あり学習を用いた故障予測に関する先行研究では,発生頻度が低い故障の予測精度が低い問題点がある.そこで本研究では発生頻度の高い故障については教師あり学習のクラス分類を用いて予測し,発生頻度の低い故障については教師なし学習の異常検知を用いる.私の知る限り,先行研究ではこの 2 種類の予測モデルを利用した保守作業支援システムに関する研究はない.

次に[8]の先行研究では故障の検出から,現場で必要な作業の確定までを行っている.この先行研究と比較して本研究では故障に関するビッグデータを蓄積できておらず,同様の予測方法では困難である.そこで,本研究では保守作業記録から保守に必要な作業内容を予測することで,故障検出後の保守業務支援を行う.

# 3. システム設計

1 章で述べたように A 社では,熟練作業者が技術伝承にかける時間を最小限に抑えつつ,新人作業者が効率的にノウハウを学習する機能が求められる.そこで,本研究で提案するシステムでは,故障予測機能と作業内容予測機能を作成する.そして,予測結果を参考に保守業務に取り組むことで,短期間で業務に必要なノウハウを身に着けることを期待している.加えて,予測結果を保守業務の技術支援につながることも期待している.

故障予測の目標として,故障が発生する 30 日以内に 検出することを目標に設定した.これは,故障の検出が 早すぎる場合には,本来稼働できたはずの時間を無駄 にしてしまう恐れがあるためである.作業内容予測で の目標は,予測を活用した保守作業を行うことで,保守 業務にかかる時間を 50%削減することが出来れば,熟 練作業者のノウハウを効率的に活用できているとして 設定した(表1).システムフローを図2に示す.

表 1:本研究で提案するシステムの機能と目標

機能	目標
故障予測	問題が発生する30日以内に検知
作業内容予測	現場での保守業務にかかる時間を50%削減

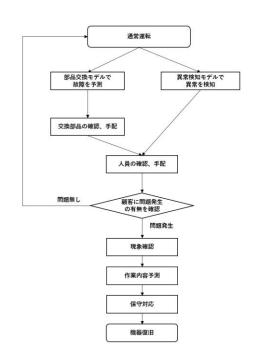


図 2:提案する学習支援システム

・故障予測機能について

本研究で提供する故障予測機能では,異常検知モデルと部品交換予測モデルを作成することで,適切なメンテナンス時期の予測と保守に必要なリソースの確保に活用していく.故障予測機能におけるシステムの構成を図 3 に示す.また,予測モデルの構築方法の詳細については4章で述べる.

部品交換予測モデルでは,部品の適切な交換時期の 予測と交換部品の調達を行うことが期待される.交換 部品の在庫が不足してしまった場合,保守業務の遅延 が生じ,顧客の満足度を下げる可能性がある.一方で,交 換部品の在庫が過剰にあると,部品の管理に不要なコ ストをかけてしまう恐れがある.交換部品の需要を正 確に把握することが出来れば、計画的に保守に必要な リソースを確保することが可能である.部品交換予測 モデルの作成には,交換が必要な部品を特定する必要 があり,教師あり学習を用いて予測することが有効で あると考えられる.しかし.教師あり学習を用いた関連 研究では,発生頻度の高い故障は予測に成功している が、発生頻度の低い故障においては、データ不足等の要 因により予測が行えない問題点がある.そこで,本研究 の部品交換予測モデルの構築には,最も発生頻度の高 いインクヘッドの交換を対象に行う.

異常検知モデルでは、教師なし学習の異常検知を用いて機器の全般的な異常を検知し、保守作業における 人員の手配を行うことが期待される、故障の記録は非 常に少なく,教師あり学習を用いて全ての故障を予測することは困難であるが,教師なし異常検知では,故障記録の少ない異常を検知することが可能である[9].保守業務に必要な人員の手配には,機器が異常か正常かを判別することが出来ればよいため,教師なし学習の異常検知が人員の手配に有効であると考えられる.他にも異常検知モデルでは,部品交換予測モデルで行う予測の信頼性を高める役割を期待している.異常検知モデルと部品交換予測モデルでは,検出可能な問題発生の範囲は異なっている(図 4).ただし,2 つの予測モデルが検出可能な範囲では,より信頼性の高い予測を行うことが出来ると考えられる.

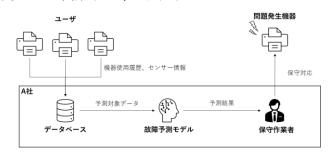


図 3: 故障予測機能のシステム構成

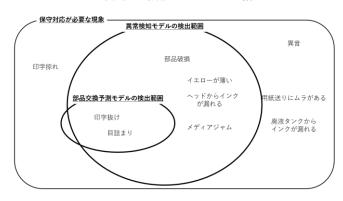


図 4:各予測モデルによる問題発生の検出範囲例

・作業内容予測機能について

作業内容予測機能では、保守作業記録を用いて作業 内容の予測を行っていく、保守作業記録には問題発生 時の現象、原因、対策が記載されている。本研究では、こ の保守作業記録が業務におけるノウハウであるとし て、問題発生時の現象記録から作業内容を予測するモ デルを構築する。このモデルを保守業務の際に使用す ることで、熟練作業者のノウハウを他の作業者でも活 用できるように提供していく(図 5)。これにより、技 術伝承にかかるコストを削減し、問題発生の解決を効 率的に行うことが期待される。



図 5:作業内容予測機能の構成

# 4. 部品交換予測モデルの構築

#### 4.1 対象データ

本章では A 社のプリンターインクヘッドの交換予測 モデルを構築する. インクヘッドとは文字や写真など のデータをもとに, 印刷対象にインクを吐出するプリ ンターのコア部品である. そのため, インクヘッドに問 題が発生した際には, 印刷に支障をきたすため早急な 対応が必要になる. また, インクヘッド交換は保守作業 において最も交換回数が多く, 最も高額な部品である ため, インクヘッド交換の予測が A 社と顧客に与える 影響度は非常に大きい.

インクヘッド交換予測モデルの構築には、プリンター機器から不定期に送られてくるプロファイルデータを用いる(表 2). プロファイルデータにはインク使用料といった機器の使用状況が分かる変数が存在する. データの取得期間はおよそ 3~4 年であり、この期間にヘッド交換が 1,2 回行われている. また、次の前処理を実施して学習に使用した.

- 1. サンプリング間隔の変更
- 2. データ数の少ない機体の削除
- 3. カウンター系変数の初期化
- 4. 移動平均, 階差系列
- 5. 次元圧縮

表 2:データ概要

	次元数	データ件数	故障件数	機体数
前処理前	125	3748	18	39
前処理後	302	15877	17	14

# 4.2 部品交換予測モデルの作成

各プリンター機器から送信されてくるプロファイルデータと機械学習を用いてインクヘッド交換の予測を行い、保守業務への有効性を検証する.保守において故障検出が早すぎる場合、機器が本来であれば稼働できたはずの期間を無駄にする恐れがある.そこで本研究では、ヘッド交換が起こる30日以内に交換を予測する

ことを目標に行っていく. 予測には教師あり学習のクラス分類を用いる. 使用する教師データはヘッド交換日をクラス 1, それ以外の日をクラス 0 として作成した. 使用するデータの 70%を訓練データ, 30%をテストデータとする. 訓練データには 11 件の交換記録とその間の正常データ, テストデータには 6 件の交換記録とその間の正常データが含まれている. 次に実験の手順を示す.

# 1. 特徴量選択と予測

データの次元数が膨大であるため、予測に重要な特徴量を選択する.特徴量選択には機械学習の中でもホワイトボックスな手法である Random Forest と Tab Net を使用する.この2つと前処理後の全ての変数を用いて交換予測を行い、各変数の重要度を求める.

#### 2. 特徴量選択後の予測

両手法における重要度の上位 10 個ずつ,最大で 20 個の特徴量を用いて Gated Recurrent Unit で最終的な交換の予測を行う.

#### 4.3 実験結果

#### 4.3.1 Random Forest による特徴量選択と予測

機体 B, C, E では交換確率がヘッド交換日に近づくにつれて,徐々に上昇する傾向がみられた(図 6). テストデータにおいてヘッド交換日に交換確率が 50%を超えたのは 6 回中 3 回で,ヘッド交換日以外に交換確率が 50%を超えたのは 903 回であった(図 7). 変数の重要度については,ヘッド交換日毎に初期化したカウンター系変数の重要度が高い結果となった(表 3).

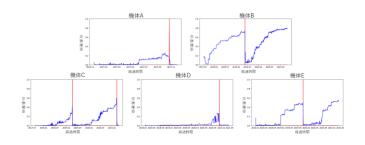


図 6: Random Forest による予測結果, 縦軸: 故障確率, 横軸: 経過時間, 赤線: ヘッド交換日 (ヘッド交換の行われた日を1, それ以外の日を0) 青線: 予測モデルによって得られた故障確率

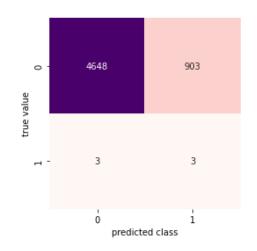


図 7: Random Forest による予測結果 (混同行列)

表 3: Random Forest から算出された重要度上位 1 0

変数	重要度
データ長_cvlog_reset	0.0240
カラー番号5のインク消費量_cvlog_reset	0.0236
カラー番号4のインク消費量_cvlog_reset	0.0233
timestamp_cvlog_reset	0.0228
キャリッジY方向モーター_cvlog_reset	0.0179
ポンプモータAのステップ数_cvlog_reset	0.0171
累積印字タイマ_cvlog_reset	0.0170
原点側廃液のインク量	0.0169
カラー番号 2 のインク消費量_cvlog_reset	0.0166
カラー番号インク消費平均_cvlog_reset	0.0160

#### 4.3.2 Tab Net による特徴量選択と予測

ヘッド交換日に近づくにつれて交換確率が徐々に上昇する傾向はみられなかった(図 8). テストデータにおいてヘッド交換日に交換確率が50%を超えたのは6回中2回で,ヘッド交換日以外に交換確率が50%を超えたのは361回であった(図 9). 変数の重要度では,Random Forest と同様に,ヘッド交換日毎に初期化した変数に加えて,一週間ごとの移動平均をとった変数の重要度が高かった(表 4).

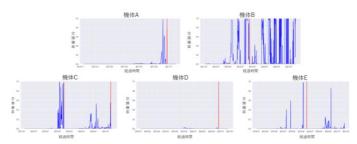


図 8: Tab Net による予測結果,縦軸:故障確率,横軸: 経過時間,赤線:ヘッド交換日(ヘッド交換の行われた 日を1,それ以外の日を0)青線:予測モデルによって 得られた故障確率

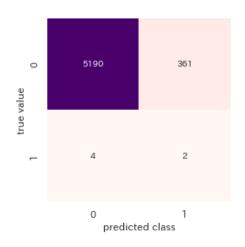


図 9: Tab Net による予測結果(混同行列)

表 4: Tab Net から算出された重要度上位10

変数	重要度
カラー番号インク消費合計_cvlog_reset	0.2815
ヘッド1インク消費合計_mean	0.1721
ポンプモータ寿命:累積_cvlog_reset	0.1536
ポンプモータ寿命:累積_mean	0.1072
ヘッド1~4インク消費合計_mean	0.1049
ヘッド2インク消費合計_mean	0.0693
カラー番号5の充填されているインクの種類	0.0564
Isomap_neighbors15_1	0.0414
原点側廃液のインク量_mean	0.0043
カラー番号5のインク消費量_mean	0.0005

#### 4.3.3 Gated Recurrent Unit による予測

予測に用いる変数は Random Forest と Tab Net から得られた重要度の上位 10 個ずつを用いた.機体 C,D,E では交換確率が交換日に近づくにつれて,徐々に上昇した(図 10).テストデータにおいてヘッド交換日に交換確率が 50%を超えたのは 6 回中 5 回で,ヘッド交換日以外に交換確率が 50%を超えたのは 1232 回であった(図 11).

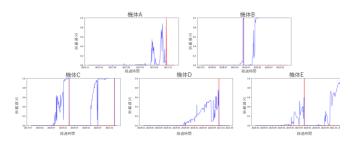


図 10: Gated Recurrent Unit による予測結果,縦軸: 故障確率,横軸: 経過時間,赤線: ヘッド交換日 (ヘッド交換の行われた日を 1,それ以外の日を 0) 青線: 予測モデルによって得られた故障確率

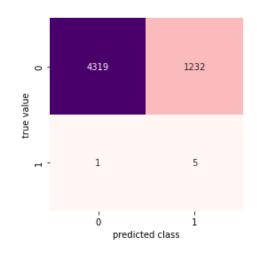


図 11: GRU による予測結果 (混同行列)

#### 4.4 考察

今回行った予測では,交換日までに交換確率が 50% を超えたものの,その後確率が下降してしまうことが ある.そのため,一度でも交換確率が 50%を超えた時点 からヘッド交換までの日数を,交換検出期間とする.表 5 に各機械学習手法によるインクヘッド交換の検出期間を示す.

表 5:各機械学習手法による検出期間の比較

	機体A 1 回目	機体B 1 回目	機体C 1 回目	機体C 2 回目	機体D 1 回目	機体E 1 回目
Random Forest	×	403	×	3	×	1
TabNet	215	×	310	372	×	180
Gated Recurrent Unit	23	11	201	354	135	5

重要度の高い特徴量について、ヘッド交換日毎にカウントをリセットした変数が Random Forest と Tab Net において重要度が高かった. 理由として次の2点が考えられる.1 点目は、今回使用したデータに欠損値が多かったため、補間を行いやすいカウンター系変数の重要度が高いと判断されたこと.2 点目は、カウンター系変数をヘッド交換日ごとに初期化したことで、インク消費量の値やモータ寿命値の組み合わせがインクヘッドの経年劣化を表せたと考えられる.

本予測の目標はヘッド交換日の30日以内に故障を検知することである. Gated Recurrent Unitではヘッド交換日の30日以内に6回中3回のヘッド交換を検出した. また, A社で働く社員に今回の予測に対する評価をいただいた結果, Gated Recurrent Unitを用いた故障予測はメンテナンスに有効であると判断された. また, 検出期間があまりに長すぎるものは, 異常検知モデルから算出された異常度との比較を行うことで予測

# 4.5 システム改善の方策

本研究で使用したデータは予測モデル構築のために取得したものではない.そのため今後は次の方策を進めることで,システム実装に向けた予測モデルの精度向上とデータ取得基盤の改善に取り組む.

#### 1. データ取得間隔の改善

使用したデータは不定期に取得しているため、機体によっては一か月に一度しか取得していないこともある.データの取得間隔をより短くなれば、短期的に変動する変数を扱えるようになるため、直近の予測を行うことが期待される.

#### 2. 特徴量選択手法の改善

本研究での特徴量選択は、Random Forest と Tab Net に依存している。そのため、A 社職員に故障原因のヒアリングをし、予測に有効な変数を調査することで精度を向上することが期待できる。

#### 3. 汎用性の評価

A 社で働く社員の方に今回の予測に対する評価をいただいた結果,本研究で使用したデータでは,メンテナンスに有効であると判断された.本実験で構築した予測モデルを活用して保守業務を行うには,新たに取得したデータを用いて予測精度を調べ,汎用性の評価を行う.

# 5. 作業内容予測モデルの構築

#### 5.1 対象データ

作業内容の予測には保守作業記録を用いて行う.データ概要は表 6 に示す.保守作業記録には問題発生時の現象,原因,対策,作業内容カテゴリが記録されている.本実験で使用する保守作業記録は72件のみで,予測対象の作業カテゴリの件数にはばらつきがある.そのため,本実験での予測対象は作業件数が,上位3つの作業カテゴリに限定する.予測を行う作業カテゴリ毎のデータ件数は表7に示す.

表 6:保守作業記録の概要

現象	原因	対策	作業カテゴリ
印刷時の掠れ	ヘッドの不具合	ヘッド交換	部品交換
メディアにインクが垂れる	ヘッド周りの汚れ	クリーニング	清掃

表 7: 作業カテゴリ毎の発生件数

部品交換	設置	清掃
37	12	7

本実験の目的は,技術伝承にかかるコストの削減を行う予測モデルを構築することである. 予測モデルの構築には自然言語処理モデルの BERT を用いる. 学習には説明変数として問題発生時の現象,目的変数を作業カテゴリとして教師あり学習を行う. また,使用するデータの 70%を訓練データ,30%をテストデータとしてモデルの構築を行う.

# 5.2 作業内容予測モデルの作成結果

表8にテストデータにおける予測結果を示す.

作業カテゴリの予測を行った結果,テストデータにおける予測の正解率は 82.3%であった.作業カテゴリにおいて清掃の必要があるものを部品交換と予測してしまう結果となった.

表 8: テストデータによる予測結果

		予測結果			
		部品交換	設置	清掃	
正解データ	部品交換	11	0	0	
	設置	1	3	0	
	清掃	2	0	0	

#### 5.3 考察

今回の実験では問題発生時の現象から作業カテゴリを予測し、テストデータにおける正解率が 82.3%であった.また、清掃における予測では1件も正解することが出来なかった.清掃の予測が出来なかった原因として、学習に使用したデータに含まれる清掃の件数が最も少なかったことが考えられる.他にも、現象の記録は保守作業者が自然言語で記述したものであるため、記載内容には個人差がある.解決策として、記録の記載をチェックシートにすることで、作業者の個人差によらず、均一の作業記録を取得することが期待できる.

本実験の目的は作業カテゴリの予測によって技術伝 承にかかるコストの削減を行うことである。今回は作 業カテゴリの予測を行ったが、作業カテゴリの予測だ けでは、どの部品に対して作業を行うのかが不明であ るため、保守業務の支援につながる可能性は低いこと が考えられる。今後、保守業務の支援を行うには作業カ テゴリを予測するだけではなく故障の原因や作業箇所 の特定を行う必要がある.

# 5.4 システム改善の方策

本研究で使用したデータは予測モデル構築のために取得したものではない.そのため今後は次の方策を進めることで,システム実装に向けた予測モデルの精度向上とデータ取得基盤の改善に取り組む.

# 1. データの新規取得,データ拡張

今後も新規の保守作業記録を取得し,清掃の予測に 十分なデータの確保を行っていく.データ拡張に関し ては,保守作業記録に記載されている単語をもとに,学 習用データを拡張することで,予測精度の向上が期待 される.また,作業者が過去に行った保守業務の内容を ヒアリングすることで,保守作業記録にはないノウハ ウを取得することが期待される.

#### 2. チェックシートの作成

保守作業記録の記載内容に個人差があることが原因で、予測精度が低下したことが考えられる。そのため、現時点での現象からチェックシートを作成することで記載内容の均一化を行っていく。また、作業記録をカテゴリ変数にすることで、データ数が少なくても学習可能な手法の適用が期待される。

# 3. 作業箇所,故障原因の予測

本実験での予測では作業カテゴリの予測を行ったが、保守業務を行うには、故障原因の特定と対策が重要である. そのため、本実験で実施した作業カテゴリの予測だけでは、業務を行うためには不十分である. 今後は、問題の原因や対策を予測していくことで、保守業務に活用可能な予測モデルを実装する.

# 6. まとめ

本研究では、熟練作業者のノウハウを効率的に獲得するための学習支援システムの提案と、システムの中核となる部品交換予測モデルと作業内容予測モデルの構築を行った.

部品交換予測モデルの作成では、Random Forest、Tab Net から重要度の高い特徴量を選択し、Gated Recurrent Unit で予測することで、交換日の30日以内に6回中3回の交換を検出した。また、Gated Recurrent Unit による予測をA社の職員に評価していただき、メンテナンスに有効であると判断された。精度を向上す

るためにはデータ取得間隔の変更や A 社職員のヒアリングを通じて特徴量を精査する必要がある.

作業内容予測モデルの作成では、問題発生時の現象から作業カテゴリの予測を行い、正解率は 82.3%であった.また、清掃に関する予測は1件も正解することが出来なかった.原因として、清掃に関する記録が7件しかなく、予測対象である作業カテゴリの中で最も少なかったことや、作業記録の記載に個人差が大きいことが挙げられる.予測精度を向上する方法として、保守作業記録をチェックシートに変更することで、記載の個人差を少なくすることが期待される.また、本実験では作業カテゴリの予測を行ったが、保守業務を支援するためには作業箇所、故障原因の予測を行う必要がある.

本研究で使用したデータは、予測モデルの構築を目的に収集したものではない。そのため、今後はシステム実装に向けて、今回の結果を基にデータ取得基盤や予測精度の改善に取り組んでいく。また、異常検知モデルの作成と図2に示した保守システムの実装と評価を行う.

# 参考文献

- (1) 経済産業省, "製造基盤白書(ものづくり白書)",2018
- (2) 今村 誠, "予知保全のための機械学習",システム/制御 /情報,65 巻,4 号,p.119-125,2021
- (3) Yann LeCun, Yoshua Bengio, and Geoffrey Hinton:
  Deep learning. Nature 521.7553 2015: 436-444
  Rockart, J. F. and Morton, M.S.S.: "Computers and the Learning Process in Higher Education", McGraw Hill, New York (1975)
- (4) 松尾豊, 人工知能は人間を超えるか: ディープラーニン グの先に あるもの: KADOKAWA, 2015.
- (5) Google: Cloud AutoML, https://cloud.google.com/automl
- (6) 梅津里香,杉江卓哉,長瀬雅之,et al, "機械学習を用いた 宇宙機の故障の予兆検知,宇宙科学情報解析論文 誌",JAXA-RR-18-008,8 号,p.11 - 20,2019
- (7) 切通 恵介,泉谷 知範, "機械学習を用いた工場機器の 故障予測",DEIM forum 2017
- (8) 奥 武憲, 水野 哲志, 林 俊輔, 荒井 仁, et al. MFP の ビッグデータを活用した故障予測", Ricoh technical report, 43 号, p.56-62, 2018
- (9) 曽我部東馬: Python による異常検知, オーム社, 2021