

油圧ショベルの故障予測に関する研究

(A Study on Failure Prediction of Hydraulic Excavators)

広島大学 先進理工系科学研究科

先進理工系科学専攻 電気システム制御プログラム

D202282 小熊 尚太

2023年3月

目次

第1章	序論	1
1.1	研究背景	1
1.2	データにもとづく故障予測	4
1.3	本論文の章構成	5
第2章	時系列データを用いた油圧ショベルの故障予測	7
2.1	緒言	7
2.2	オートエンコーダを用いた故障予測	11
2.2.1	オートエンコーダ	11
2.2.2	畳み込みオートエンコーダ	13
2.2.3	LSTM オートエンコーダ	14
2.2.4	評価方法	17
2.2.5	評価結果	18
2.3	掘削作業の操作特性の比較方法	26
2.3.1	評価方法	26
2.3.2	評価結果	31
2.3.3	考察	37
2.4	結言	39
第3章	掘削作業の動作分類と特定動作における故障予測	40
3.1	緒言	40
3.2	油圧ショベルの掘削作業の動作分類	44

3.2.1	LSTM による動作分類方法	44
3.2.2	評価方法	45
3.2.3	評価結果	49
3.3	特定動作に着目した故障予測	53
3.3.1	動作分類を利用した故障予測方法	53
3.3.2	評価結果	58
3.3.3	考察	63
3.4	結言	65
第4章	油圧ショベルの残存耐用時間による故障予測	66
4.1	緒言	66
4.2	油圧ショベルの下部走行体の故障予測	69
4.2.1	機械学習モデルによる故障予測	71
4.2.2	評価結果	74
4.3	油圧ショベルの残存耐用時間予測	80
4.3.1	故障データのクラスタリング	80
4.3.2	残存耐用時間の予測方法	81
4.4	残存耐用時間の評価方法	83
4.5	結果	84
4.5.1	k-Means クラスタリングの結果	84
4.5.2	残存耐用時間の予測結果	86
4.5.3	考察	89
4.6	結言	92
第5章	結論	93
参考文献		97

引用既発表論文	101
A. 学術雑誌等掲載論文	101
B. 国際学会等講演論文	101
その他既発表論文	102
C. 学術雑誌等掲載論文	102
謝辞	103

第1章 序論

1.1 研究背景

日本における生産年齢人口(15~64歳人口)は、1995年に8,716万人となったのをピークに年々減少の一途をたどっている [1]。総人口についても、1億2,806万人でピークを迎えた2010年から年々減少し、2053年には総人口が9,924万人となり、1億人を割り込む見込みとなっている。建設業においても、就業者人口が1997年に685万人となったのをピークとし、2020年には492万人にまで落ち込んでおり、この20年間でピーク時から約28%減少している [2]。また建設投資額は、1992年度に約84兆円でピークに達し、2010年度には約41兆円まで落ち込んだものの、2021年度にはピーク時の約70%となる約58.4兆円まで増加している。

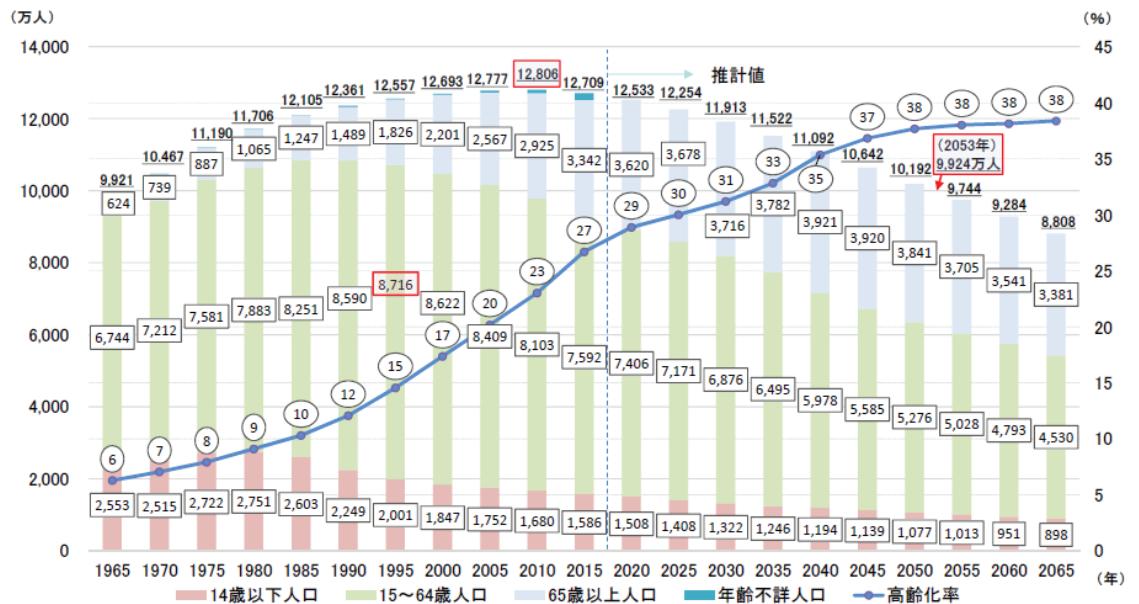


Fig. 1.1: Transition of total population [1]

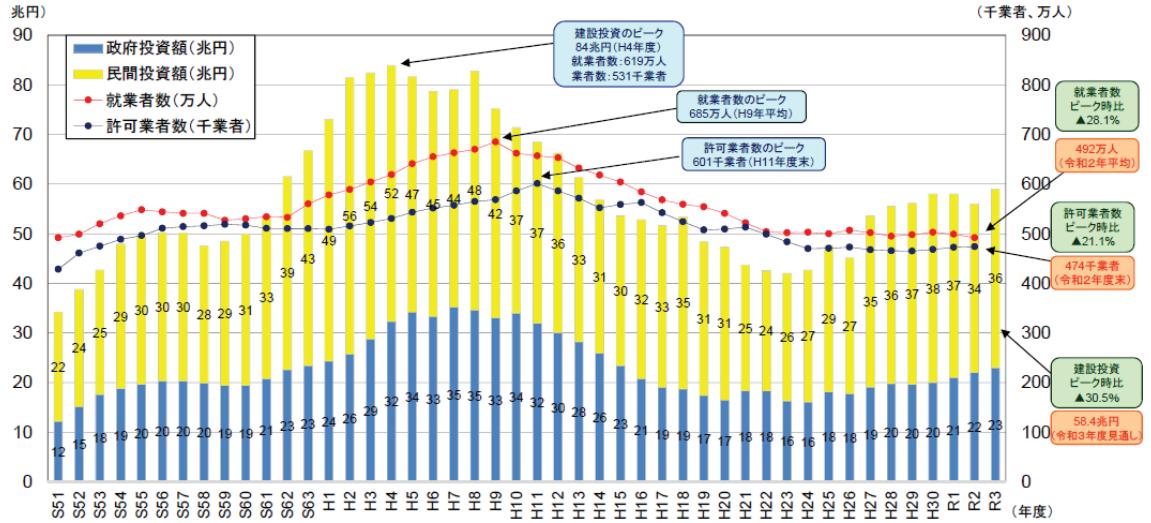


Fig. 1.2: Transition of construction investment and the number

of construction workers [2]

Fig.1.3 は、建設業就業者における 55 歳以上の割合、および 29 歳以下の割合の推移を全産業と比較したグラフである [2]. 55 歳以上の人口は約 34%，29 歳以下が約 11% となつており、全産業と比べても高齢化が進行しており、若年層の比率も低調したままである。高齢の建設業就業者は 10 年以内には、その大半が引退することが見込まれており、次世代への技術継承が大きな課題である。若年層についても、入職者の確保や育成が喫緊の課題であると言える。このように、生産年齢人口と同様に建設業就業者人口も減少しており、また少子高齢化により建設業就業者における高齢者の比率が増加するとともに、若年層の割合が減少しているため、建設業における就業者的人材確保が課題となっている。また、東京オリンピックや震災復興による需要は、ひととおりインフラ工事が落ち着いたものの、今後も老朽化した設備やインフラ補修の需要が見込まれる。

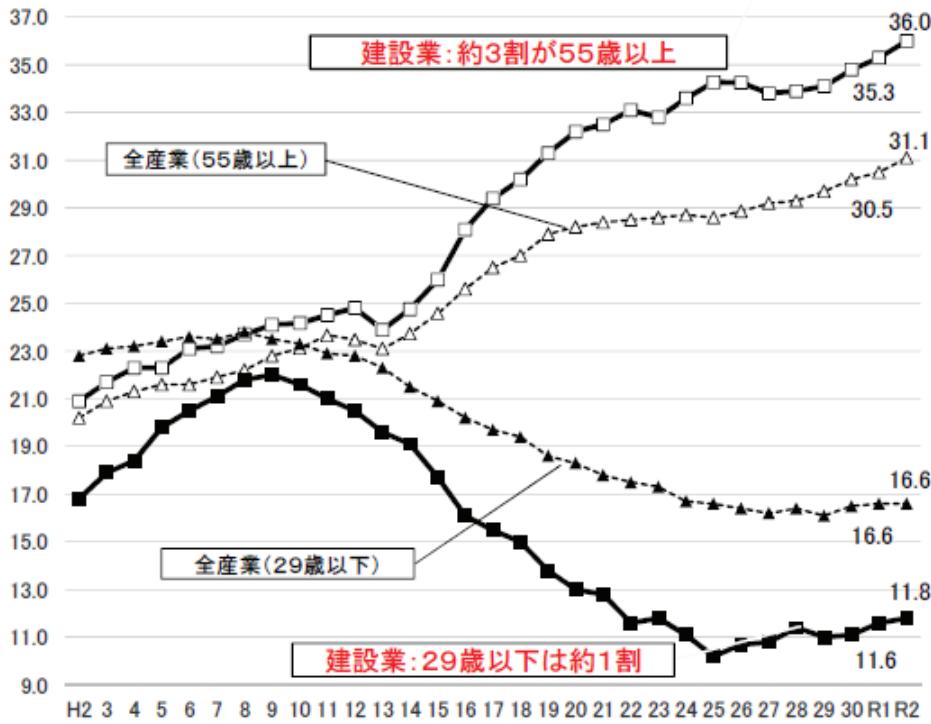


Fig. 1.3: Aging construction workers [2]

これらの課題を解決するために、国土交通省では「i-Construction」を推進し、「ICT の全面的な活用」、「規格の標準化」、「施工時期の平準化」等の施策を建設現場に導入することによって、建設生産システム全体の生産性向上を図ろうと試みている [3][4][5]。この「i-Construction」の取り組みの中で、特に「ICT の全面的な活用」では、ドローン等による 3 次元測量や 3 次元測量データによる設計・施工計画、ICT 建設機械の自動制御による施工などにより、建設現場での作業効率化に関わる施策が取り組まれている。そして、調査・測量から設計、施工、検査、維持管理・更新までの全ての建設生産プロセスで ICT 等を活用することで、建設現場の生産性を 2025 年度までに 2 割向上することを目指している。これにより、今までよりも少ない人数・少ない工事日数で同じ工事量の実施を実現できるものと見込んでおり、これらの取り組みによって、従来の 3K(きつい、きたない、きけん)のイメージを払拭することで新 3K(給与がよい、休暇がとれる、希望がもてる)の魅力ある現場を

目指している。

このような生産性を向上させる施策を行われる際にも、従来と同様に建設現場において、油圧ショベルなどの建設機械車両は必要不可欠である。建設現場で稼働する建設機械に対して保全活動やメンテナンスは、欠かせないものである [6]。保全には、故障やトラブル発生後に処置を行う「事後保全」と、故障前に手当を行う「予防保全」に大別される。「予防保全」には、定期的な点検やメンテナンスに該当する「時間計画保全」と、機械に設置されたセンサにもとづいてメンテナンス時期が決定される「状態基準保全」の2種類に大きく分けられる。とくに、近年は、後者による方式が見られるようになってきている。建設現場を計画通りに施工を進めていくためには油圧ショベルなどの建設機械をメンテナンスしなければならず、突発的な故障は避けられるべきである。インフラの整備は、この先も需要が減ることは考えられないため、建設業の生産性を向上させるためには施工計画外のトラブルは大きな損失となる。

以上の背景により、代表的な建設機械のひとつである油圧ショベルを研究対象とし、油圧ショベルの稼働データから故障を予測する。

1.2 データにもとづく故障予測

近年ではデータ活用への関心が高まっており、機械学習や深層学習などといった人工知能から平均・分散などの統計情報を使うことにより、産業領域での課題を解決することが求められている。このような課題を解決するために、建設業では油圧ショベルから取得されるセンサデータを解析することで得られる結果から機械の状態を把握し、保全活動に役立てている。このデータ活用により故障を予測し、事前にメンテナンスを行うことで故障をなくし計画通りの施工を行う必要がある。

油圧ショベルの故障予測に対して、機械の稼働ロスを最小化し、建設現場の生産性を向上するためには、以下の項目が重要となり、それらに基づく故障予測手法が必要となる。

故障データが少ない場合にも有効な方法として,

(i) 正常データから故障予測が可能なモデルによる故障を予測する方法

(ii) 機械特性をモデル化し, その変化から故障を予測する方法

また, 故障データが十分に蓄積されている場合に有効な方法として,

(iii) 教師あり学習を用いたモデルから故障を予測する方法

建設機械をはじめとする製造業では, あらかじめ故障データを大量に準備することは困難であるため, 故障データが少ない場合にも有効な故障予測が必要である. この故障データが少ない場合にも, 正常データから故障予測が可能なモデルや油圧ショベルの機械特性のモデルを作成することで故障を予測する. 正常データから故障予測のモデルを作成する方法としては, 油圧ショベルの掘削作業における時系列データに LSTM オートエンコーダモデルを適用する. 油圧ショベルの機械特性をモデル化する方法では, 掘削作業の動作分類を行い, 特定動作における作業データを抽出し故障予測モデルを作成する. また, 故障データが十分にデータベースに確保できている場合には教師あり学習による故障予測が有効であるため, 機械学習モデルによる故障有無の予測と残存耐用時間の予測を行う.

1.3 本論文の章構成

油圧ショベルのアフターサービス業務における保全活動を対象とし, 機械から得られる稼働データにもとづいた故障の予測方法を提案する. 本論文における構成を以下に示す.

第 1 章では, 建設業における社会的課題について説明し, 油圧ショベルのメンテナンス・保全活動に関する課題を述べる. また, 本論文のテーマでもあるデータにもとづいた故障予測の重要性について述べ本研究の位置づけを提示する.

第 2 章では, 油圧ショベルの掘削作業において LSTM オートエンコーダを適用した故障予測方法を提案し, その有効性を検証する. 一般的な故障予測の手法では, 教師となる故障データを事前に集める必要があるが, まず, 油圧ショベルの正常な状態の時系列データを

LSTM オートエンコーダに学習させ、再構成誤差を指標としてテストデータの故障有無を評価する。次に、LSTM オートエンコーダによる故障予測の誤検知を抑制するため、畳み込みオートエンコーダを用いた操縦技量の差異分析法を提案し、掘削作業における操縦技量を従来手法である主成分分析と比較することで、有効性を示す。さらに、「熟練操縦者」と「一般操縦者」の操作技量を再構成誤差によって評価し、本提案法の有効性を検証する。

第 3 章では、掘削作業の動作分類と特定動作における故障予測方法を提案する。まず、油圧ショベルの掘削動作である「掘削」、「持ち上げ旋回」、「排土」、「復帰」の各動作を長期的な時間依存性を学習できるといわれている LSTM により分類できるモデルを作成する。つぎに、操作スキルの異なる操縦者（「熟練操縦者」、「一般操縦者」、「非熟練操縦者」）の掘削作業データを LSTM モデルにより 5 種類の動作に分類し、予測された動作の予測確率から操縦者の特徴を比較できることを示す。さらに、機械特性から流量を予測できる重回帰式によりポンプ故障の予測モデルを作成する。この際、油圧ショベル特有のシステムによる誤検知を抑えるため、「持上げ旋回」動作の作業データから予測モデルを作成し、故障の有無を判定することで提案法の有効性を示す。

第 4 章では、油圧ショベルの下部走行体の故障を予測する方法を提案する。機械の構造上、下部走行体の損傷具合を測定できないため、まず、油圧ショベルのセンサから収集されデータベースに蓄積された稼働データと故障情報から機械学習モデルを作成することにより、機械の故障有無を予測する。つぎに、油圧ショベルの稼働状況による違いを考慮するため、kMeans 法によるクラスタリングを行い、機械の使われ方による分類を行う。さらにクラスタリングされたデータの中から、十分にデータを確保できているクラスタに対して、少ない誤差で残存耐用時間を予測できることを示す。

第 5 章では、本論文の研究を総括し、今後の研究展望について述べる。

第2章 時系列データを用いた 油圧ショベルの故障予測

本章では、まずオートエンコーダを用いた故障予測方法を述べ、掘削作業における油圧ショベルの故障事例に適用した結果を示す。つぎに、畳み込みオートエンコーダを用いた油圧ショベル操縦者の技量差異を分析する手法について述べ、さらに実際の掘削作業における熟練操縦者の作業データと一般操縦者の作業データの技量差異を評価することにより、提案手法の有効性を示す。

2.1 緒言

油圧ショベルをはじめとする建設機械や産業設備などの長期間にわたる故障による作業停止は、ユーザ／メーカ双方にとって多大なる損失に繋がる [6]。その結果、生産ラインや施工現場などの計画通りに運用ができなくなり、計画変更を余儀なくされる。このような故障を防ぐためには、定期的なメンテナンスやアフターサービスなどの保全活動が欠かせず、近年では IoT やセンサデータなどを活用した「状態基準型」の保全活動やアフターサービスが見られるようになってきた。「状態基準型」の保全を行うことで、故障に至る前に兆候を捉えて事前にメンテナンスを行えば、長期間にわたる作業停止を防ぐことができる。

このような研究の先行事例として、切通らは化学プラントのセンサデータを用いて数種類の機械学習により工場機器の故障を予測するモデルを作成し、比較・評価を行い、ニューラルネットワークの有用性を確認している [7]。森山らはダイカスト設備に取り付けたセンサから得られる時系列データを使い設備の状態変化を示す異常度を算出し、センサデータの因果関係を評価している [8]。渋谷らは多次元のセンサ信号に基づき設備故障の兆候を早

期に検知する手法を提案している。そこでは、局所部分空間法に基づくモデルから異常判定する方法を実在する設備に適用し、故障の数日前に異常を検知できることを確認している[9][10]。さらに、朝日らは工場設備の故障を加速度センサから得られる振動データを用いて、機械学習により予測する手法を提案している[11][12]。このように製造業において生産設備やプラントなどに対して多数の監視用センサデータから得られた時系列データを活用した故障予測手法が提案されている。

しかし建設機械の故障に対し、これらの先行研究のような故障データをもとにした「教師あり学習」を行うためには、事前に教師となる故障データを大量に集める必要がある。建設機械をはじめとする製造業においては故障データが少なく、「教師あり学習」を用いた故障予測に不向きことが多い。

そこで、事前に教師となる故障データを集めることのない故障予知方法を提案する。具体的には、「教師なし学習」のひとつであるオートエンコーダを用いることにより、稼働中の油圧ショベルから取得された時系列のセンサデータから、早期に異常を診断し故障を予知する方法を提案する。また、油圧ショベルの実際の稼働データへ適用し、その有効性を検証する。

また、このようなオートエンコーダを用いた故障予測方法では機械の操作技量による影響により、判定結果が誤検知となる可能性がある。したがって、これを抑制するためには操縦者の操作技量を評価する必要がある。

建設機械に対する技量評価では制御工学的なアプローチによる技量評価手法[13]や油圧ショベルの掘削時におけるバケット軌跡から操縦スキルを解析する手法[14]、機械学習による特徴分析手法が用いられている[15][16]。これらの研究により、熟練度が高い操縦者ほど反復動作において滑らかで規則的な操縦を行っていることが明らかになっている。一方、いずれの手法も操縦者のどの操作が技量差異を生じさせたかについては数十種類のセンサデータの中から解析によって特定しており、建設機械に対する深い知識と多くの労力

を必要とする。

人の単一の動作や歩行などの単純な反復運動を対象とした技量評価の研究では、主成分分析や特異値分解などの次元圧縮手法が用いられている [17][18][19]。これらは人に取り付けられた多数のセンサから取得される多次元データを低次元空間へ線形写像することによって低次元の特微量を獲得し解析する手法である。対象者により動作時間が異なる場合でも適用可能であり、低次元で表現される対象者の動作の特徴を解析できるため、対象者間でどのような技量差異があるかを具体的に明らかにすることができる。しかし、非線形性を含むデータ構造に対しては情報の損失が大きくなる問題があるため、建設機械への適用は難しい。

そこで、学習データの特徴に類似するデータのみを復元できる畳み込みオートエンコーダ(CAE: Convolutional Autoencoder)を用いて油圧ショベル操縦者の技量差異を分析する手法を提案する。具体的には、熟練操縦者の作業データのみをオートエンコーダに学習することで熟練操縦者の特微量分布を低次元の特微量空間で獲得する。熟練操縦者の特微量分布を獲得することにより、熟練操縦者の特徴を含むデータは復元することができるが、熟練操縦者に無い特徴を含むデータは復元することができない。この時の復元度合(再構成誤差)を計算することで、技量差異を評価する。さらに、畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)とオートエンコーダを組み合わせた CAE は畳み込み層での局所的な畳み込み演算によって入力データを特徴マップへ繰り返し変換しながら次元圧縮する手法であり、時間方向に 1 次元の畳み込み演算を行うことで時系列データに対しても適用可能である [20]。この CAE を用いて油圧ショベルの動作が切り替わる短い区間の特徴を効果的に抽出する。

本章では、油圧ショベルの掘削作業にオートエンコーダを適用し、故障予測を行った結果を示す。正常な状態の掘削作業データを学習させることで異常な状態を含んだデータを評価すると、再構成誤差の値がしきい値を超えることを確認している。またオートエンコーダ

を用いた故障予測では操作技量による影響により判定が誤検知となる可能性がある。これを抑制するため、CAE を用いた油圧ショベル操縦者の操作技量差異を分析する方法を提案する。その結果、主成分分析を用いるよりも作業データの情報を損なうことなく特徴量分布を獲得できることを確認している。また、一般操縦者の操作が熟練操縦者の特徴と異なる場合には、CAE では復元できないことを示している。

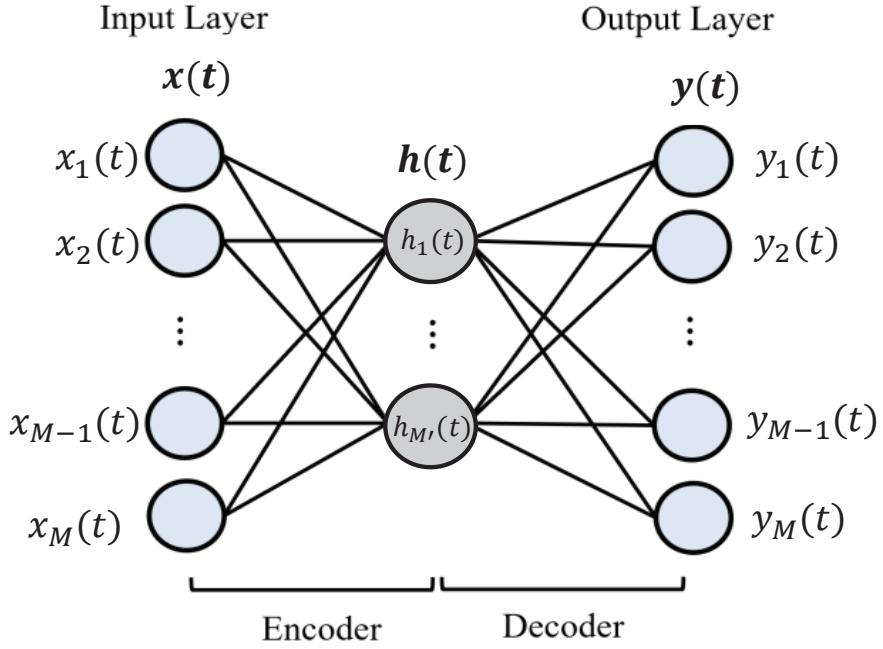


Fig. 2. 1: Autoencoder

2. 2 オートエンコーダを用いた故障予測

「教師なし学習」のひとつであるオートエンコーダ(Autoencoder)とよばれる手法を用いて [21], 油圧ショベルの掘削作業における故障予測について考える.

2. 2. 1 オートエンコーダ

Fig.2.1 に基本的なオートエンコーダの構造図を示す. オートエンコーダは, エンコーダとデコーダから構成される. $\mathbf{x}(t)$ はデータ数 N の入力データ \mathbf{x} の t 番目のデータ ($t = 1, 2, \dots, N$) を示す. $\mathbf{x}(t)$ の要素数を $M(\mathbf{x}(t) = (x_1(t), \dots, x_M(t)))$ とし, 圧縮する次元数は $M' (< M)$, 圧縮後の特徴量を $\mathbf{h}(t) = (h_1(t), \dots, h_{M'}(t))$ とした時, エンコーダ部は式(2.1)で定式化される.

$$\mathbf{h}(t) = f(\mathbf{W}_e \mathbf{x}(t) + \mathbf{b}_e) \quad (2.1)$$

ここで, f は非線形活性化関数である. \mathbf{W}_e と \mathbf{b}_e はそれぞれニューラルネットワークの重みとバイアスである.

つぎに、この時のデコーダ出力を $\mathbf{y}(t) = (y_1(t), \dots, y_M(t))$ とした時、デコーダ部は式(2.2)のように定式化される。

$$\mathbf{y}(t) = g(\mathbf{W}_d^T \mathbf{h}(t) + \mathbf{b}_d) \quad (2.2)$$

ここで、 g は非線形活性化関数である。 \mathbf{W}_d と \mathbf{b}_d はそれぞれニューラルネットワークの重みとバイアスである。

入力と出力の誤差は式(2.3)の平均二乗誤差を用いて計算される。

$$E(\mathbf{x}(t), \mathbf{y}(t)) = \frac{1}{M} \|\mathbf{x}(t) - \mathbf{y}(t)\|_2 = \frac{1}{M} \sum_{m=1}^M |x_m(t) - y_m(t)|^2 \quad (2.3)$$

オートエンコーダの学習にはミニバッチ学習が用いられる。ミニバッチ学習とはデータ数 N の \mathbf{x} からランダムに n 個のデータを取り出し、取り出した n 個のデータの誤差の平均値を用いてオートエンコーダのパラメータを学習していく手法である。この時、取り出した n 個のデータの誤差の平均 L を損失関数といい、式(2.4)で表される。

$$L = \frac{1}{n} \sum_{t=1}^n E(\mathbf{x}(t), \mathbf{y}(t)) \quad (2.4)$$

1 回のパラメータ更新が終わると、再びランダムに n 個のデータを抽出して学習を行い、全てのデータが抽出されるまで繰り返す。ここまでサイクルの単位をエポックといい、取り出すデータ数 n をバッチサイズという。

学習パラメータを $\boldsymbol{\theta} = (\mathbf{W}_e, \mathbf{W}_d, \mathbf{b}_e, \mathbf{b}_d)$ とした時、損失関数が最小となるような $\boldsymbol{\theta}$ を確率的勾配降下法などの最適化手法によって求める。この時、特微量空間では学習データの情報をできる限り保存するような特微量分布が存在している。そのため学習データと類似する特微量分布を持つデータであれば事前に獲得している特微量分布を利用して高い精度で復元することができる。ただし、学習データと大きく異なる特微量分布を持つデータは復元することができない。さらに、このような基本的なオートエンコーダに対して中間層を多層化することにより非線形な表現力が増すことが知られている [22]。

2.2.2 畳み込みオートエンコーダ

畳み込みオートエンコーダ(CAE: Convolutional Autoencoder)では主に画像認識に用いられる CNN により中間層が多層化される。CNN は主に入力層で入力データを受け取り、畳み込み層とプーリング層をいくつか繰り返した後、全結合層、出力層へつながる構造である。畳み込み層では画像のような 3 次元の入力データに対して畳み込み演算をすることによって特徴マップを生成する。特徴マップもまた 3 次元配列で表され、チャネル数は畳み込み演算に用いるフィルタ数で決まる。1 層目のフィルタサイズが $P \times Q$ である畳み込み層で縦横サイズが $H \times W$ 、チャネル数が K の画像を受け取った場合、 l 番目の特徴マップのピクセル (i, j) の値 $u_{i,j}^l$ は以下のように表される。

$$u_{i,j}^l = \phi \left(\sum_{k=0}^{K-1} \sum_{p=0}^{P-1} \sum_{q=0}^{Q-1} z_{i+p, j+q, k} w_{p,q}^l \right) \quad (i = 0, 1, \dots, H-1 \quad j = 0, 1, \dots, W-1) \quad (2.5)$$

ここで $z_{i,j,k}$ は入力データのチャネル k におけるピクセル (i, j) の画素値、 $w_{p,q}^l$ は l 番目のフィルタのピクセル (p, q) の重み係数、 ϕ は活性化関数である。

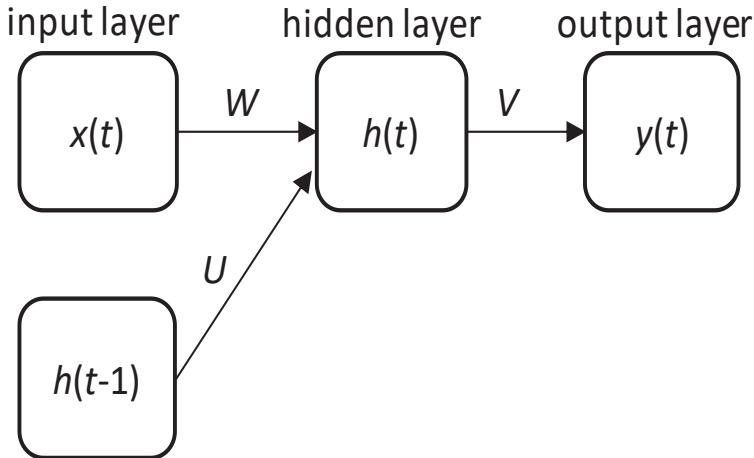


Fig. 2.2: Recurrent neural network

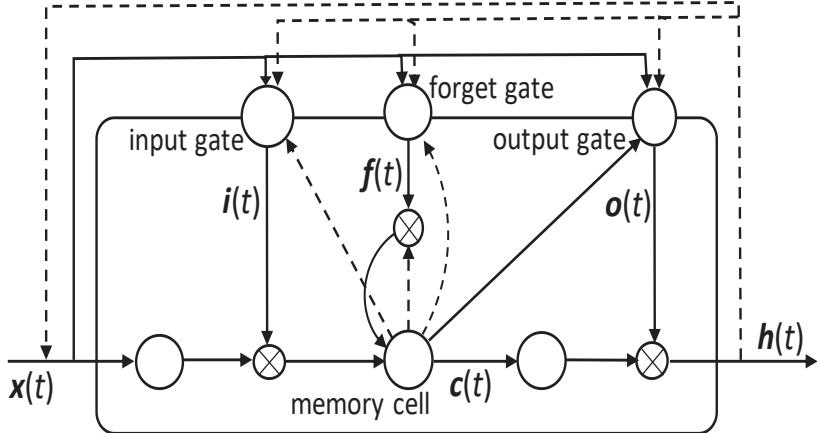


Fig. 2.3: LSTM block

2.2.3 LSTM オートエンコーダ

時系列データを扱うため、時間概念をニューラルネットワークに導入する必要がある [23]. Fig.2.2 にリカレントニューラルネットワーク(Recurrent Neural Network)を示す. Fig.2.2 に示す $x(t)$ は時刻 t における入力データ、 $h(t)$ は隠れ層の出力値を示している. $h(t)$ は過去からの影響を考慮して、過去の隠れ層の出力 $h(t-1)$ を加えた値となる. また W , U , V は、それぞれ $x(t)$, $h(t-1)$, $h(t)$ の重みを表す. 過去の隠れ層を導入することにより時系列データを扱えるようになったが、長期の時間依存性はパラメータの勾配が消失してしまうことから学習が進まない場合があるという問題を抱えている [24].

この問題を解決し長期の時間依存性を学習することができるのが LSTM(Long Short-Term Memory)とよばれる手法である [25]. LSTM は、Fig.2.3 に示すように 3 種類のゲート(入力ゲート、出力ゲート、忘却ゲート)とメモリセルとよばれるセルから成る LSTM ブロックを導入し、以下のような仕組みを並べることで構成されている.

時刻 t における入力を $x(t)$ とし、1 時刻前の隠れ層の出力を $h(t-1)$ 、メモリセルの出力を $c(t-1)$ とすると、時刻 t における入力ゲートの出力 $i(t)$ は

$$i(t) = \sigma(W_i x(t) + U_i h(t-1) + V_i c(t-1) + b_i) \quad (2.6)$$

で表される。ここで、 \mathbf{W}_i は $\mathbf{x}(t)$ の重み、 \mathbf{U}_i は $\mathbf{h}(t-1)$ の重み、 \mathbf{V}_i は $\mathbf{c}(t-1)$ の重みをそれぞれ表す。 \mathbf{b}_i はバイアスを表す。また σ は活性化関数を示し、ここでは ReLU(Rectified Linear Unit)関数を使用する。

時刻 t における出力ゲートの出力 $\mathbf{o}(t)$ は、時刻 t における入力を $\mathbf{x}(t)$ 、メモリセルの出力を $\mathbf{c}(t)$ とし、1時刻前の隠れ層の出力を $\mathbf{h}(t-1)$ とすると、

$$\mathbf{o}(t) = \sigma(\mathbf{W}_o \mathbf{x}(t) + \mathbf{U}_o \mathbf{h}(t-1) + \mathbf{V}_o \mathbf{c}(t) + \mathbf{b}_o) \quad (2.7)$$

と表される。ここで、 \mathbf{W}_o は $\mathbf{x}(t)$ の重み、 \mathbf{U}_o は $\mathbf{h}(t-1)$ の重み、 \mathbf{V}_o は $\mathbf{c}(t)$ の重みをそれぞれ表し、 \mathbf{b}_o はバイアスを示す。 σ は活性化関数を示し、ReLU 関数を使用する。

同様に、時刻 t における忘却ゲートの出力 $\mathbf{f}(t)$ は、時刻 t における入力を $\mathbf{x}(t)$ とし、1時刻前の隠れ層の出力を $\mathbf{h}(t-1)$ 、メモリセルの出力を $\mathbf{c}(t-1)$ とすると、

$$\mathbf{f}(t) = \sigma(\mathbf{W}_f \mathbf{x}(t) + \mathbf{U}_f \mathbf{h}(t-1) + \mathbf{V}_f \mathbf{c}(t-1) + \mathbf{b}_f) \quad (2.8)$$

で表され、 \mathbf{W}_f は $\mathbf{x}(t)$ の重み、 \mathbf{U}_f は $\mathbf{h}(t-1)$ の重み、 \mathbf{V}_f は $\mathbf{c}(t-1)$ の重みをそれぞれ表し、 \mathbf{b}_f はバイアスを示す。また活性化関数 σ は ReLU 関数とする。

また、時刻 t におけるメモリセルの出力 $\mathbf{c}(t)$ は

$$\mathbf{c}(t) = \mathbf{i}(t) \odot \mathbf{a}(t) + \mathbf{f}(t) \odot \mathbf{c}(t-1) \quad (2.9)$$

と表される。ここで、 $\mathbf{a}(t)$ は入力 $\mathbf{x}(t)$ を活性化した値である。なお、 \odot はベクトルの各要素同士を掛け合わせた要素積を表している。また、隠れ層における出力 $\mathbf{h}(t)$ は

$$\mathbf{h}(t) = \mathbf{o}(t) \odot \mathbf{c}'(t) \quad (2.10)$$

と表される。ここで $\mathbf{c}'(t)$ は、メモリセルの出力 $\mathbf{c}(t)$ を tanh 関数で活性化した値である。

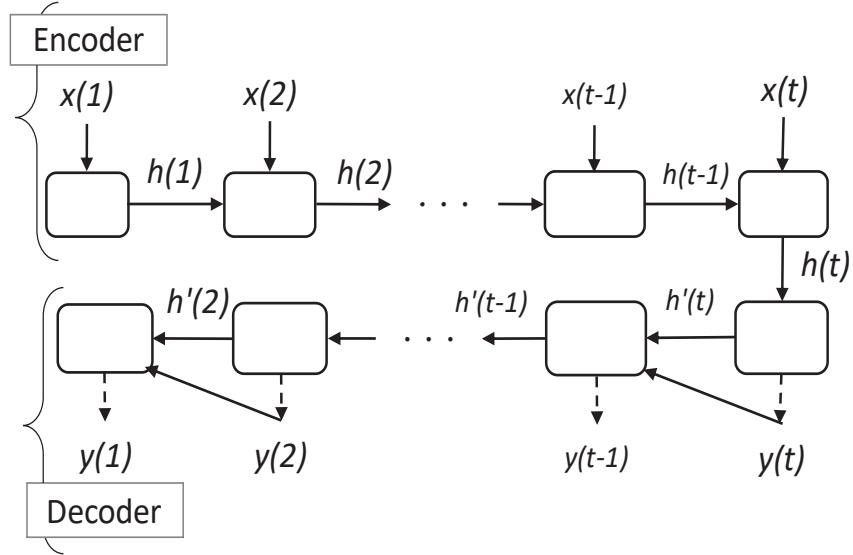


Fig. 2.4: LSTM autoencoder

Fig.2.4 に示すように、LSTM ブロックにより構成されたエンコーダとデコーダの両方を持つオートエンコーダによりモデルを作成する [26]. エンコーダ部の隠れ層の出力は $\mathbf{h}(t)$ と示され、 $\mathbf{h}'(t)$ はデコーダ部の隠れ層の出力を表す. エンコーダ部でデータの特徴ベクトルが計算され、デコーダ部ではエンコーダ部で作成された特徴ベクトルを初期値として元のデータを再構成する. この際、デコーダ部は系列の後ろから予測され、隠れ層の出力 $\mathbf{h}'(t-1)$ を得るために出力 $\mathbf{y}(t)$ と隠れ層の出力 $\mathbf{h}'(t)$ を入力とする. このとき得られた出力 $\mathbf{y}(t-1)$ とエンコーダ部の入力 $\mathbf{x}(t-1)$ が対応関係となる. 作成されたモデルから予測される値と入力データの差を再構成誤差とし、この再構成誤差を異常度として評価することにより、油圧ショベルの故障を予測する. なお、時刻 t における再構成誤差 $r(t)$ は、

$$r(t) = \|\mathbf{x}(t) - \mathbf{y}(t)\|_2 \quad (2.11)$$

で示される. ここで $\mathbf{y}(t)$ は、入力データ $\mathbf{x}(t)$ から予測される時刻 t における出力値を示す.



Fig. 2.5: Hydraulic excavator (SK200-9)

2.2.4 評価方法

油圧ショベルの代表的な動作である掘削作業を対象として、故障予測の評価を行う。掘削作業の繰り返し動作によって、ポンプ圧力や操作レバー信号などのセンサデータを計測し、取得される時系列データをもとに故障予測のモデルを作成し、評価を行う。

掘削作業には一般的に 20t クラスの油圧ショベルが使われることが多いため、Fig.2.5 に示す油圧ショベル(SK200-9 コベルコ建機株式会社製アセラ・ジオスペック)を対象に故障予測を行う。この油圧ショベルには、エンジンやポンプ、アタッチメントとよばれる作業部分を稼働させるシリンダなどが搭載されている。そして、これらを制御するために多数のセンサが取り付けられている。作業現場での掘削作業中における油圧ショベルのポンプ圧力や操作レバー圧力などのセンサ値を 20[Hz] のサンプリング周波数で計測し、取得された時系列データを故障予測モデルの学習、および評価に用いる。

故障評価の対象とする作業は、Fig.2.6 に示すような一般的な油圧ショベルの掘削作業とし、「掘削」、「持ち上げ旋回(90°)」、「排土」、「復帰旋回(90°)」の 4 作業を一つのサイクルとする。

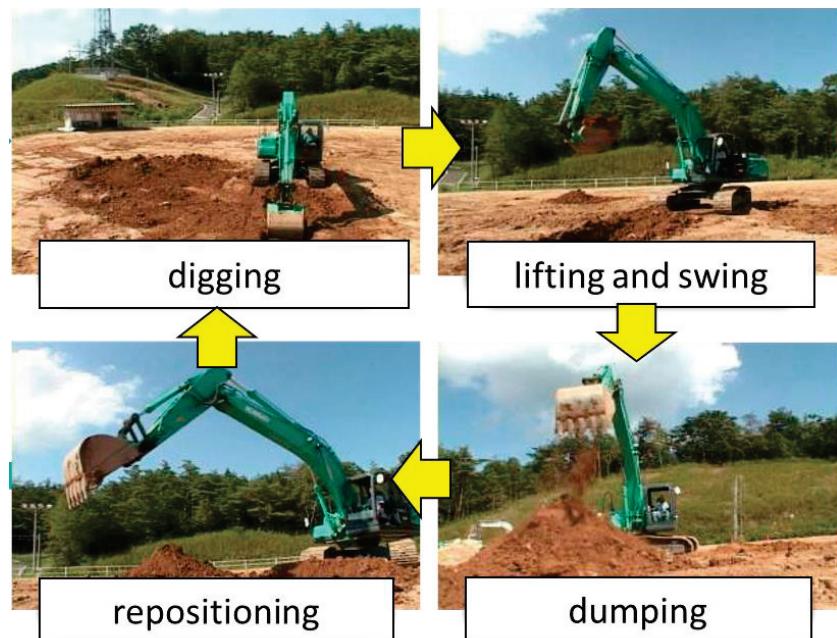


Fig. 2.6: Digging operation

2.2.5 評価結果

Fig.2.7 にポンプ圧力・操作圧力・シリンダ圧力・アクチュエータ速度の計測結果を示す。

各グラフは横軸に計測中の経過時間[秒]をとり、縦軸は正規化した値とした 3 サイクル分の掘削作業を示している。また計測項目については、Table 2.1 に示す番号にそれぞれ対応している。

この 8 サイクルの掘削作業中に計測された 20 変数のデータのうち、前半 7 サイクル分のデータを用いて LSTM オートエンコーダモデルを作成し、残り 1 サイクル分をテスト用データとして評価を行う。

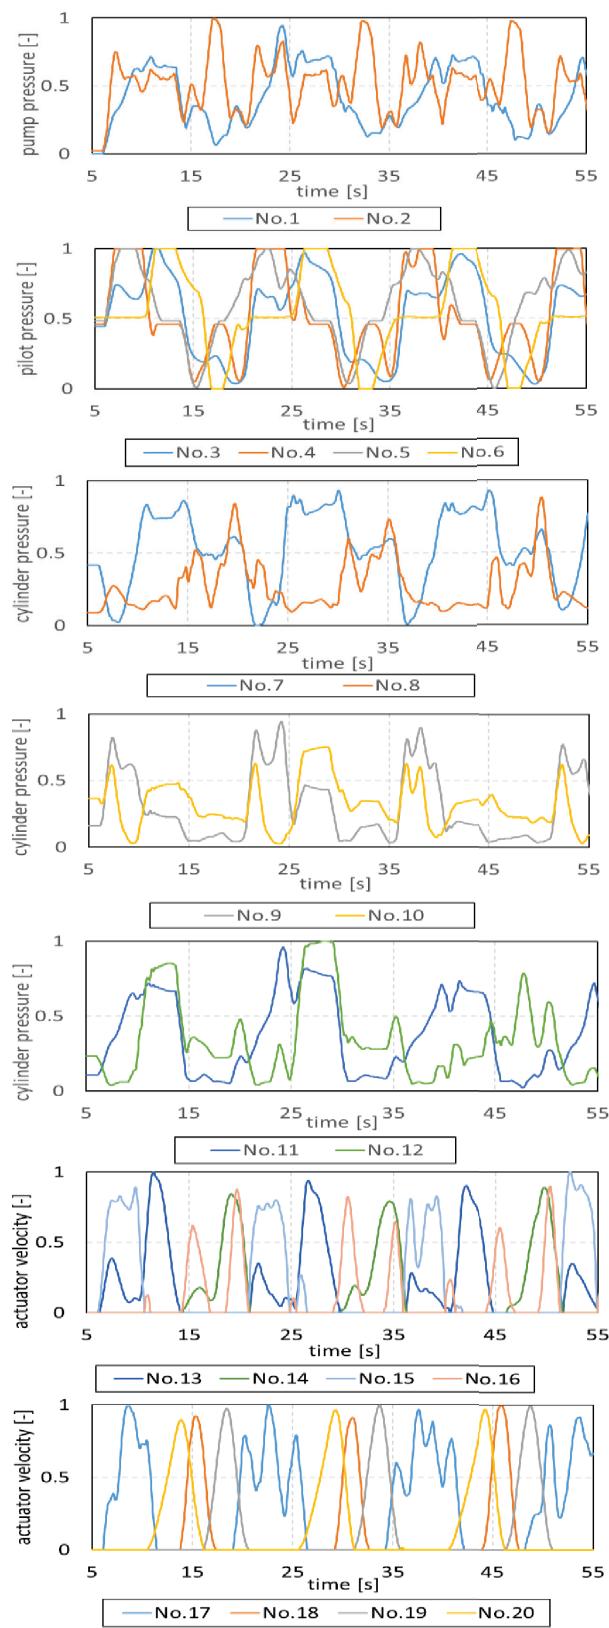


Fig. 2.7: Measurement data

Table 2.1 Measurement items

No.	Items	Units
1	P1 pump pressure	[MPa]
2	P2 pump pressure	[MPa]
3	Boom pilot pressure	[MPa]
4	Arm pilot pressure	[MPa]
5	Bucket pilot pressure	[MPa]
6	Swing pilot pressure	[MPa]
7	Boom cylinder head pressure	[MPa]
8	Boom cylinder rod pressure	[MPa]
9	Arm cylinder head pressure	[MPa]
10	Arm cylinder rod pressure	[MPa]
11	Bucket cylinder head pressure	[MPa]
12	Bucket cylinder rod pressure	[MPa]
13	Boom cylinder head velocity	[mm/s]
14	Boom cylinder rod velocity	[mm/s]
15	Arm cylinder head velocity	[mm/s]
16	Arm cylinder rod velocity	[mm/s]
17	Bucket cylinder head velocity	[mm/s]
18	Bucket cylinder rod velocity	[mm/s]
19	Swing left rotation velocity	[rpm]
20	Swing right rotation velocity	[rpm]

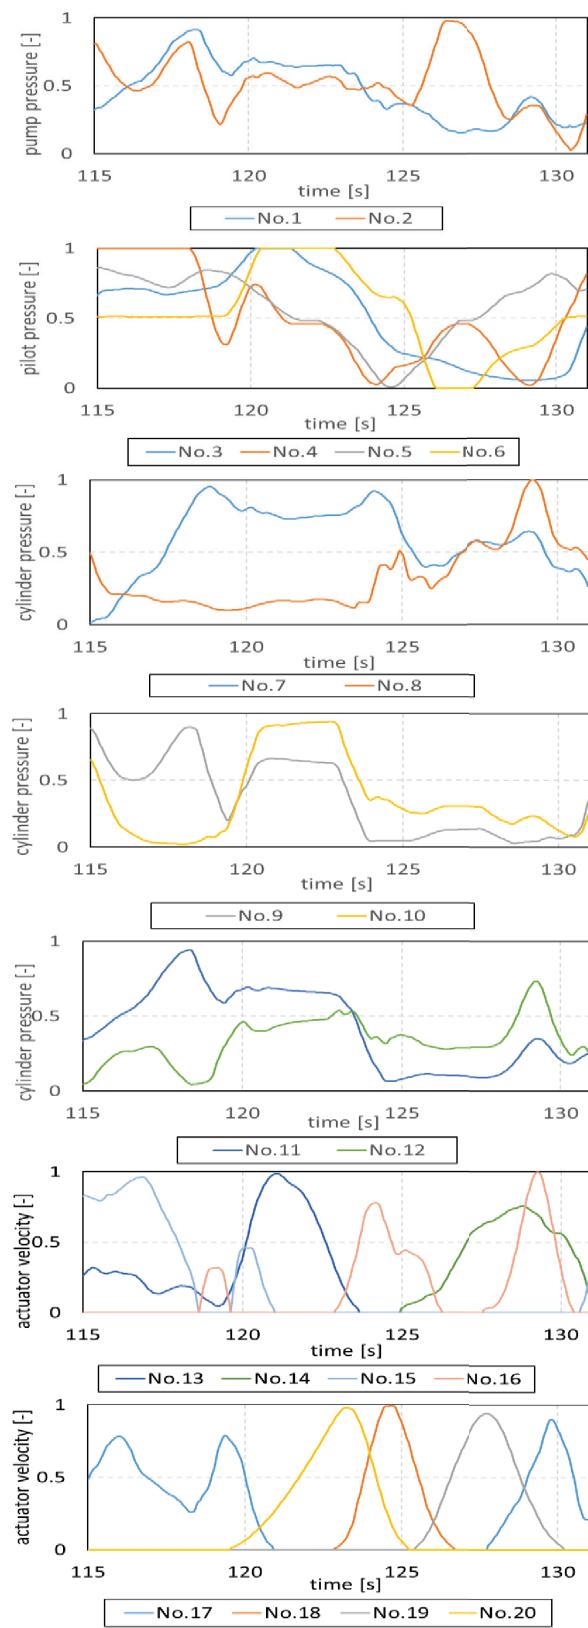


Fig. 2.8: Test data

Fig.2.8 にテスト用データのポンプ圧力・操作圧力・シリンダ圧力・アクチュエータ速度をそれぞれ示す。各グラフは横軸に経過時間[秒]をとり、縦軸は正規化した値を示す。最初の約4秒間は掘削(digging)が行われ、その後に90度の持ち上げ旋回(lifting and swing)動作が続く。開始から約7.5秒からは排土(dumping)操作でバケット内の土が捨てられ、残りの約6秒間で復帰旋回(repositioning)が行われて、初期の姿勢と同等の位置へバケットが戻ってきている。学習データについても同様に掘削作業が繰り返し行われている。

Fig.2.9 は、横軸に経過時間[s]をとり、縦軸を再構成誤差としてモデルを学習させた結果を示す。この経過時間中における再構成誤差の平均値 μ を求めるとき $\mu = 0.27$ となり、再構成誤差が0に近くて小さいと判断できることから、モデルにより入力を復元できていることがわかる。したがって、機械の状態は正常でモデルの学習が正しくできていると判断できる。

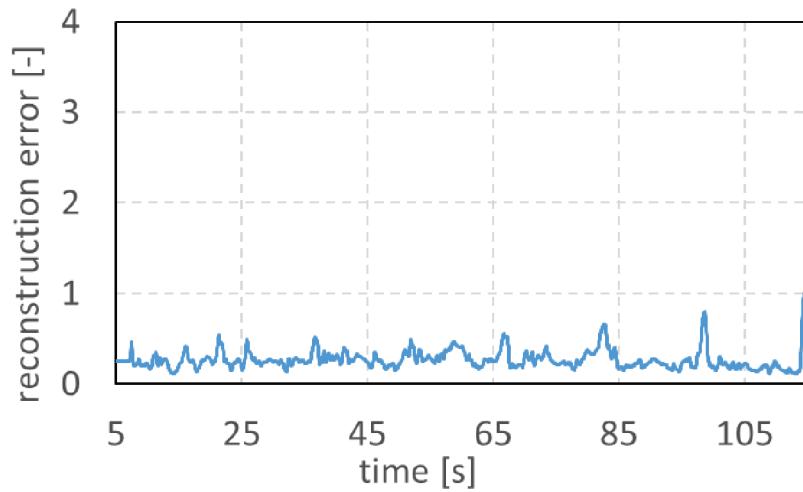


Fig. 2.9: Reconstruction errors (train data)

作成された LSTM オートエンコーダモデルへテスト用データを入力した結果を Fig.2.10 に示す。学習モデルと同様に再構成誤差は小さい値を示しており、テストデータの掘削作業において、正常データの復元ができていることから、LSTM オートエンコーダモデルは妥当であると評価できる。

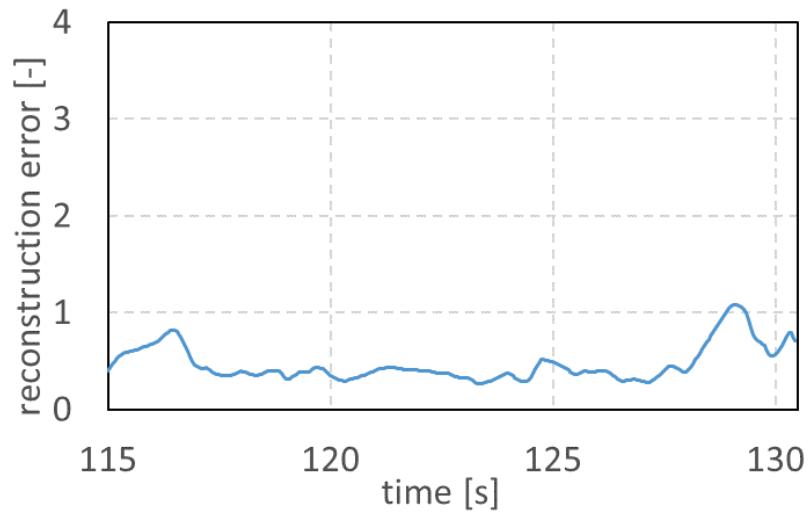


Fig. 2.10: Reconstruction errors (normal test data)

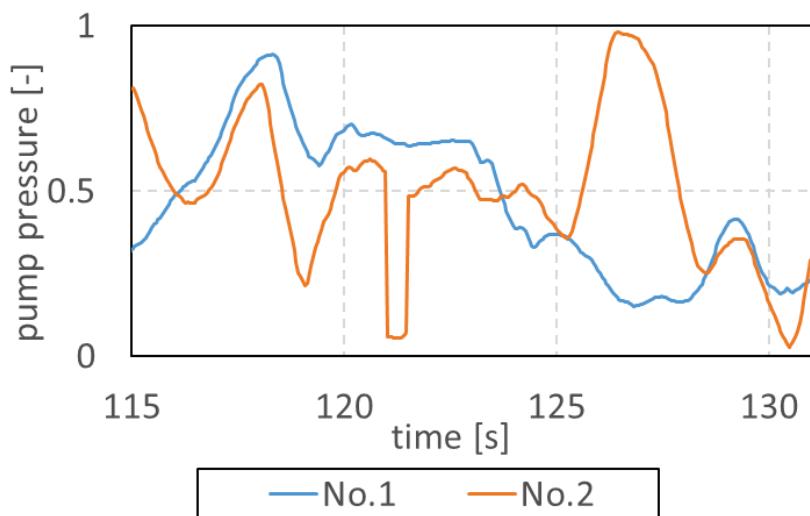


Fig. 2.11: Failure test data (pump pressure value)

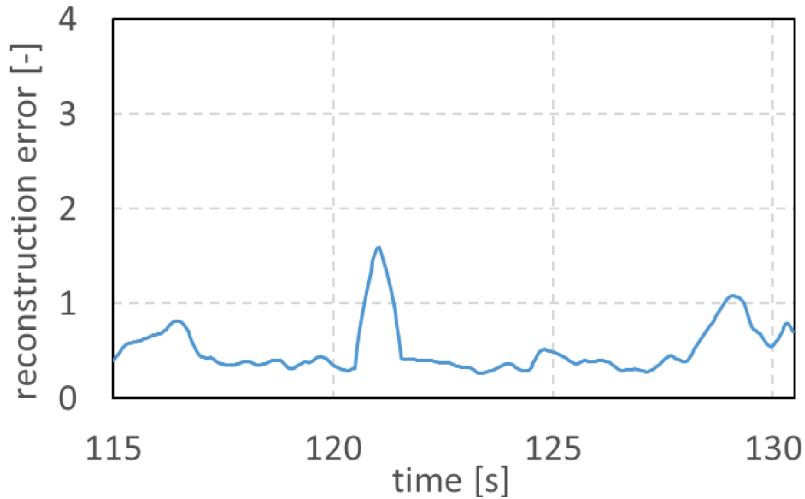


Fig. 2.12: Reconstruction errors (failure test data)

つぎに、異常を含んだ状態のテストデータを用意し評価する。故障データ入手することが困難であるため、模擬的な異常を含んだ状態のデータをテストデータとする。ここではアタッチメント動作で頻繁に使われる P2 ポンプ(No. 2)の故障を想定する。Fig.2.11 に示すように、掘削作業サイクルにおいて約 121 秒付近で P2 ポンプに搭載されている圧力センサの一時的な断線による故障のため P2 ポンプ圧力が一時的に低下する状態を模擬的に生成し、そのテストデータを評価する。なお、P2 ポンプ圧力以外には異常が発生しておらず、Fig.2.8 と同等の値が出力されていると想定する。

Fig.2.12 は Fig.2.11 に示す P2 ポンプの圧力低下異常を想定したテストデータを LSTM オートエンコーダモデルへ入力したときの再構成誤差を示す。このグラフから、P2 ポンプの圧力低下異常を想定したタイミング以外では Fig.2.10 のように再構成誤差の値が小さく、正常な状態であることを示している。また、P2 ポンプの圧力低下異常を想定したタイミングでは、再構成誤差の値が正常な状態とは異なり、非常に高く異常な値を示している。Fig.2.9 では正常な状態におけるテストデータでの再構成誤差を示しており、この区間ににおける再構成誤差の平均値は $\mu = 0.47$ 、標準偏差は $\sigma = 0.18$ である。 $\mu + 3\sigma$ を異常度のしきい値とすると、 $(\mu + 3\sigma) = 1.01$ となり、これを超えると異常の可能性が高いといえる。

Fig.2.12 のグラフから、約 121 秒付近で再構成誤差のピークは $r(t)_{max}=1.59$ 示しており、このときの再構成誤差はしきい値を越えているため、異常と判断できる。したがって、LSTM オートエンコーダモデルにより、想定した模擬的な故障を正しく捉えられているといえる。以上の結果から、掘削作業中における時系列データを使って油圧ショベルの正常な状態を LSTM オートエンコーダによりモデルを作成することで、故障を含むデータを入力すると再構成誤差の値が高く異常な値を示し、故障の予測ができるこことを示した。

2.3 掘削作業の操作特性の比較方法

CAE を用いて油圧ショベル操縦者の技量差異を分析するため、CAE の有効性を実際の油圧ショベル操縦者の作業データを用いて検証する。まず、CAE が線形写像による次元圧縮手法である主成分分析と比べて油圧ショベルの動作切り替え区間での情報を失うことなく再構成できることを確認する。つぎに、熟練操縦者と一般的な技量を有する操縦者の作業データを CAE を用いて再構成し、再構成誤差を計算することで技量差異を評価する。一般操縦者の操作に熟練操縦者に似た操作をしていれば再構成誤差が小さくなることをいくつかの例を挙げて確認する。

2.3.1 評価方法

油圧ショベルの作業データを用いて技量の差異を評価する。油圧ショベルは Fig.2.5 に示す 20t 油圧ショベル(コベルコ建機株式会社製 SK200-9 型)を使用する。油圧ショベルは建設現場において掘削や積込、整地などの役割を担う建設機械である。ブーム、アーム、バケットが連結されたアタッチメント部、上部旋回体、下部走行体から構成され、全て操縦席の左右に設置されているレバーにより操作することができる。対象とする作業は Fig.2.6 の掘削作業である。掘削作業は「掘削」、「持上旋回」、「排土」、「復帰旋回」の 4 つの動作から構成され、アタッチメント部を構成する 3 つの部位と上部旋回体を旋回させるための操作の複合操作によって行われる。特に次の動作へ切り替える区間ではそれら全てを同時に実行わなければならない場合もあり、操縦に慣れていない作業員にとっては高度な技術が要求される。ここで熟練操縦者とは、長年に渡って油圧ショベルの操縦業務に従事しており、新人研修などの操縦指導経験が豊富であるために模範的な操縦を熟知している操縦者である。一方、一般操縦者とは油圧ショベルの運転資格を有し、日常的に操縦するが、他者への指導経験が無く模範的な操縦技術を有していない操縦者である。熟練操縦者 1 名と一般操縦者 1 名に対して動作内容のみを指示し、動作時間は指示せず、複数回作業を行ってもらう。

Table 2.2 Sensor data list

Notation	Sensor
x_1	Boom cylinder H
x_2	Boom cylinder R
x_3	Arm cylinder H
x_4	Arm cylinder R
x_5	Bucket cylinder H
x_6	Bucket cylinder R
x_7	Boom up Pi
x_8	Boom down Pi
x_9	Arm pull Pi
x_10	Arm push Pi
x_11	Bucket dig Pi
x_12	Bucket open Pi
x_13	Boom stroke
x_14	Arm stroke
x_15	Bucket stroke
x_16	Swing angle
x_17	Swing velocity
x_18	Swing right Pi
x_19	Swing left Pi

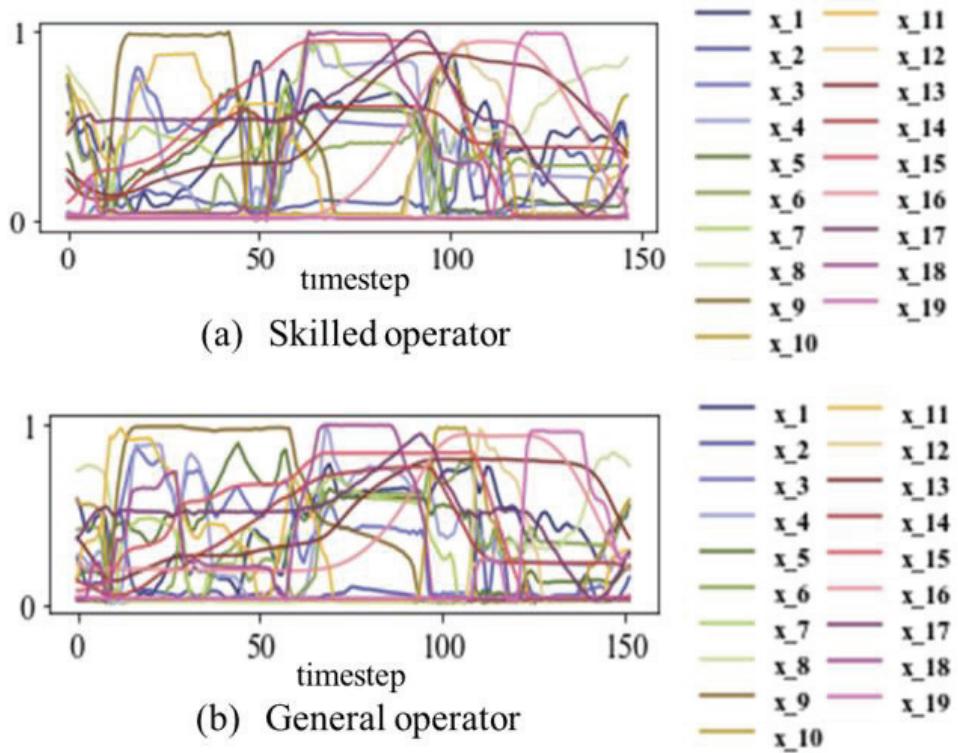


Fig. 2.13: Sensor data of digging motion in a cycle

Table 2.2 に取得した 19 種類のセンサデータを示す。以後図中では各センサを Table 2.2 に対応させて表記する。表中の P_i はパイロット圧、 H は油圧シリンダのヘッド圧、 R はロッド圧を示す。

また、Fig. 2.13 に各操縦者による掘削作業 1 サイクル分のセンサデータを示す。横軸にタイムステップをとり、Table 2.2 の値を示している。なお縦軸は 0 から 1 の値となるように正規化している。センサデータは作動油をシリンダまで送るための各部位のパイロット圧や旋回モータに関するセンサ情報であるが、油圧ショベルに精通している者でなければ熟練操縦者と一般操縦者の技量差異を分析するのは難しい。また、油圧ショベルに精通している者であってもその解析には多くの時間と労力を要する。なお、センサデータのサンプリング周期は 0.1[s]であり、前処理として正規化している。熟練操縦者の作業データのサンプル数は 1692 サンプル、一般操縦者は 1832 サンプルである。ここで 1 サンプルとは 0.1[s]毎のサンプリングによって得られた時系列データ 1 時刻分の各センサの値である。

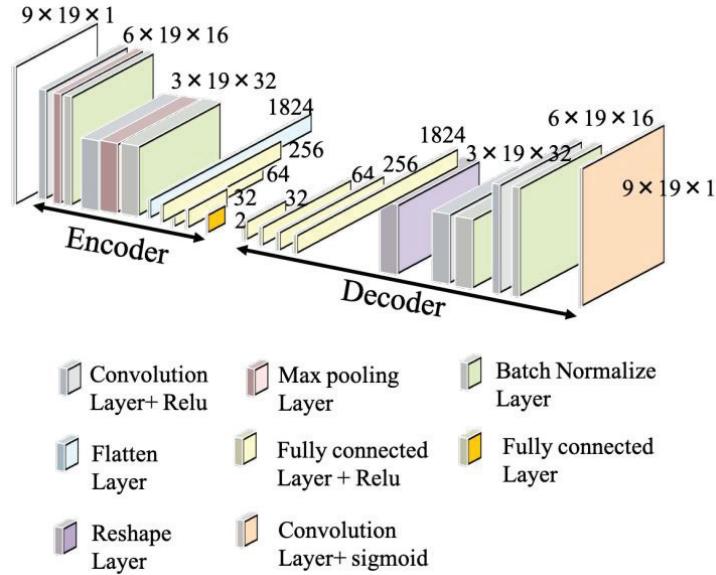


Fig. 2.14: Convolutional autoencoder

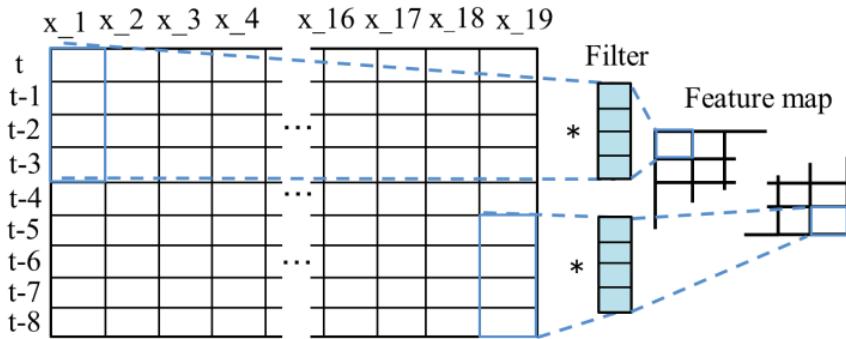


Fig. 2.15: How to extract feature

つぎに CAE のモデル構成図を Fig.2.14 に示す。エンコーダ部は主に 4×1 フィルタの畠み込み層、最大プーリング層、バッチ正規化層、全結合層から構成される。なお、最大プーリング層では適用前に特徴マップ周辺を 0 で埋める 0 パディングによって適用後のデータサイズが変更されないようにしている。デコーダ部は主に 4×1 フィルタの転置畠み込み層とバッチ正規化層から構成される。

特徴抽出方法を Fig.2.15 に示す。CAE の入力データは 19 種類のセンサデータを 9 時刻

分の窓幅で切り出し、さらにその窓を 1 時刻後にスライドさせ、再び 9 時刻分切り出す。これを繰り返すことで作成する。1 つの入力データは $9 \times 19 \times 1$ の 3 次元配列となる。畳み込み層のフィルタサイズは 4×1 、ストライドを 1 として各センサの時間方向の畳み込み演算により特徴マップへの変換を繰り返し行い、入力データの次元を圧縮する。

この CAE に対し、まず熟練操縦者の掘削作業データを学習データとしてモデルを作成する。エポックは 30、バッチサイズは 32 とする。入力と出力の誤差は式(2.9)より計算され、損失が最小となるように CAE の重みを更新する。誤差を最小化するための最適化手法は Adam とし、重みの更新には誤差逆伝播法を用いる [27]。つぎに、作成したモデルに熟練操縦者ほどの技量を有していない一般操縦者の作業データを入力し、同様にセンサごとに再構成誤差を計算する。再構成誤差は平均二乗誤差として計算する。また学習に用いた熟練操縦者の操縦が模範的な操縦であることを想定しており、一般操縦者の再構成誤差が大きいセンサほど熟練操縦者になかった特徴を含んでいることを意味し、油圧ショベルの掘削作業における一般操縦者の技量の差異を示している。

2.3.2 評価結果

まず、時系列データの特徴量によって技量評価を試みる。このとき、非線形写像による次元圧縮によって作業データの情報を損なうことなく特徴量分布を獲得できるかを確認するため、主成分分析による次元圧縮と本手法による次元圧縮を比較する。熟練操縦者が掘削作業を1サイクル行った作業データをそれぞれの手法で2次元に次元圧縮し、再び復元させ、各センサの再構成誤差を求める。

Fig.2.13 に示す掘削作業1サイクルにおける主成分分析での再構成誤差の推移を Fig.2.16 に示す。ここで、縦軸は再構成誤差の大きさを示している。青色、赤色、黄色、紫色の領域がそれぞれ「掘削」、「持上旋回」、「排土」、「復帰旋回」を示す。

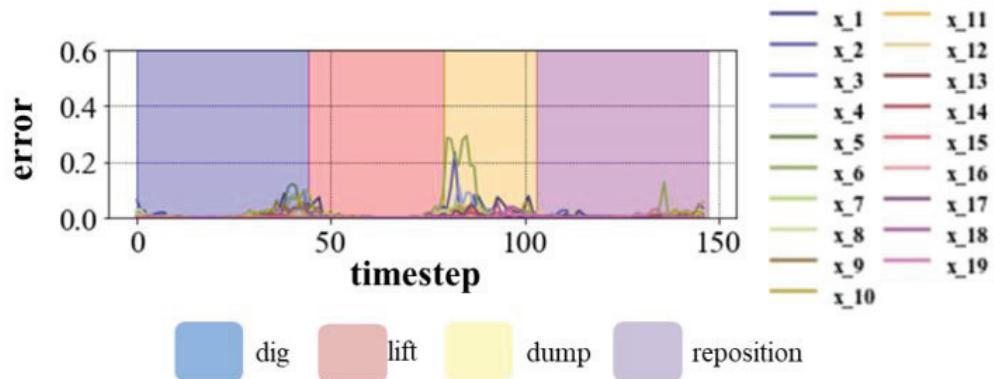


Fig. 2. 16: Reconstruction error of the skilled operator by principle components analysis

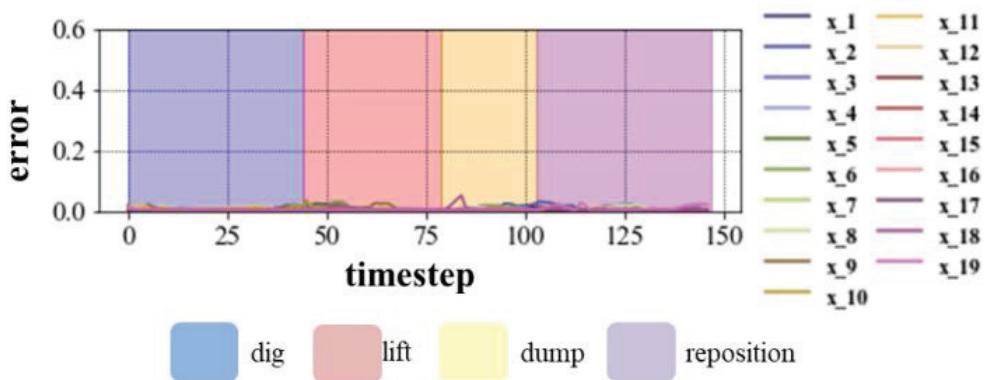


Fig. 2. 17: Reconstruction error of the skilled operator by CAE

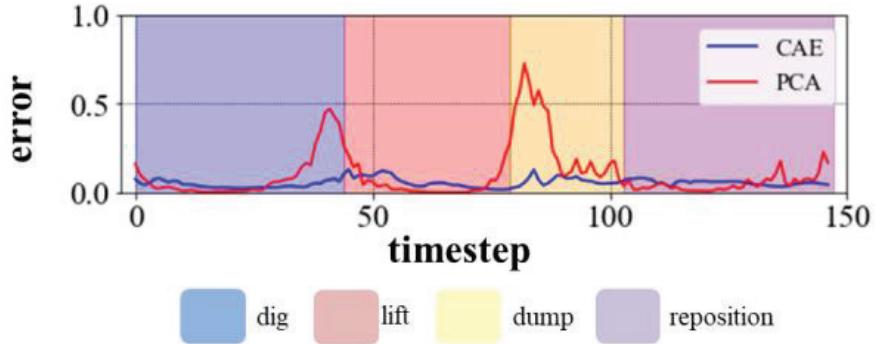


Fig. 2.18: Sum of reconstruction errors at each time

つぎに, Fig.2.13 と同様のサイクルにおける CAE を用いた場合の再構成誤差の推移を Fig.2.17 に示す. また, Fig.2.16 と Fig.2.17 における各時刻の各センサの再構成誤差の和を Fig.2.18 に示す. Fig.2.18 より, 「掘削」から「持上旋回」, 「持上旋回」から「排土」へ動作が切り替わる区間において, 主成分分析による再構成誤差の最大値がそれぞれ 0.47, 0.73 と CAE よりも特に大きい. これは動作が切り替わる区間において, 次元圧縮による情報の損失が大きいことを示す. また, CAE の最大値は 0.13 であり, 全ての区間で再構成誤差が小さいことがわかる. これは非線形写像により次元圧縮できる CAE を用いることで油圧ショベルの作業データの情報を損なうことなく特徴量分布を獲得できているためと考えられる.

つぎに, 熟練操縦者の作業データを学習させた CAE に対し一般操縦者の作業データを入力した時の Fig.2.13 と同様のサイクルにおける再構成誤差の推移を Fig.2.19 に示す. Fig.2.19 のそれぞれの動作において再構成誤差の大きかったセンサを Table 2.3 に示す. Table 2.3 より, 各動作で再構成誤差の大きかったセンサはその動作と関連性のある部位に取り付けられているセンサであることがわかる. いくつかの例を取り上げ, この結果の有効性を示す.

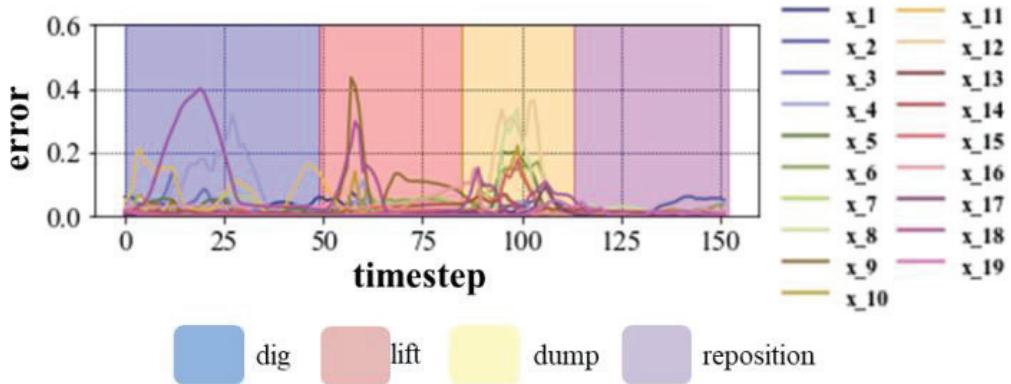


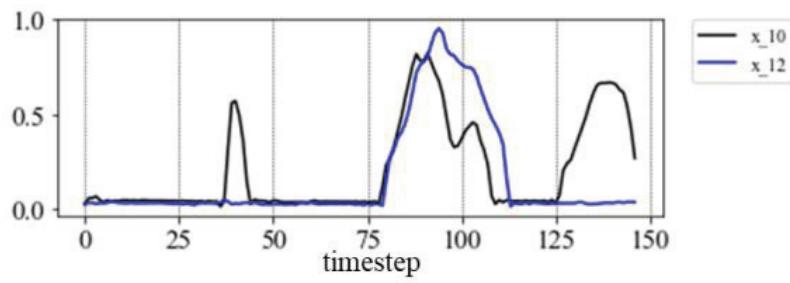
Fig. 2. 19: Reconstruction error of the general operator by CAE

Table 2. 3 Sensors with large reconstruction error

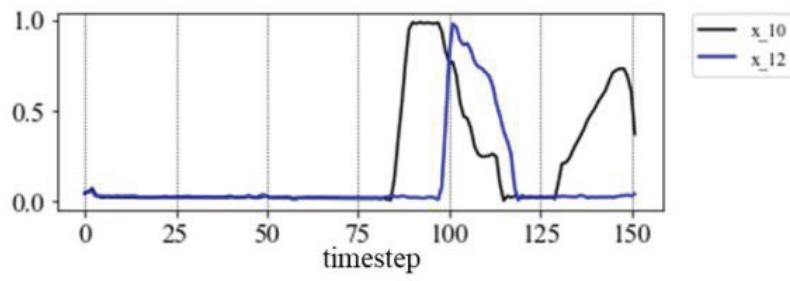
Operation	Sensor (no particular order)
Dig	x_4, x_11, x_18
Lift	x_9, x_18
Dump	x_5, x_6, x_8, x_12
Reposition	x_2

例えば「排土」領域の中央付近で「Bucket open Pi (x_12)」の再構成誤差が 0.36 である。

「排土」はバケットを開くことで掘削した土を捨てる動作であるため「Bucket open Pi (x_12)」と関連がある。あるサイクルの各操縦者の「Bucket open Pi (x_12)」波形を「Arm push Pi (x_10)」と併せて Fig.2.20 に示す。Fig.2.20 より、熟練操縦者では「Bucket open Pi (x_12)」と「Arm push Pi (x_10)」の圧力が同時に上昇しているのに対し、一般操縦者では「Arm push Pi (x_10)」が減少し始める時に「Bucket open Pi (x_12)」が上昇している。これは、熟練操縦者はアームを押し出す動作とバケットを開く動作を同時に行っているのに対し、一般操縦者は交互にこれらの動作を行っていることを示す。レバーを同時に操作することによって滑らかにショベルを操作できるため、この時の再構成誤差は技量の差異を示している。

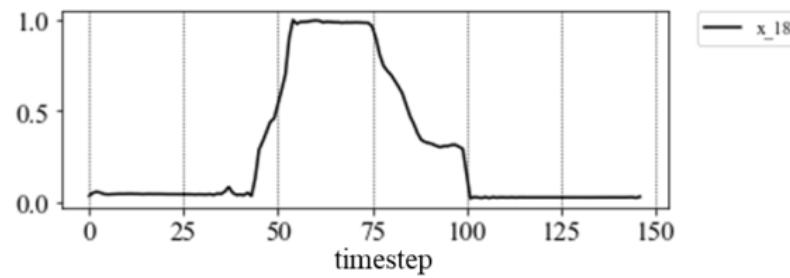


(a) Skilled operator

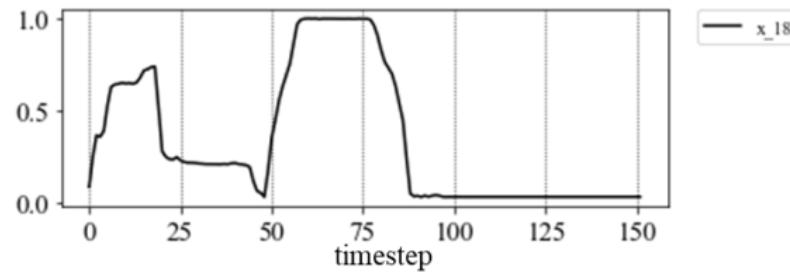


(b) General operator

Fig. 2. 20: Sensor data of Arm push Pi and Bucket open Pi

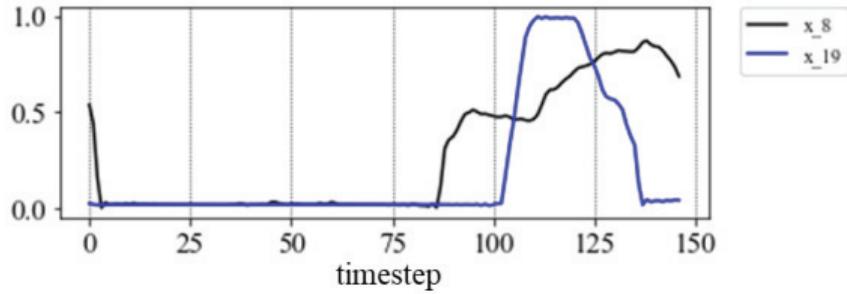


(a) Skilled operator

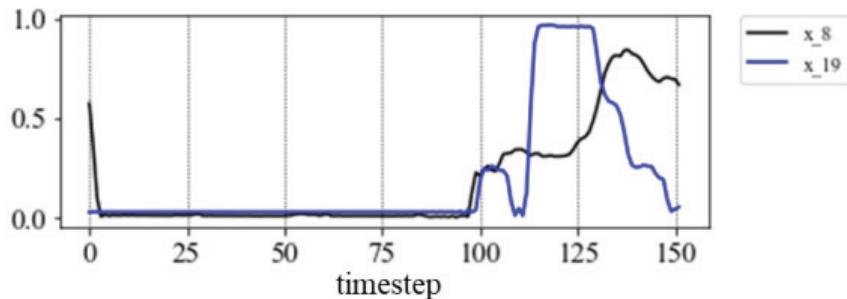


(b) General operator

Fig. 2. 21: Sensor data of Swing right Pi



(a) Skilled operator



(b) General operator

Fig. 2. 22: Main sensor data related to reposition of the skilled operator

「掘削」の領域で「Swing right Pi (x_18)」の再構成誤差が 0.40 である。「掘削」はアームを引き寄せながらバケットを抱え込むことで土を掘る動作であるため、旋回とは関係のない動作である。この時の各操縦者の「Swing right Pi (x_18)」波形を Fig.2.21 に示す。Fig.2.21 より、一般操縦者ではタイムステップ 25 付近の「掘削」領域で「Swing right Pi (x_18)」の圧力が上昇しているのに対し、熟練操縦者は圧力が上昇していない。これは、アームと旋回の操作が同じレバーで行われるために一般操縦者が誤って旋回していると考えられる。これは誤操作であるので、この時の再構成誤差も技量の差異を示すことができている。

また、「復帰旋回」の領域で、「Swing left Pi (x_19)」における技量の差異は見られず、技量差がないことを示すことができている。「復帰旋回」と関連のある各操縦者の「Boom down Pi (x_8)」、「Swing left Pi (x_19)」波形を Fig.2.22 に示す。Fig.2.22 より、「復帰旋回」

ではブームを徐々に下げながら、左へ旋回するようなレバー操作が求められる。一般操縦者の「復帰旋回」操作は熟練操縦者に比べて若干遅いタイミングでタイムステップ 100 から入力されている。しかし熟練操縦者の「復帰旋回」操作は、概ね熟練操縦者と同様のタイミングでレバーを操作できており、顕著な技量差異は見受けられない。これは本手法が各操縦者の特徴を評価しているため、操作タイミングが異なっていても影響を受けないことを示している。

2.3.3 考察

2.2 節で LSTM オートエンコーダによる故障予測方法を示した。しかし、油圧ショベル操縦者の操作の影響により、故障予測の誤検知が発生することがある。LSTM オートエンコーダによる故障予測モデルを学習させるときに使った操縦者のデータとは別の操縦者のデータを評価するときに特に誤検知が発生し、機械が正常な状態であっても故障と判定される可能性がある。この誤検知の発生を抑制するために、本節で示した CAE による操作特性の比較を行い、Fig.2.23 に示すようなフローチャートで演算を行うことで、誤検知を回避できると考えられる。

まず油圧ショベルのポンプ圧力やレバー信号などのセンサデータ（操作量や動作情報など）を取得し、その後に実操作特性と実動作特性を演算する。この際、実操作特性の演算は、2.3 節で示した CAE を用いた操作特性による演算で算出し、実動作特性の演算は、2.2 節で示した LSTM オートエンコーダを用いた故障予測による演算で求める。演算された実操作特性が、基準操作特性に一致する場合、すなわち油圧ショベル操縦者の操作特性が近い場合に、次の処理に進む。このとき基準操作特性は、事前に得られた操縦者の作業データによってあらかじめ学習させておく。また、実操作特性が基準操作特性と異なる場合には、以降の処理を行わないこととする。このように操縦者の操作の特徴を事前に判定することで、故障予測の誤判定を抑制できる。また実動作特性の処理において、あらかじめ学習された基準動作特性と一致しない場合は、正常な状態ではないことを示しており、判定を故障と予測する。以上のように、CAE を用いた操作特性の比較を行った後に、LSTM オートエンコーダを用いた故障予測を行うことで油圧ショベル操縦者の操作の影響による誤判定を抑制することができるといえる。

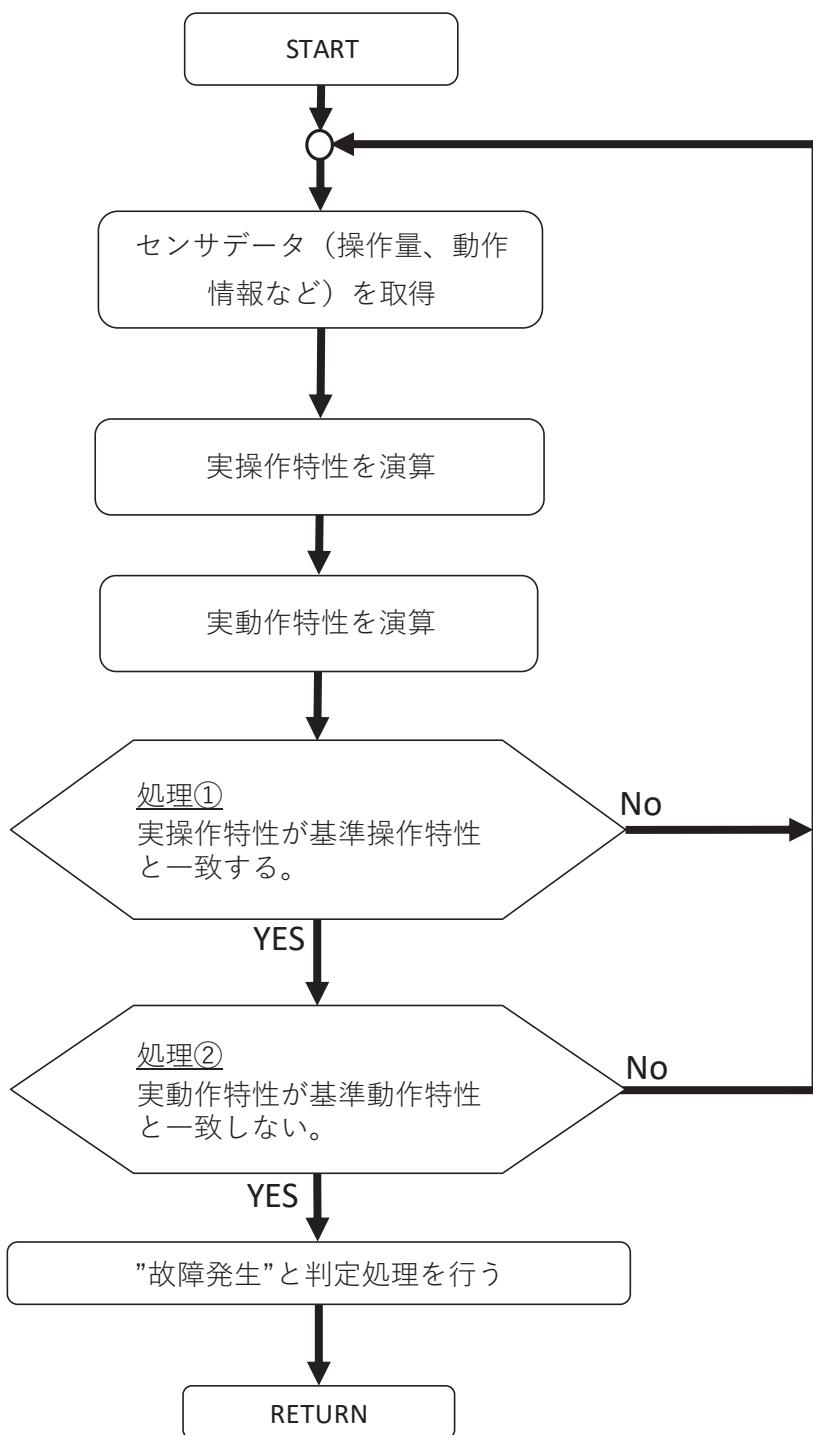


Fig. 2. 23: Failure prediction flow chart

2.4 結言

本章では、油圧ショベルの故障事象に対して稼働中の時系列データを用いることによつて、故障を予測する方法を提案した。教師なし学習のひとつである LSTM オートエンコーダを用いて、正常な状態のデータによりモデルを学習することで異常を含んだ状態のデータでは再構成誤差が大きい値を示し、故障の予測ができることを示した。

また本章では CAE を用いた油圧ショベルの掘削作業における技量差異分析手法を提案した。まず、線形写像での次元圧縮手法の 1 つである主成分分析と非線形写像が可能である CAE を用いて、熟練操縦者の作業データを再構成した時の再構成誤差の結果を比較した。その結果、CAE では作業データの情報を損なうことなく特徴量分布を獲得できることを確認した。そして、一般操縦者の作業データを CAE を用いて再構成し、再構成誤差を求めた。いくつかの例から、一般操縦者の操作の特徴が熟練操縦者と異なる場合には CAE では復元できていないことがわかった。一方、一般操縦者が熟練操縦者の操作の特徴に近い操作をしている場合には再構成誤差は小さかった。以上の結果より本手法の有効性を示した。

第3章 掘削作業の動作分類と 特定動作における故障予測

本章では、まず、LSTM を用いることにより油圧ショベルの掘削作業動作を分類する。技量の異なる操縦者の各動作を予測確率により示し、その特徴を比較する。つぎに、重回帰式によりシリンダなどのアクチュエータの流量からポンプ流量を予測するモデルを作成する。油圧ショベルの掘削作業における時系列データから「掘削」、「持上旋回」、「排土」、「復帰」、「待機」の各動作を LSTM により分類可能であることから、特定状態の動作として「持上旋回」動作の作業データに絞り込みモデルを作成する。さらに、作成した予測モデルをもとに故障を想定した作業データにおいて故障を捉えられることを示し、その提案方法の有効性を検証する。

3.1 緒言

近年、建設業界では、熟練労働者の減少に伴い、生産性の向上が求められている [1][2]。国土交通省では「i-Construction」を推進しており [5]、建設現場での生産性や安全性を向上させるために情報通信技術（ICT）を活用している [3][4]。油圧ショベルは、土の掘削や積み込み作業をするために欠かせない建設機械である。油圧ショベルの操縦には高度な技術を必要とし、一般的には熟練した操縦者の方が生産性は高いと言われている。つまり、建設現場の生産性は、油圧ショベルの操縦者のスキルに左右されると言っても過言ではない。操縦者のスキルの定量的な特徴を評価することで、建設現場の生産性をより深く理解し、その向上に役立てることができる。

これまでの先行研究では、深層学習を用いて油圧ショベルの動作を分類しているが、その

評価は 1 人の操縦者のデータのみに基づいており、異なる操縦者の比較には至っていない [28][29]。異なる操縦者を比較するために、ランダムフォレストを用いた動作分類が提案されているが、深層学習など他の手法との比較は行われていない [15][30]。また、旋回の操作スキルを評価するシステムを構築し、異なる操縦者のスキルを比較する研究が行われているが、特定の動作のみを評価している [31]。医療分野では、機械学習を用いた手術スキルの評価が、初心者や手術ロボットの訓練に利用されている [32]。

本章では、複数のセンサから得られたデータに基づいて、油圧ショベルの動作を分類するモデルを作成する。異なる操縦者による油圧ショベルの時系列データを利用して、掘削動作を分類し、動作の特徴を比較する。時系列の時間依存性を考慮するために、リカレントニューラルネットワークを用いる。しかし、リカレントニューラルネットワークは、パラメータの勾配が消失してしまうため、十分な学習ができないことが多い [24]。そこで、長期的な時間依存性を学習できると言われていることから、深層学習の一つである LSTM (Long Short-Term Memory) を採用する [25]。

油圧ショベルの一般的な掘削動作には、Fig.3.1 に示すような「掘削(digging)」、「持上旋回(lifting and swing)」、「排土(dumping)」、「復帰(repositioning)」の動作があり、これらの動作に加えて何も操作しない状態である「待機(idle)」がある。これらの 5 種類の動作を対象に分類を行う。また、操作スキルの異なる操縦者は、「熟練操縦者」、「一般操縦者」、「非熟練操縦者」に分類され、予測されたクラスの特徴と各動作の予測確率の比較を行う。

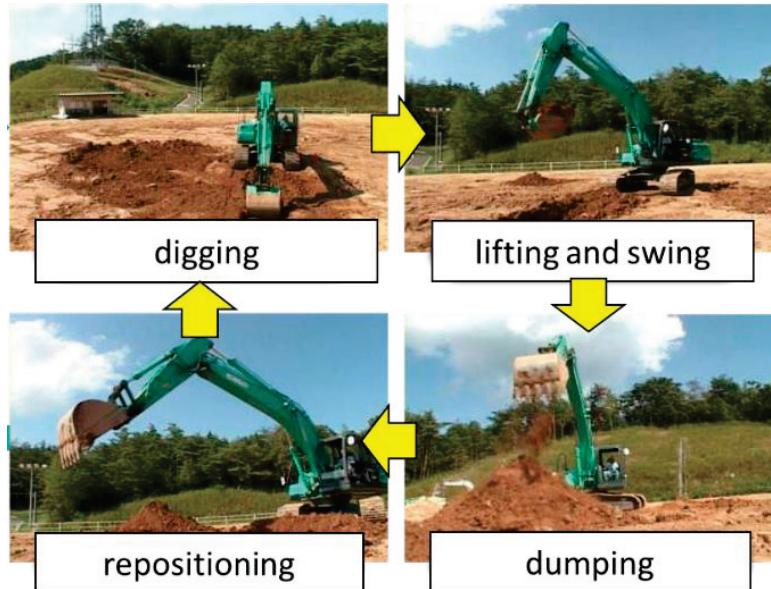


Fig. 3.1: Digging operation

また、油圧ショベルは操作レバーにより機体動作をコントロールしていることから操縦者の操作技量の差異による影響で故障予測の結果に誤った判定を与える可能性がある。そのため、機械特性の変化に着目した故障予測モデルが必要である。油圧ショベルは、重要部品である油圧ポンプが故障するとアタッチメントや走行モータなどを稼働させることができなくなるため、その故障は避けられるべきである。ポンプの吐出流量とアクチュエータ流量の関係性により、予測モデルを作成することを考え、解釈性や説明性を考慮して比較的シンプルな重回帰式によりモデルを作成する。

しかし、油圧ショベル特有のシステムにより、操作によってはポンプ流量を予測するモデルが複雑となり、故障予測による誤検知のリスクがかえって増えることが懸念される。そこで掘削作業の動作分類を用いることで特定状態における動作に着目した故障予測モデルとすることを提案する。

本章では、20t クラスの油圧ショベルの時系列データを使用し、油圧ショベルの一般的な掘削作業動作(「掘削」、「持上旋回」、「排土」、「復帰」、「待機」)を分類できるモデルを作成

する。操作技量が異なる操縦者(「熟練操縦者」, 「一般操縦者」, 「非熟練操縦者」)の作業データを評価し, 予測されたクラス分類の特徴と各動作の予測確率を比較する。またポンプの故障を「持ち上げ旋回」動作の作業データから予測モデルを作成する。

その結果, LSTM モデルを用いて各操縦者の作業データの動作を分類すると, 熟練操縦者と一般操縦者は高い精度で分類できることが示されている。しかし非熟練操縦者の作業データは他の操縦者と比較して分類精度が低く, 非周期的な動作をしている特徴を示している。各動作の予測確率については, 熟練操縦者と一般操縦者は各動作において高い予測確率を示しており, 誤判定も少なく特徴の差が見られない。非熟練操縦者の場合, つぎの動作に移るときや動作中に「待機」状態の予測確率が高いことを示している。また「持ち上げ旋回」動作の作業データから重回帰式によりポンプ流量を予測するモデルを作成すると, 誤検知を抑制してポンプの故障を予測できることを示している。

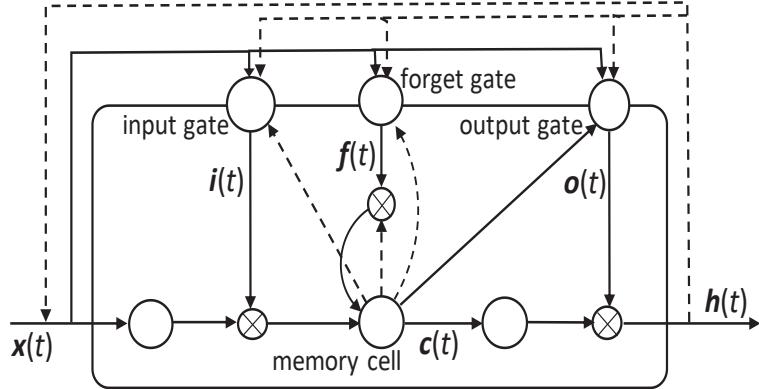


Fig. 3.2: LSTM block

3.2 油圧ショベルの掘削作業の動作分類

3.2.1 LSTM による動作分類方法

Fig.3.2 は、3 種類のゲート（入力ゲート、出力ゲート、忘却ゲート）とメモリセルと呼ばれるセルからなる LSTM (Long Short-Term Memory) ブロックを導入したものである。時刻 t における入力ゲートの出力 $i(t)$ 、出力ゲートの出力 $o(t)$ 、忘却ゲートの出力 $f(t)$ 、およびメモリセルの出力 $c(t)$ は、第 2 章の式(2.6), (2.7), (2.8), および(2.9)により、それぞれ示される。

この LSTM ブロックを Fig.3.3 に示すような構造に配置することで、時系列データが逐次的に入力され、過去に入力したデータから抽出された情報を保持しておくことが可能になる。このとき時刻 t における出力は、その入力と過去の情報に基づいて決定される。

つぎにクラス数を n とすると、出力層は n 個の値を出力する全結合層で構成される。またソフトマックス関数で変換すると、これらの値の合計は 1 になり、時刻 t における隠れ層の出力 $h_k(t)$ の変換式は、式(3.6)で表される。

$$y_k(t) = \frac{\exp(h_k(t))}{\sum_{i=1}^n \exp(h_i(t))} \quad (k = 1, 2, \dots, n) \quad (3.6)$$

この変換された値を予測確率とし、最も高い出力に対応するラベルを分類ラベルとする。

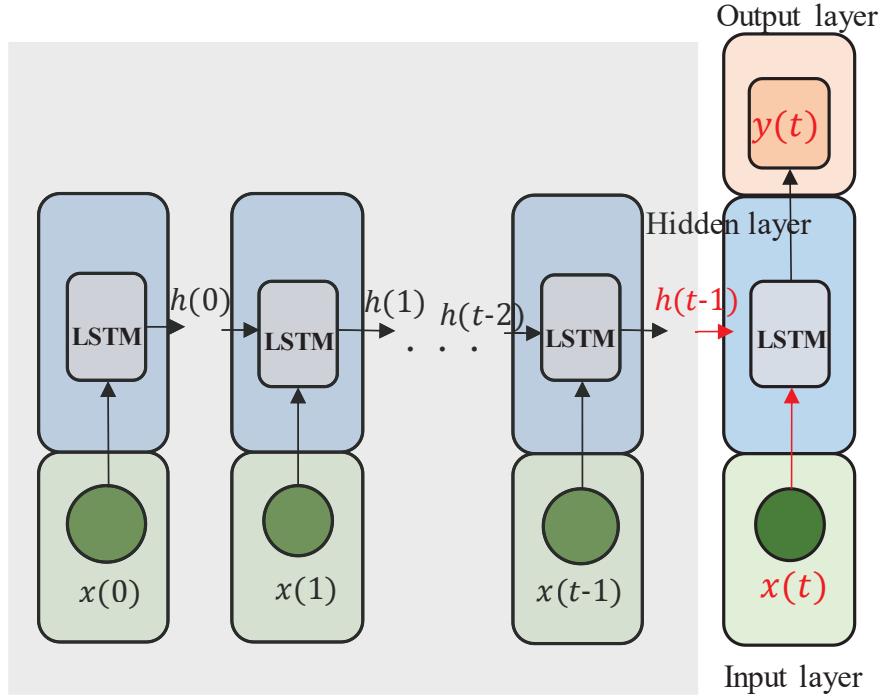


Fig. 3.3: LSTM structure

3.2.2 評価方法

第2章のFig.2.5に示す20tクラスの油圧ショベル（コベルコ建機株式会社製SK200-9）の掘削作業データを使用する。掘削作業は、「掘削」、「持上旋回」、「排土」、「復帰」の4つの作業を1つのサイクルとして構成されており、分類クラスは何も操作を行わない「待機」状態を含めて5つのクラスに分類する。掘削作業データは、それぞれの操作スキルが「熟練操縦者」、「一般操縦者」、「非熟練操縦者」に分類される操縦者の時系列データを使用する。時系列データは、0.1[s]ごとにサンプリングされたTable 3.1に示す33種類のセンサデータで構成されている。これらのセンサデータには、ポンプ圧力や操作パilot圧力などが含まれる。

Table 3.1 Sensor data list

No.	Sensor	No.	Sensor
1	P1 pump pressure	18	Swing pilot pressure
2	P2 pump pressure	19	Swing angle
3	Boom cylinder head pressure	20	Engine rotation
4	Boom cylinder rod pressure	21	Vibration (cab)
5	Arm cylinder head pressure	22	Vibration (weight)
6	Arm cylinder rod pressure	23	Vibration (attachment)
7	Bucket cylinder head pressure	24	P1 electric current
8	Bucket cylinder rod pressure	25	P2 electric current
9	Boom up pilot pressure	26	P1 displacement volume
10	Boom down pilot pressure	27	P2 displacement volume
11	Arm pull pilot pressure	28	Boom cylinder velocity
12	Arm push pilot pressure	29	Arm cylinder velocity
13	Bucket dig pilot pressure	30	Bucket cylinder velocity
14	Bucket open pilot pressure	31	Swing rotation velocity
15	Boom cylinder stroke	32	Swing right pilot pressure
16	Arm cylinder stroke	33	Swing left pilot pressure
17	Bucket cylinder stroke	-	-

熟練操縦者の掘削作業を基準としているため、熟練操縦者の時系列データには作業分類のラベルが貼られている。熟練操縦者のデータの後半 500 サンプルをテストデータ、残りのデータを学習データとして分類モデルを作成する。同様に、一般操縦者と非熟練操縦者のデータの最後の 500 サンプルをテストデータとして抽出し、熟練操縦者のデータで学習したモデルにより、一般操縦者と非熟練操縦者の掘削作業データを分類する。掘削作業データの概要を Table 3.2 に示す。

学習時には、学習データを複数のバッチに分割し、各バッチをモデルに入力する。モデルは、その時点での予測値と実データの間の損失を最小化するように学習される。学習データがすべて入力された時点を 1 エポックとし、30 エポックの間、このモデルの学習を繰り返す。各エポックにおいて、学習データから 30% のデータをランダムに抽出し、これらのデータを検証データとして使用する。学習結果を Fig.3.4 に示す。

Table 3.3 は、30 エポックのときにおける正解率と損失を示したものである。Fig.3.4 に示すように、学習を繰り返すごとに損失が減少しており、また正解率も上昇していることがわかる。Table 3.3 は、30 エポックでの損失が十分に小さく、モデルが高い精度で検証データを分類できることを示している。したがって、このモデルは、未知のデータに対しても高い汎化性能を有しているといえる。

Table 3.2 Overview of operation data

	Sampling time [sec]	Sample	Class
Skilled operator	0.1	1,692	5
General operator	0.1	500	5
Unskilled operator	0.1	500	5

Table 3.3 Accuracy [%] and loss in training data (epoch = 30)

	Accuracy	Loss
Training data	95.9	0.1019
Validation data	96.6	0.0882

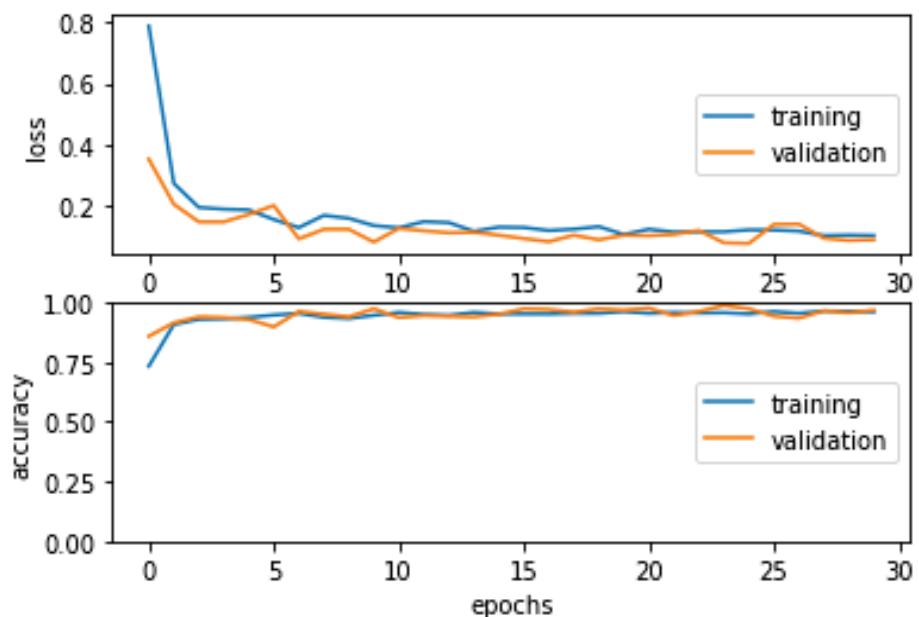


Fig. 3.4: Training results

3.2.3 評価結果

Fig.3.5 に学習したモデルを用いてテストデータに対する各操縦者の掘削作業動作を分類した結果を示す。Fig.3.5 のグラフは、横軸にタイムステップをとり、各タイムステップで予測された分類クラス（「掘削」、「持上旋回」、「排土」、「復帰」、「待機」）を示し、上から「熟練操縦者」、「一般操縦者」、「非熟練操縦者」の各操縦者のグラフである。これらのグラフから、熟練操縦者と一般操縦者の作業データの分類は、それぞれの掘削作業動作に対し正確に行われていることが示される。また、掘削作業動作が周期的に行われていることも、これらのグラフからわかる。

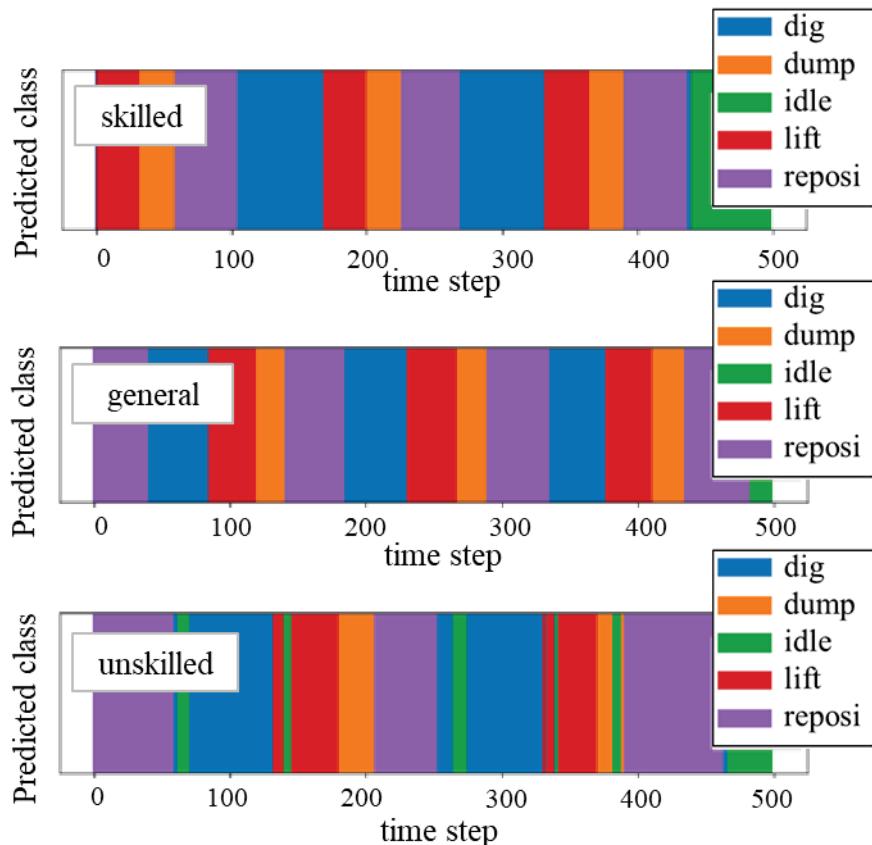


Fig. 3.5: Predicted class

その一方で、非熟練操縦者の作業データに対する掘削作業動作の分類は、正確に行われていないことが示されている。非熟練操縦者の予測分類クラスは、他の操縦者のように周期的にならず、掘削作業が各動作において等間隔に分類されず、非周期的になる傾向を示している。また非熟練操縦者の結果は、掘削作業動作中に「待機」状態として分類される特徴が見られた。「待機」は何も操作をしていない状態であるが、掘削作業中の動作にも関わらず、非熟練操縦者の作業データには「待機」に分類される動作が含まれている。

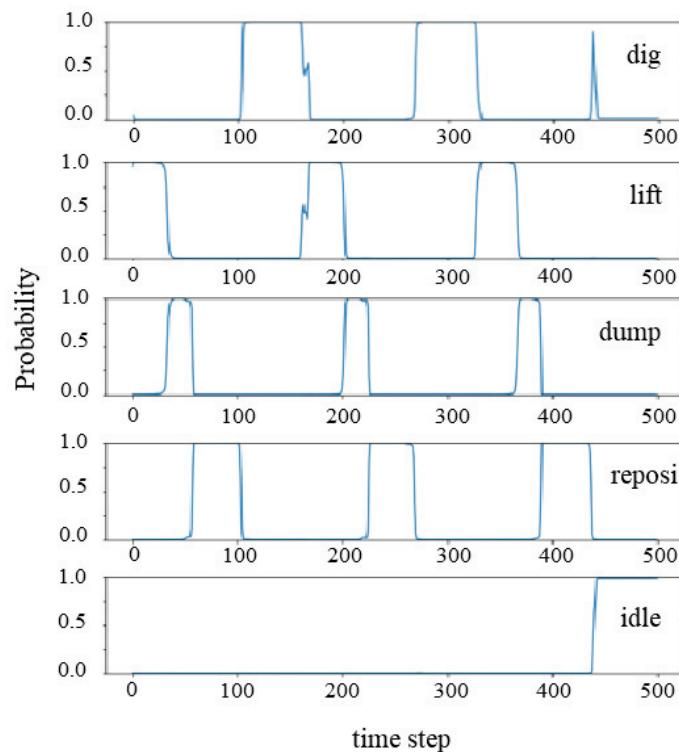


Fig. 3.6: Predicted probability (skilled operator)

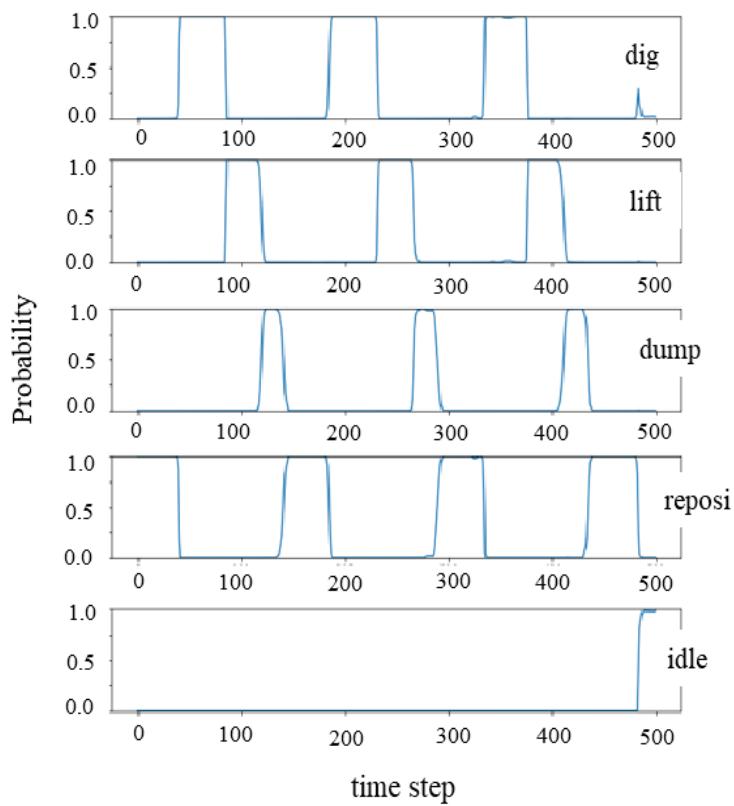


Fig. 3.7: Predicted probability (general operator)

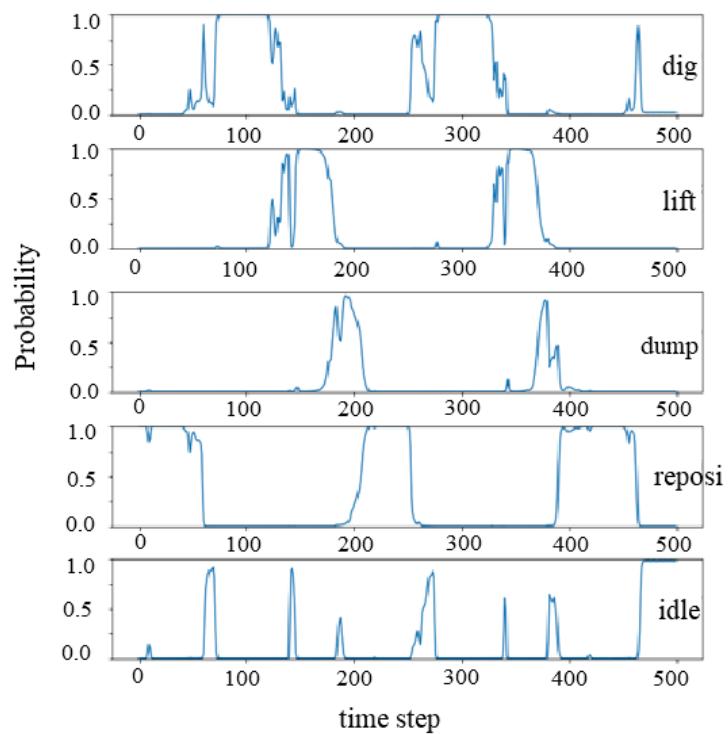


Fig. 3.8: Predicted probability (unskilled operator)

Figs.3.6-3.8 に示すグラフは、各操縦者の 5 つの動作に対する予測確率を比較したものであります。横軸をタイムステップとし、縦軸は各動作(「掘削」、「持上旋回」、「排土」、「復帰」、「待機」)における予測確率の値をそれぞれ示している。Fig.3.6 は熟練操縦者の各動作に対する予測確率を示す。これらのグラフから熟練操縦者の各動作に対する予測確率は高い値を示しており、また誤判定の数も少ないことがわかる。Fig.3.7 に示すグラフは、一般操縦者の各動作における予測確率である。熟練操縦者と同様に、掘削作業の各動作において高い予測確率を示しており、また正確に各動作を分類されていることがわかる。このことから、熟練操縦者と一般操縦者の掘削作業動作は、近い特徴を持っていることがいえる。

非熟練操縦者の各動作に対する予測確率を Fig.3.8 に示す。Fig.3.8 に示すように、非熟練操縦者の予測確率は他の操縦者とは異なる傾向を示している。特に、動作が次の動作へ切り換わるときに「待機」状態の予測確率が高い。例えば、Fig.3.8 に示すグラフの 250 タイムステップ付近において「復帰」から「掘削」に遷移するとき、「待機」状態の予測確率が高くなっていることが確認されている。また、150 タイムステップ付近の「持上旋回」動作中のときにも、「待機」状態の予測確率が高くなることが見られる。「待機」状態は操作をしていない状態であるが、非熟練操縦者の予測確率は掘削作業の動作途中にも、無操作の特徴が示されている。熟練操縦者や一般操縦者には見られなかつたため、これらの特徴は非熟練操縦者の特有の特徴といえる。これらの結果は、非熟練操縦者の不安定な操作や低い操縦スキルによる影響と考えられる。

3.3 特定動作に着目した故障予測

オートエンコーダを用いた掘削作業における故障予測方法では、機体動作時の操作影響により誤検知の可能性があることがわかつており、第2章では、それを抑制するために操縦者の操作特性を評価することにより誤検知を防止する方法を提案した。ここでは、特定の動作に着目した故障予測のモデルを用いた判定方法を提案し、評価を行う。そのためには機械特性の変化に着目した故障予測モデルが必要であるが、油圧ショベル特有のシステムのため、動作によっては予測するモデルが複雑となり、故障予測による誤検知のリスクがかえって増えることが懸念される。そこで3.2節で示したLSTMによる掘削作業の動作分類を用いて、特定動作に着目した故障予測モデルとすることを提案する。

3.3.1 動作分類を利用した故障予測方法

油圧ショベルは、ポンプの吐出油を各アクチュエータへ圧送することでブーム/アーム/バケットのアタッチメントを作動させ、また上部旋回体を作動させることができる。Fig.3.9にアタッチメントのアクチュエータである油圧シリンダを作動させるための油圧回路図を示す。駆動源であるエンジン(Engine)の回転エネルギーをポンプ軸に伝えることで、ポンプ(Hydraulic pump)は作動油を吐出する。パイロットレバー(Lever)の操作によりパイロット圧をコントロールバルブ(Control valve)に与えることでバルブ内の流路が導通し、ポンプから吐出された作動油をシリンダ(Hydraulic cylinder)へ圧送することができる。シリンダへ作動油が送られることでシリンダは伸縮いずれかの動作ができる。Fig.3.9はシリンダが伸び側に動く。またシリンダに押し出された作動油は、再びバルブを通ってタンク(Tank)へ戻される。このような作動油の流れをすることから、アクチュエータへの流入流量からポンプの吐出流量を予測することでポンプの故障を捉える。もし仮に、ポンプの指示流量に対し、予測した流量が乖離しているならば実際に吐出しているポンプ流量が指示流量と合っていない可能性があり、ポンプが故障している可能性が高いと予測できる。

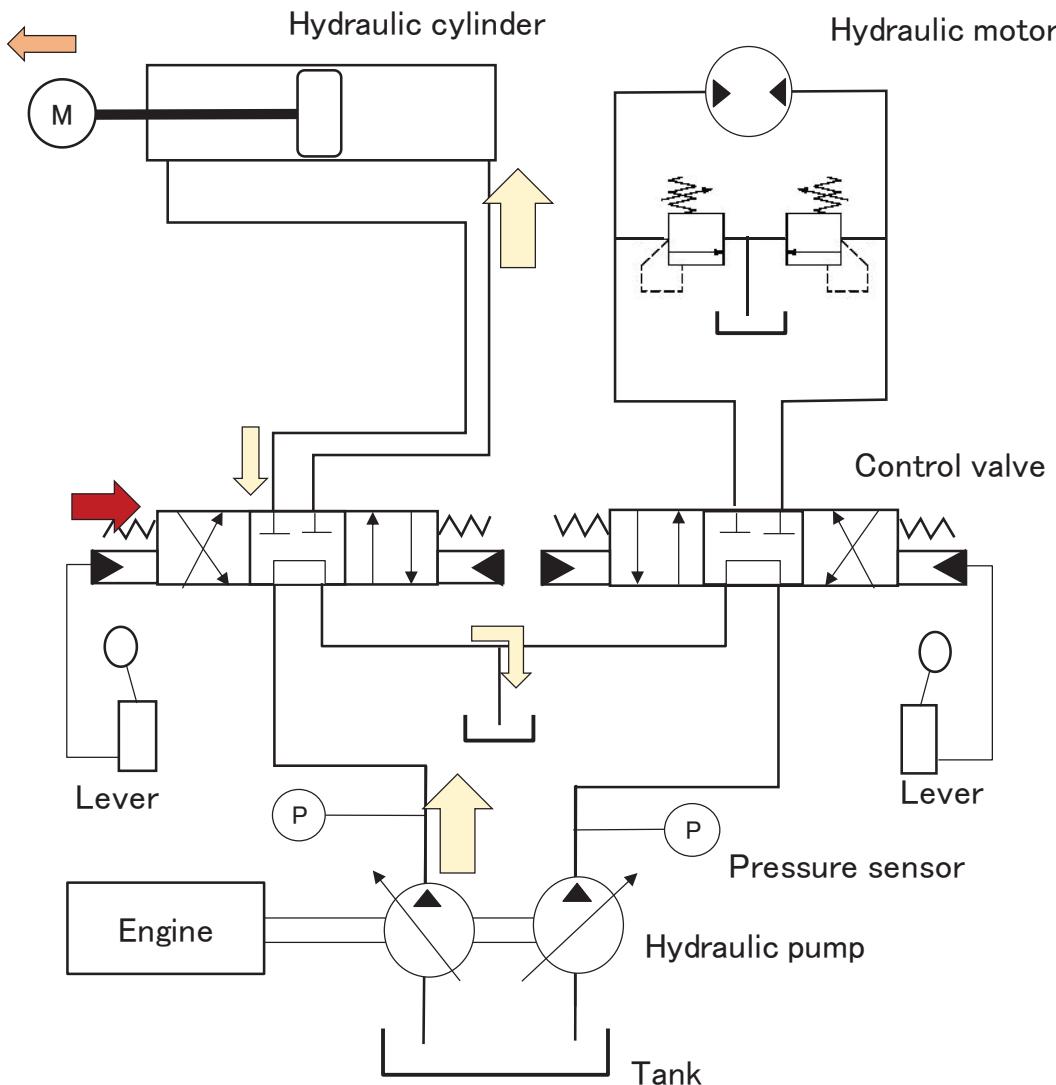


Fig. 3.9: Hydraulic circuit (hydraulic cylinder circuit)

しかし、油圧ショベル特有のシステムのために、ポンプが正常な状態のときでもポンプの指示流量と予測したポンプ流量が一致しない状況があり、誤検知の可能性がある。ポンプの指示流量と予測したポンプ流量が一致しない油圧ショベル特有のシステムとしては、例えば再生回路(Regenerative circuit)が考えられる。再生回路は、Fig.3.10 に示すようにシリンダから排出された作動油の一部、もしくは全部がタンクへ戻ることなく、その作動油を再びシリンダの供給側へ圧送可能な回路である。この場合、ポンプによって吐出された流量とシ

リンダの供給側へ送られる流量は、機械に故障がなく正常なときには両者が一致しないのが一般的である。したがって再生回路を使う動作を行うときに、ポンプの指示流量に対し予測した流量が乖離しているときに故障と判定する考え方を採用すると、誤検知が発生する可能性がある。

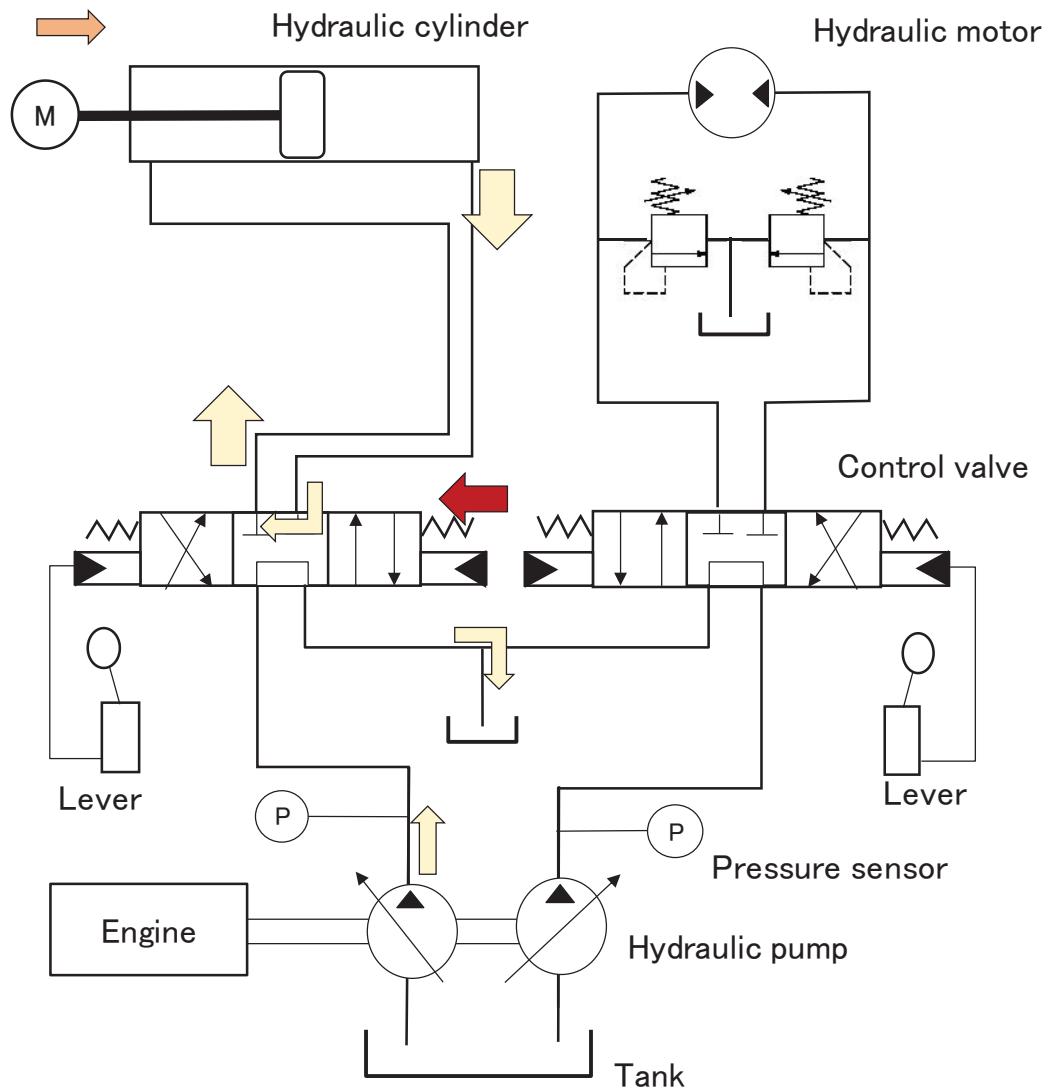


Fig. 3.10: Hydraulic circuit (regenerative circuit)

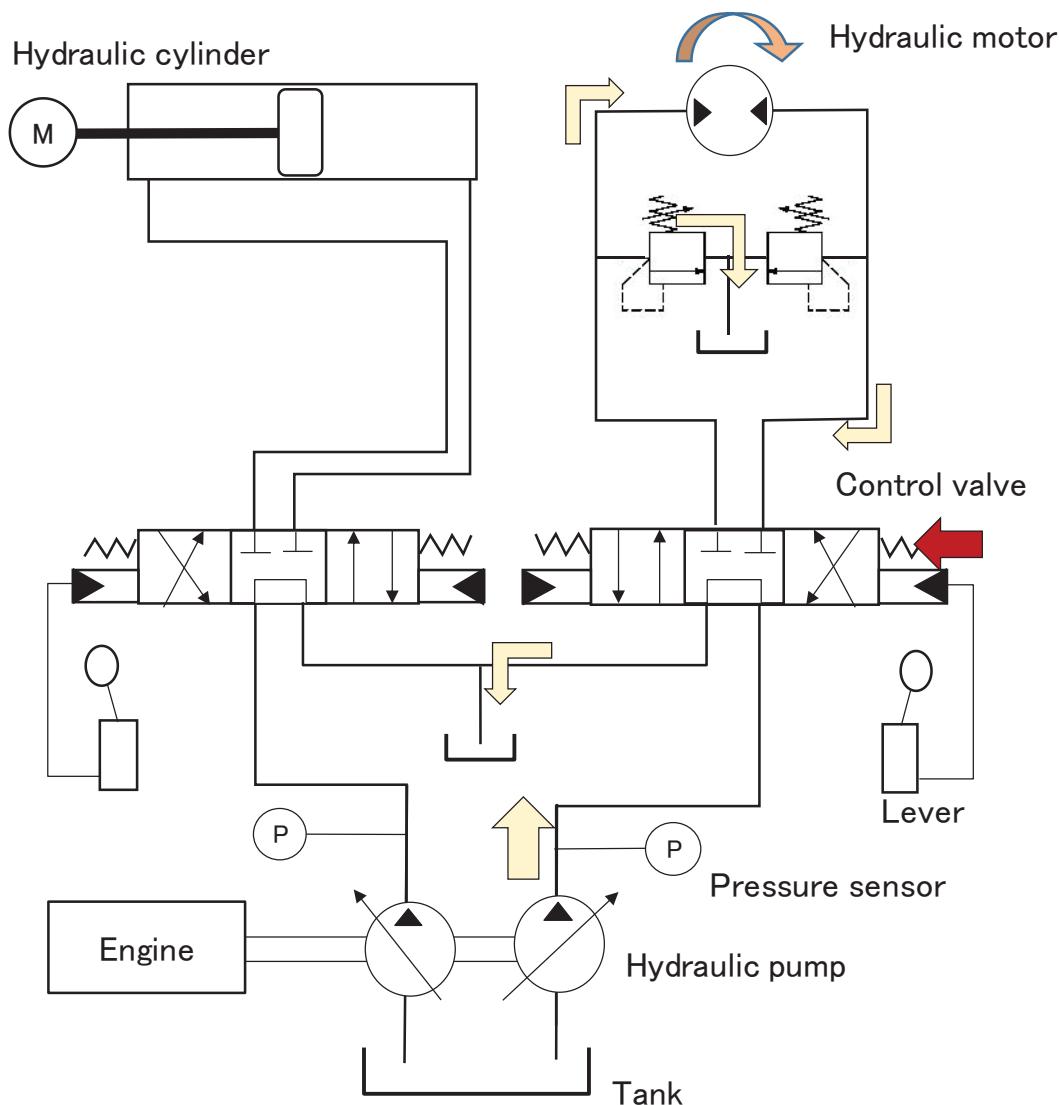


Fig. 3.11: Hydraulic circuit (hydraulic motor relief circuit)

また旋回操作時に、上部旋回体の作動時に高トルクを得るために油圧回路内の圧力が高くなり、Fig.3.11 に示すようにリリーフバルブと作動油タンクが導通することがある。この際、旋回油圧回路内の圧油はリリーフバルブから作動油タンクへ戻ることとなる。このケースのときにも、ポンプによって吐出された流量と旋回モータ(Hydraulic motor)の作動に供給される流量は一致しないため、誤検知の可能性が想定される。

そこで機械に故障がなく正常なときにも、ポンプの指示流量と予測した流量が掛け離れている状態を誤検知から避けるために、掘削作業における時系列データから特定の動作に分類されるデータのみを抽出し、故障予測モデルを作成する。故障を予測するため、式(3.7)の重回帰式によって、ポンプの流量を予測可能なモデルを作成する。

$$Q_p(t) = a_0 + \sum_{i=1}^m (a_i \times Q_i(t)) \quad (3.7)$$

ここで $Q_p(t)$ は予測流量を示し、 a_i は回帰係数、 $Q_i(t)$ はアクチュエータの流量を表す。なお、アクチュエータの種類数(ブームシリンダ、アームシリンダ、バケットシリンダ、旋回モータ)から $m = 4$ とする。また、モデルの説明性や解釈性を重視するため比較的単純な重回帰式を選択しポンプ流量の予測モデルを作成する。モデル作成時の操縦者のデータとは別の操縦者のデータを評価に用い、予測流量と実際のポンプ指示流量を比較し、乖離が発生していれば故障の可能性があると予測する。

3.3.2 評価結果

特定の動作に着目した故障予測モデルによる評価を行う。Fig.3.12 は掘削作業時におけるポンプ流量の推移(青プロット)とアクチュエータ流量の積算値(赤プロット)の推移を比較したグラフを示す。このグラフは横軸に時間(秒)をとり、縦軸は流量を示している。なお、流量は最大ポンプ流量との割合で表されており 0 から 1 までの間の値となるように正規化されている。また、水色の領域は「掘削」、オレンジ色の領域は「持上旋回」、黄色の領域は「排土」、紫色の領域は「復帰」の作業にそれぞれ分類される。このグラフよりポンプ流量とアクチュエータ流量の積算値は、油圧ショベル特有のシステムのために両者は一致しておらず、特に「復帰」の動作において大きな乖離があることを示している。また、それとは対照的に「持上旋回」動作においては、比較的両者が一致していることがわかる。したがって、3.2 節で示した LSTM モデルにより動作分類を行うことで「持上旋回」動作のデータを抽出し、故障予測モデルを作成することができれば、誤検知を抑制できるものと考えられる。

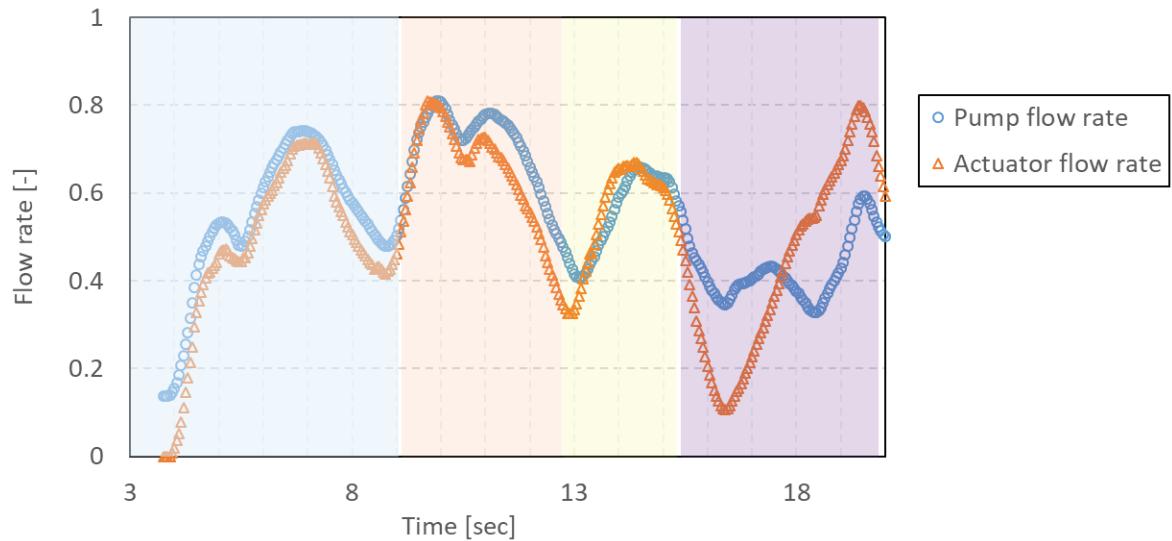


Fig. 3.12: Discharge flow rate (pump and actuator flow rate)

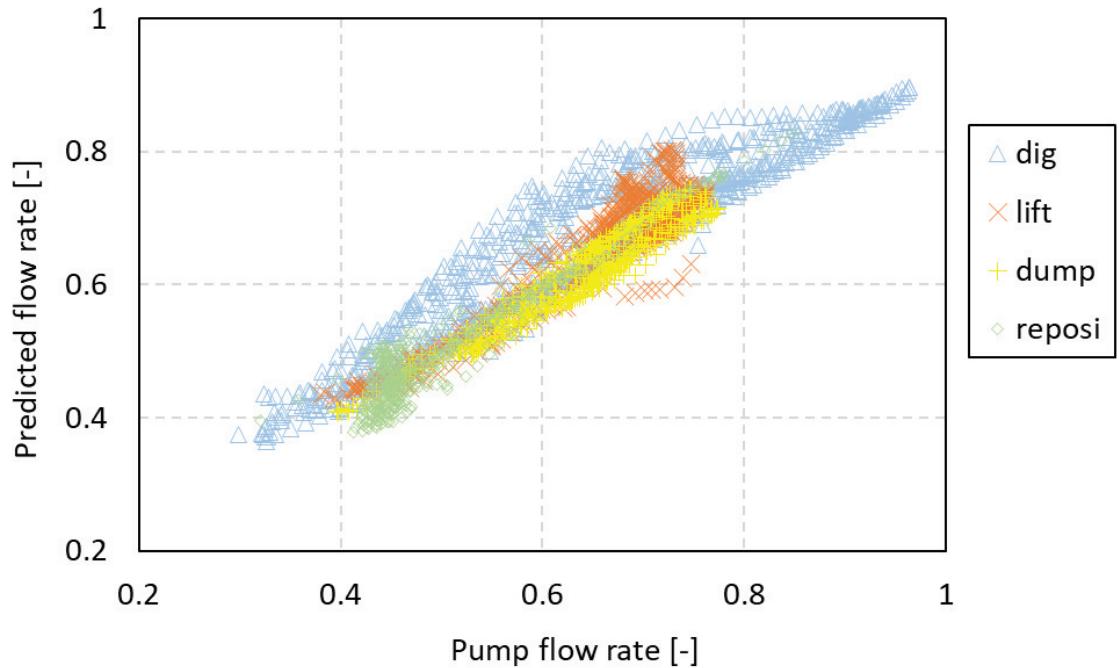


Fig. 3.13: Predicted flow rate (all operations)

Fig. 3.13 に動作分類を行わず、「掘削」、「持上旋回」、「排土」、「復帰」の作業データからポンプ流量の予測モデルを作成した場合のグラフを示す。横軸はポンプの指示流量を示し、縦軸はアクチュエータ流量を説明変数として算出したポンプの予測流量を示している。なお横軸・縦軸とともに、流量は最大ポンプ流量との割合で表されており 0 から 1 までの間の値となるように正規化されている。また動作毎に比較するため、プロットの色をそれぞれ変えている。Fig.3.13 のグラフから、アクチュエータ流量から求めた予測流量とポンプの指示流量が一致しない動作が見られることがわかる。特に、水色プロットで示した「掘削」や緑色プロットで示した「復帰」の動作において両者が一致しないことが多い。

それに対し、橙色プロットで示された「持上旋回」の作業データに絞り込んでポンプの故障予測モデルを作成したグラフを Fig. 3.14 に示す。Fig. 3.13 と同様に、横軸はポンプ指示流量を示し、縦軸はポンプ予測流量を示しており、それぞれ正規化されている。この際、赤プロットの作業データを学習用として故障予測のモデル作成に使い、青プロットで示す別

の操縦者の作業データをテストデータとして評価した。グラフからわかるようにテストデータも指示流量に対し、アクチュエータ流量からポンプ流量の予測を出来ていることが示されている。

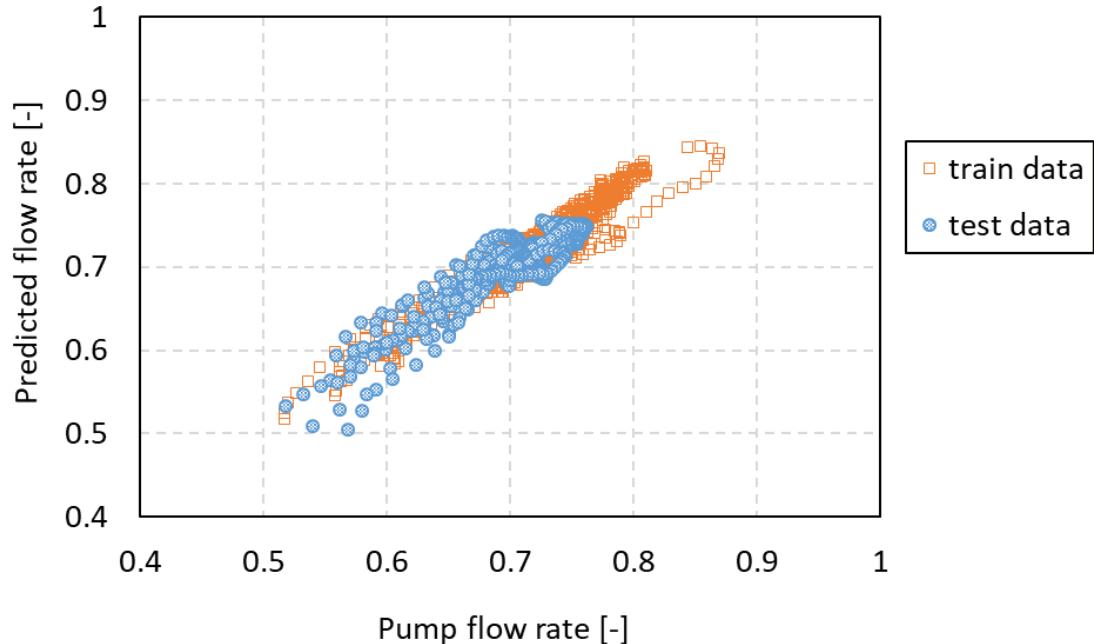


Fig. 3.14: Predicted flow rate (lifting and swing operation)

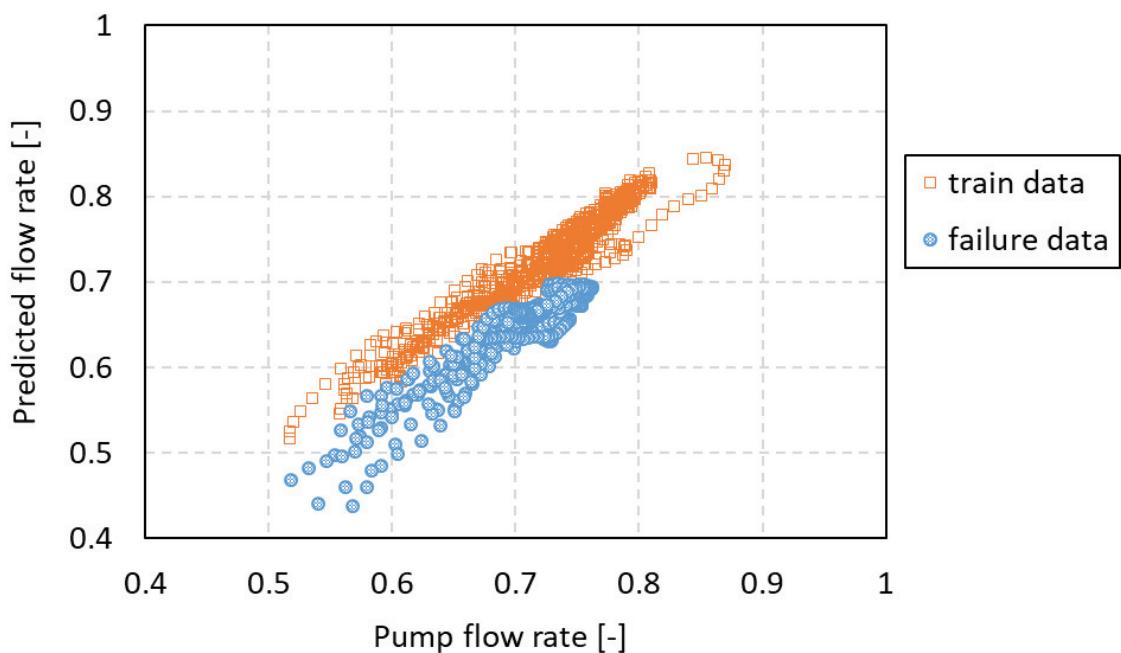


Fig. 3.15: Predicted flow rate (failure test data)

また、故障を想定したアクチュエータ流量におけるポンプ故障の予測流量を Fig. 3.15 に示す。Fig. 3.14 と同様に赤プロットのデータでモデルを作成し、青プロットの操縦者のデータに対しポンプの故障を想定し評価を行う。Fig. 3.15 の結果から、故障を想定したテストデータでは学習に使った正常な状態のデータよりも下方にプロットされていることから、指示流量に対し十分な吐出ができておらず、故障の可能性があると予測できるといえる。

つぎに、「持上旋回」動作に加えて「排土」動作も含んだ作業データに着目する。Fig.3.12 のポンプ流量の推移とアクチュエータ流量の積算値の推移を比較したグラフから、「排土」動作も比較的両者が一致しているため、「持上旋回」動作と「排土」動作の作業データを抽出してポンプの故障予測モデルを作成する。Fig. 3.16 に「排土」動作の作業データを加えたポンプの予測流量を示す。Fig.3.16 のグラフは、横軸にポンプ指示流量を示し、縦軸はポンプ予測流量を示している。また、赤プロットは「持上旋回」動作を示し、青プロットが「排土」動作を示す。このグラフから、「排土」の動作は「持上旋回」動作よりもポンプ流量が低く、流量が低い領域まで予測できていることを示している。

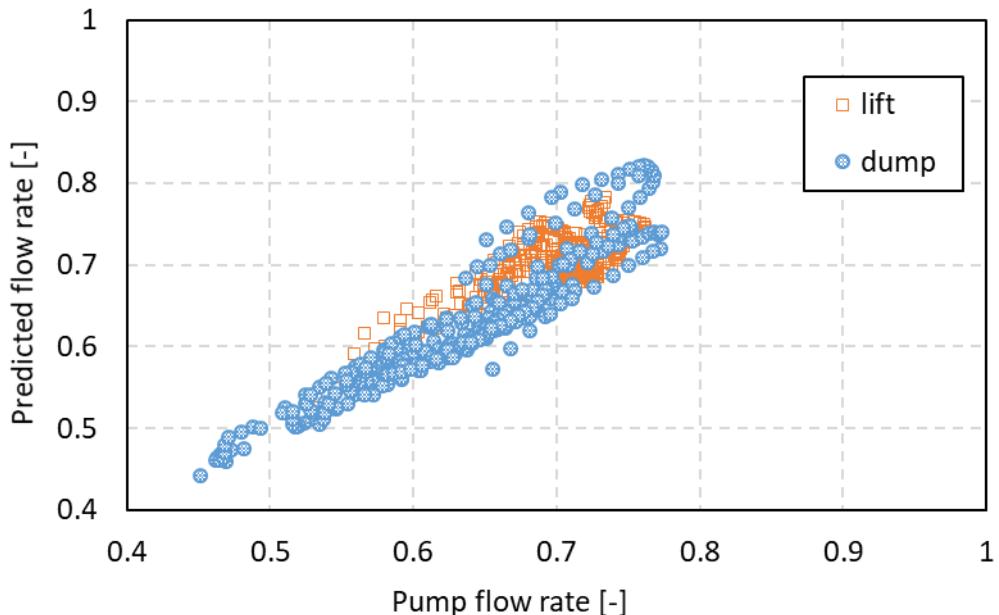


Fig. 3.16: Predicted flow rate (lifting and swing, dumping operations)

また故障を想定したアクチュエータ流量の場合、ポンプ故障の予測流量は Fig.3.17 に示すグラフのようになる。Fig.3.15 と同様に青プロットのデータに対し、ポンプ故障の想定を行う。Fig.3.17 のグラフに示すように、故障を想定したデータは学習に使用した正常状態のデータよりも下方にプロットされていることがわかる。このことから、想定した指示流量よりも十分な吐出流量を得られておらず、ポンプ本体側に故障が発生している可能性が高いと予測できる。

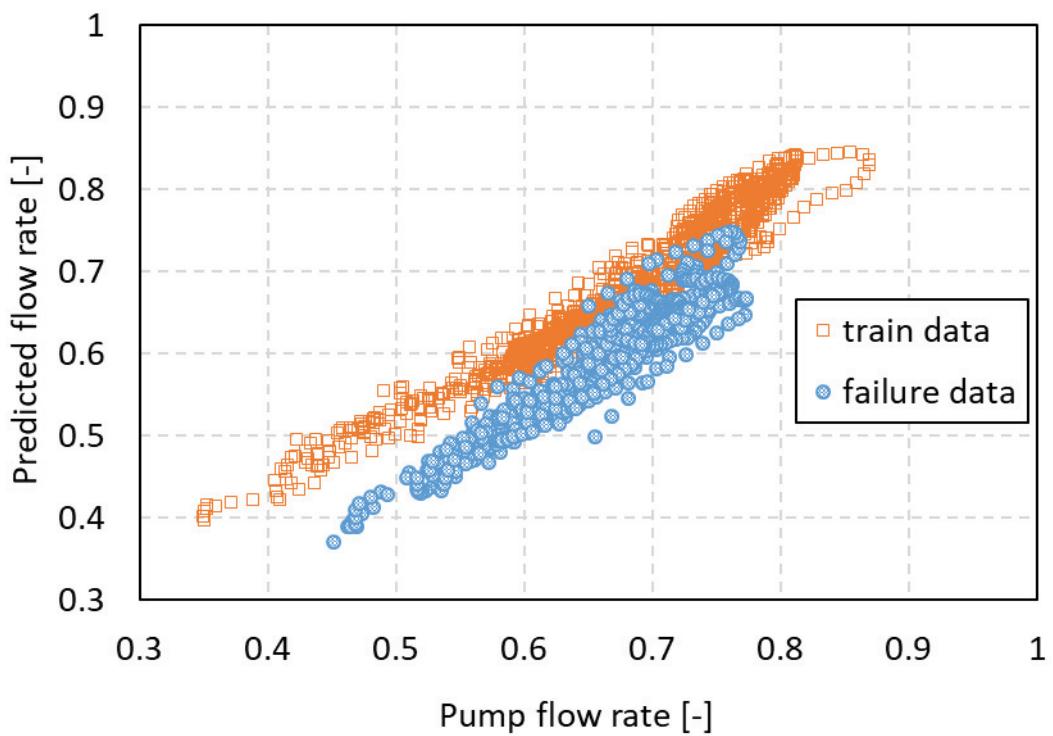


Fig. 3.17: Predicted flow rate (failure test data)

3.3.3 考察

3.2 節で示した油圧ショベルの掘削作業における動作分類を行い、特定動作のデータを抽出し、重回帰式による予測モデルを作成することでポンプの故障を判定できることを示した。これは掘削作業時における動作ごとに異なるアクチュエータへポンプの吐出油を供給しており、ポンプの流量配分は複雑となっている。「持上旋回」や「排土」の動作では、ポンプの吐出油がアクチュエータの作動に使われているため、重回帰式による比較的シンプルなモデルを立てることによって予測が出来たものと考えられる。

一方、「掘削」や「復帰」の動作は、Fig.3.10 や Fig.3.11 に示すような再生回路やリリーフ回路が使われることにより、シリンドラや旋回モータなどのアクチュエータの作動がポンプ吐出油以外からの供給によるもの、あるいはポンプからの吐出油がリリーフバルブを介して作動油タンクへ戻されるために、ポンプの故障予測モデルを立てられないものと考えられる。

また、今回は油圧ショベルの掘削作業動作を対象にポンプの故障を予測するモデルを特定の動作に対して絞込み、Fig.3.18 に示すフローチャートにより作成した。掘削作業の動作分類を LSTM により行い、「持上旋回」動作や「排土」動作の作業データを抽出し故障予測モデルを作成したが、動作や油圧ショベル特有のシステムが変わったとしても考え方が同じであれば、Fig.3.19 のフローチャートに従って故障を予測することは可能であると考えられる。

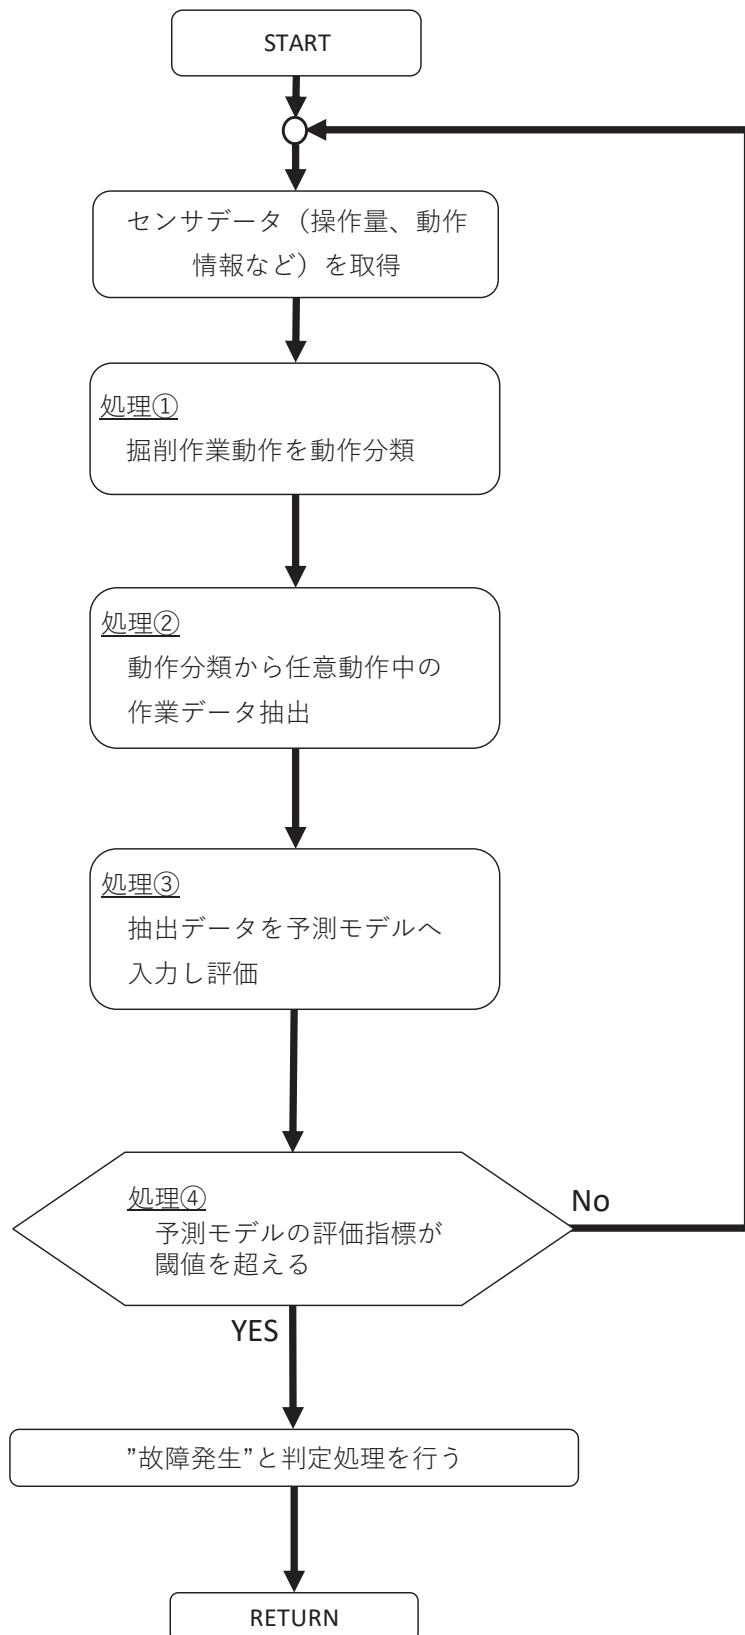


Fig. 3.18: Failure prediction flow chart

3.4 結言

本章では、LSTM を用いて掘削作業動作の分類モデルを作成し、油圧ショベルの掘削作業動作を「掘削」、「持上旋回」、「排土」、「復帰」、「待機」の 5 クラスの動作に分類を行った。操縦スキルが異なる 3 名の操縦者（「熟練操縦者」、「一般操縦者」、「非熟練操縦者」）の時系列データを用いて動作分類した結果を比較すると、熟練操縦者と一般操縦者の作業データは周期的な掘削作業の動作を分類していることがわかった。

その一方で、非熟練操縦者の作業データは、他の操縦者と比べて動作分類の精度が低かった。各動作の予測確率を算出すると掘削作業中のいくつかの動作において「待機」状態を示すという特徴が示され、非熟練操縦者特有の不安定な操作や低い操縦スキルによる影響が見られた。

また、掘削作業の動作分類を行うことによって、ポンプの機械特性の変化から故障を予測する方法を提案した。LSTM モデルにより動作分類を行って掘削作業動作の「持上旋回」や「排土」の作業データを抽出しポンプ流量の予測モデルを作成することで、誤検知を抑制してポンプ故障を予測できることを示した。

第4章 油圧ショベルの残存耐用時間 による故障予測

本章では、油圧ショベルの下部走行体を対象に故障が発生する前に故障を捉える方法を提案する。機械学習による故障を予測する方法として、稼働データからニューラルネットワークなどのモデルを構築する。残存耐用時間を予測する方法として、機械ごとの使われ方による違いを考慮するため、まず故障データを稼働状況が近い機械ごとにクラスタリングすることにより分類する。つぎに、データを十分に確保できているクラスタに対し残存耐用時間を予測するモデルを作成し、実際の残存時間と予測した残存時間の差を評価することで予測モデルの有効性を示す。また、実際の油圧ショベルのアフターサービスにおいて、機械学習を用いた故障予測と残存耐用時間予測を合わせた運用例を提示することにより、その有効性を示す。

4.1 緒言

IoT/ビッグデータ/AIなどの技術を活用した超スマート社会の実現を目指す「Society5.0」の推進が内閣府により提唱されている [33]。これまでの情報化社会では必要な知識や情報・データが十分に共有されておらず、情報・データを見つけ分析する作業に困難や負担が生じていた。Society5.0では、サイバー空間(仮想空間)とフィジカル空間(現実空間)を高度に融合させたシステムにより、センサとIoTを通じてあらゆる情報やデータがサイバー空間に蓄積されてビッグデータとなる [34]。そこではAIがビッグデータを解析することで現実空間に付加価値がフィードバックされるようになる [35]。したがって、Society5.0が様々な産業や社会生活に取り入れられることで経済発展と社会的課題の解決の両立ができる、超

スマート社会の実現が可能となる。

一方、建設業において油圧ショベルに代表される建設機械は、機械特有の高負荷・長期稼働などの使用環境や想定外の使われ方により早期に意図しない故障が発生することがある。このような故障を防ぐため、メーカ推奨の時間間隔による定期点検(時間計画保全)や機械に設置されたセンサから得られるデータを活用した「状態基準保全」が行われている。さらに、建設機械を製造するメーカは機械納入後もユーザが施工計画通りに機械を運用できるようにアフターサービスやメンテナンス活動を行うことが重要である。特に、予期しない突発的な機械故障による長期間の稼働停止は施工計画の遅延や余計な保全コストの損失に繋がる。

超スマート社会における建設業では機械が故障に至る前に予兆を捉え、保全計画を立てメンテナンスを行う必要がある。そのため、サイバー空間に集積されたセンサデータを AI により解析し、故障の予兆が見られる機械を特定し、保全計画へフィードバックすることが有効であると考えられる。

このような研究の先行事例として、袖子田らは、実際のプラントや産業機械のデータを用いて、MT 法をベースとしたデータ解析による診断技術の開発を行い、その有効性を検証している [36]。植木らは化学プラント機器の予防保全を目的に、時系列計測データと故障／保全データから生存時間解析に基づくデータの分析手法を提案している [37]。これらのよう、製造業において生産設備やプラントなどに対して多数の監視用センサデータから得られた時系列データを活用した故障予測手法や異常検知技術がよく見られる。しかし、対象とする設備や機械によってはコスト（製造費、通信料など）や機械性能の制約から予測対象物のセンサデータが必ずしも得られるとは限らない。また、短いサンプリング周期で取得した時系列データを入手できないこともある。

油圧ショベルのような産業機械の場合、頻繁に移動作業を行い、通信を介してデータを収集する必要があり、大容量の時系列センサデータをメモリに蓄積し、通信機器にて送受信す

ることが困難なケースが多く、日ごとの稼働情報を集約したサマリデータのみが得られることが少なくない。また、監視用に多数のセンサが設置されることは少なく、機械の制御用センサを監視に代用することが多い。さらに、油圧ショベルにおいては、生産設備のように一定負荷で同一動作の繰り返し作業が行われることは少なく、一般的には掘削や積み込み、均しなどの様々な作業が行われ、作業ごとにも掛かる負荷の大きさが異なる。

また油圧ショベルの下部走行体は、機械の構造上、損傷具合を測定できるセンサが搭載されていない。追加機器やレイアウト変更を行わないで既存センサで故障を予測するためには、上部旋回体に設置されたセンサから取得されたデータを使う必要がある。そこで、データベースに蓄積された上部旋回体のセンサデータを用いて、ニューラルネットワークなどの機械学習による予測モデルを構築し、油圧ショベルの下部走行体の故障を予測する方法を提案する。さらに、油圧ショベルのような建設機械の場合、過酷な環境下で使われることが多く、機械ごとの稼働状況が異なる。そのため、取得されたデータから機械ごとの稼働状況を考慮して残存時間を予測する必要がある。そこで、故障前にメンテナンス実施を判断するために必要な下部走行体が故障するまでの残存耐用時間を予測する方法も併せて提案する。

本章では、油圧ショベルの下部走行体を対象に故障が発生する前に故障を捉える方法として、機械学習モデルによる故障予測と残存耐用時間の予測を行う。稼働データからニューラルネットワークなどの機械学習モデルを構築することで故障発生の有無を予測し、今回用いた中では DNN によるモデルが最も再現率が高く、誤検出率も最も低いことを示している。残存耐用時間を予測する方法として、故障データを稼働状況が近い機械ごと分類する k-Means クラスタリングにより使われ方ごとに分類を行い、十分に故障データを確保できているクラスタに対して残存耐用時間予測のモデルを作成することで、少ない誤差で予測できることを示している。

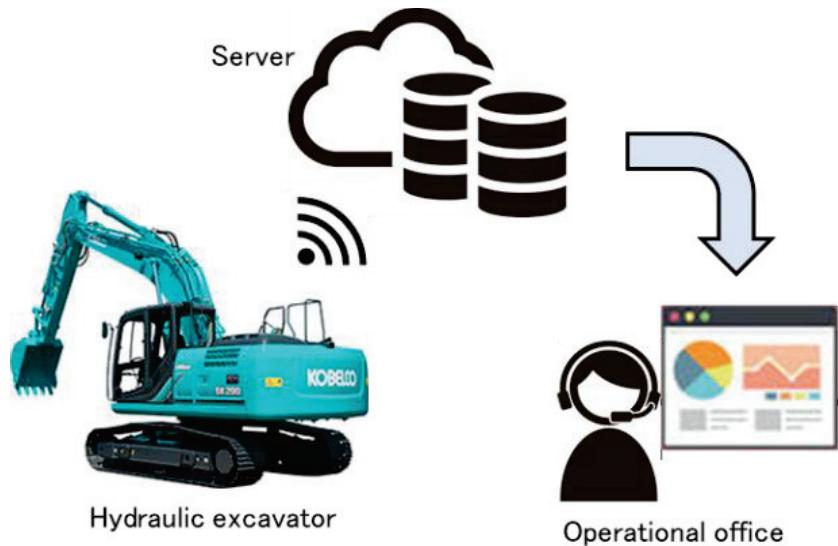


Fig. 4.1: Failure Prediction System

4.2 油圧ショベルの下部走行体の故障予測

提案する故障予知システムの構成および対象とする油圧ショベル（コベルコ建機株式会社製 SK200-10）を Fig.4.1 に示す。油圧ショベルにはポンプや作業部分を稼働させるアクチュエータなどが搭載されており、これらを制御するために多数のセンサが搭載されている。これらのセンサは機械状態の計測や各部位の制御のみだけではなく、日々の作業における稼働状況を演算し、実際のフィールド現場で稼働した実稼働データとして、外部のサーバへ送信される。フィールド現場で稼働している複数の油圧ショベルから外部サーバへ送られた実稼働データを故障予測システムへ入力することにより、特定部位の故障が発生する機械を予測する。

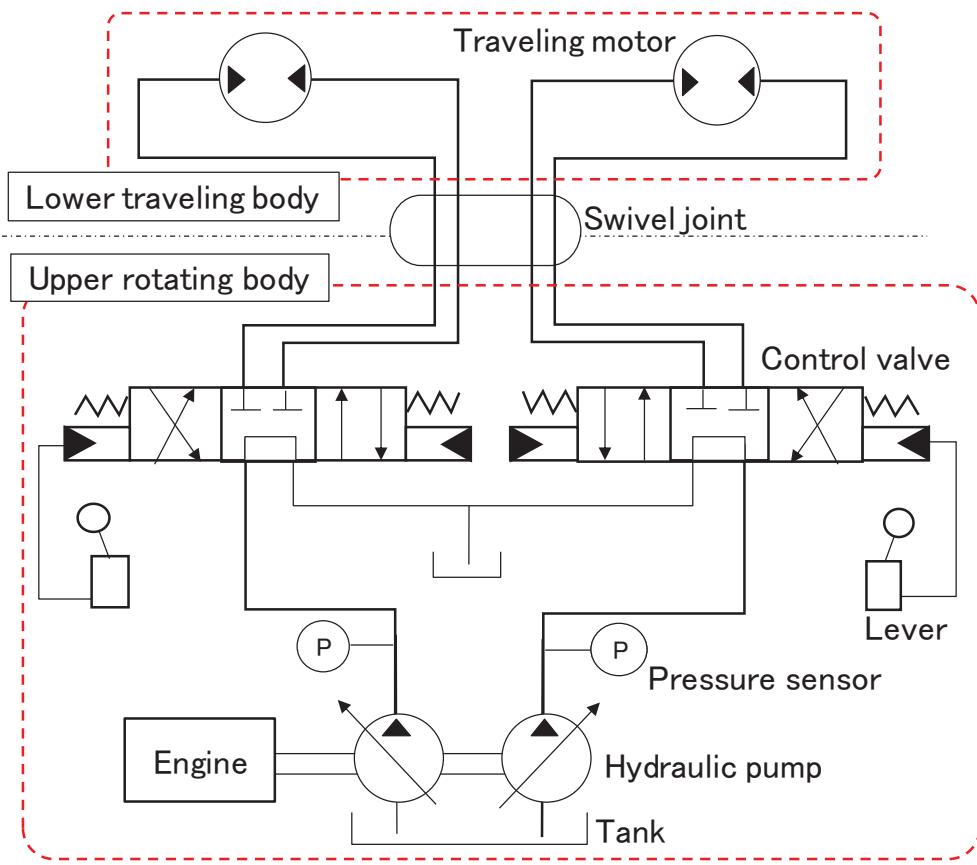


Fig. 4.2: Hydraulic Circuit (Traveling operation)

油圧ショベルは、その作業内容の特性から起伏が激しい道路や急こう配の坂道などで使われることが多い。このような場所での走行作業は、特に応力に起因し下部走行体への損傷が大きい。そこでこの油圧ショベルの下部走行体に関する故障発生の有無を予測する。

油圧ショベルの下部走行体の動作方法を Fig.4.2 の油圧回路図を用いて説明する。油圧ショベルは大きく分けて、エンジン (Engine) や油圧ポンプ (Hydraulic pump) などの機器が搭載されている上部旋回体 (Upper rotating body) と左右 2 個の走行油圧モータ (Traveling motor) が搭載されている下部走行体 (Lower traveling body) に分かれている。上部旋回体は 360 度の旋回動作ができるように制御弁 (Control valve) とスイベルジョイント (Swivel joint) が配管で接続されている。また、上部旋回体から作動油を送るためスイベルジョイントと走行油圧モータも配管で接続されている。エンジンから油圧ポンプの駆動軸へトルク

を与えることでタンク (Tank) から作動油を吸い込み油圧回路へ吐出される。走行レバー (Lever) を入力することで制御弁が切り替わり、油圧ポンプから作動油が送られる。スイベルジョイントを経由して作動油が送られることで走行油圧モータは駆動力を得る。このようにして車体の前進・後退動作が可能となる。

下部走行体の故障を予測するため、ひずみゲージやセンサなどを用いて下部走行体に加わる応力を直接的に計測することが考えられる。しかし、機械の構造上、下部走行体に設置したセンサと上部旋回体のコントローラを配線で接続しようとすると、ロータリ運動を伴うスイベルジョイント部分を通す必要があるため、旋回時に配線が断線する可能性がある。また、ひずみゲージやセンサ自身へ加わる外力や損傷も考えられ、正しくセンサデータを得られないことが予想される。さらに、センサや配線を追加搭載するとレイアウト変更や製造コストの増加など、さまざまな課題が生じる。

そこで、予測される下部走行体の故障事象と走行動作中の搭載機器の状態量との関係を推定し、既存のセンサや搭載済みの機器から得られる下部走行体に関わる入力変数を抽出し、故障予測モデルを作成する。

4.2.1 機械学習モデルによる故障予測

油圧ショベルの走行作業中に、下部走行体の走行油圧モータに与えられるトルク T_t は以下の式で示される。

$$T_t = \frac{\Delta P_t q_t}{2\pi} \quad (4.1)$$

ここで、 ΔP_t は走行モータ圧力（前後差圧）、 q_t は走行モータ容量である。

下部走行体に係る応力をひずみゲージなどを搭載することにより直接的に計測することは出来ないが、下部走行体に掛かる応力と走行時の油圧モータに与えられるトルクは強い関係があると推定される。しかし、下部走行体に走行モータトルクを直接的に測定可能なセンサも搭載されていない。また、走行モータ圧力 ΔP_t を計測可能なセンサについても走行の

制御に必要としないため搭載されていない。

走行時の圧力は、油圧ポンプ圧力から配管・バルブなどの圧力損失を除いた圧力に比例すると推測される。油圧ポンプに搭載された制御用の圧力センサを兼用して計測することで圧力分布データとして、低圧力・中圧力・高圧力・超高圧力の4領域のデータを取得する。また、フィールド現場での作業負荷が油圧ショベルの故障に影響していると思われる。作業負荷を示す状態量として油圧ポンプトルク分布データをトルク $T_1 \cdot T_2 \cdot T_3 \cdot T_4 \cdot T_5 \cdot T_6$ として取得する。なお、油圧ポンプトルク T_p は以下の式で示される。

$$T_p = \frac{P_{p1}q_{p1} + P_{p2}q_{p2}}{2\pi} \quad (4.2)$$

ここで、 P_{p1} および P_{p2} は油圧ポンプ圧力を示し、制御用の圧力センサにて計測可能である。また、 q_{p1} および q_{p2} は油圧ポンプ容量を示しており、電流値を計測することにより求めることができる。

さらに、フィールド現場での油圧ショベルの使われ方も故障の要因として関わっているものと考えられるため、作業別の稼働時間として、掘削作業・走行作業・待機状態の各作業時間も取得する。

なお、コスト（製造費、通信料など）や記憶媒体容量などの制約条件があり、多数かつ短周期のセンサデータが得られないため、実稼働データは機械1台につき、1日の作業を集約したデータとして外部サーバへ送信する。下部走行体構造物の故障事象であるため、1日ごとのデータを変数ごとに積算した値を1つの変数として扱う。

また、基幹システムにて管理されている故障情報から下部走行体構造物の故障に該当する機械を抽出する。該当機があれば出力変数を1とし、故障のない正常データであれば0とする。

Table 4.1: Input and output variables.

input/output	classification	variables	items
Input	pressure distribution	O_1	low pressure
		O_2	middle pressure
		O_3	high pressure
		O_4	ultra-high pressure
	torque distribution	O_5	torque T_1
		O_6	torque T_2
		O_7	torque T_3
		O_8	torque T_4
		O_9	torque T_5
		O_{10}	torque T_6
	operation time	O_{11}	digging time
		O_{12}	traveling time
		O_{13}	idle time
Output	failure or normal	t_1	failure
		t_0	normal

以上より, Table 4.1 に示す下部走行体の故障に関する入力変数(油圧ポンプの圧力分布, トルク分布, 各作業時間のデータ)と故障情報から得られる出力変数を用いる. これらを使い, 下部走行体の故障予測モデルを作成する.

生産設備のように決まった負荷で大きな変動がなく, 同一動作が繰り返し行われる機械であれば, 稼働時間をもとに回帰分析などの手法により寿命時期を予測することが可能である. しかし, 本研究で用いる故障予測システムのモデルには, 油圧ショベル特有の機械ごとに作業内容や稼働状況, 負荷状態などが異なることが考えられるので, 重回帰などの線形モデルではなく, ニューラルネットワークをはじめとする非線形モデルを用いる.

Table 4.2: Overview of operation data.

	values	unit
sample data	501,903	data
machine	1,526	unit
sampling	1	per a day
input variable	13	variable

Table 4.3: Training data and test data.

	normal	failure
training data	281	325
test data	1,163	85

4.2.2 評価結果

Table 4.2 に機械学習による故障予測モデルの作成および評価に用いる実稼働データの概要を示す。これらの実稼働データを用い、学習データおよび評価データを生成する。

今回評価するのは構造部品の耐久に関わる故障事象のため、入力変数は機械個体ごとに積算した値とする。観察期間中に故障がない機械は各入力変数を観察期間終了日まで積算した値を正常データとして扱う。観察期間中に故障がある機械は、観察開始日から故障前日および 2-5 日前までの積算した値を故障データとして扱う。なお、観察開始日から観察終了日まで対象とする故障以外は含まない機械を選定する。また、機械の重量カテゴリ（重量、大きさ）や地域による特性を考慮し、特定地域の重量カテゴリが同一の機械に限定する。

Table 4.3 に示すように学習データは正常データを 281 データ、故障データを 325 データ用いて機械学習モデルの学習を行う。

学習データにより作成したモデルに対する評価データの分類精度を正解率 A 、再現率 R 、適合率 P 、誤検出率 F として

$$A = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.3)$$

$$R = \frac{TP}{TP + FN} \quad (4.4)$$

$$P = \frac{TP}{TP + FP} \quad (4.5)$$

$$F = \frac{FP}{FP + TN} \quad (4.6)$$

と表す。ただし、 TP (True Positive) は真陽性を表し、陽性（故障）と予測して実際に陽性であったデータ数を示す。 TN (True Negative) は真陰性を表し、陰性（正常）と予測して実際に陰性であったデータ数を示す。また、 FP (False Positive) は偽陽性を表し、陽性（故障）と予測したが実際には陰性（正常）であったデータ数を示す。 FN (False Negative) は偽陰性を表し、陰性と予測したが実際には陽性であったデータ数を示す。 $(4.3) - (4.6)$ 式は、正解率 A は全データ数のうちで正しく予測できたデータ数の割合を表し、再現率 R は実際に故障であったデータの中で故障を正しく予測できたデータ数の割合を表す。適合率 P は故障と予測したデータの中で実際に故障であったデータ数の割合を表し、誤検出率 F は実際には正常であったが故障と予測したデータ数の割合を表している。

まず、学習データを使いニューラルネットワークモデルの学習を行った。なお、ニューラルネットワークのハイパーパラメータは Table 4.4 に示す値を用い、隠れ層を 1 層、学習回数を 6,000 回、学習率 $\eta = 0.3$ とした。勾配法のアルゴリズムには Momentum 法 ($\alpha = 0.2$) を採用する。正常データにおいて、正しく識別されず故障に分類されるデータがあったが、データを確認すると故障データに近い傾向を示していたため、これらのデータを除外して評価する。

Table 4.4: Hyper parameters.

	values
hidden layer	1
learning rate	0.3
Momentum	0.2
batch size	100
training time	6,000

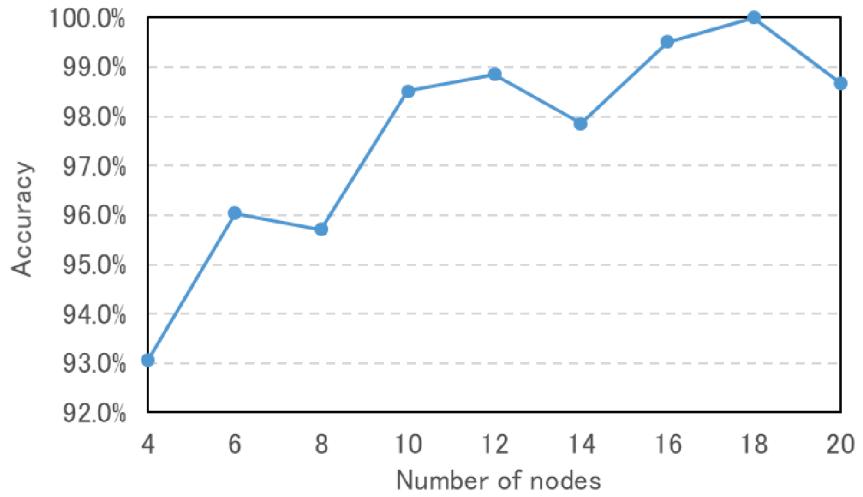


Fig. 4.3: Accuracy (training data)

Table 4.5: Confusion matrix (nodes = 18).

		prediction	
		failure	normal
actual	failure	325	0
	normal	0	281

Fig.4.3 に隠れ層のノード数を 4 個から 20 個まで 2 個ずつ増やしたときの学習モデルの正解率を示す。ノード数を 18 個まで増やしたときに正解率は最大を示し、Table 4.5 に示すように正常データと故障データを正しく分類できていることを確認している。

つぎに、ノード数を 18 個として学習させたニューラルネットワークモデルに対し、評価データを入力して故障予測の精度を評価する。Table 4.6 に示すように正解率 A , 再現率 R , 適合率 P , 誤検出率 F は、それぞれ 81.9[%], 64.7[%], 21.9[%], 16.9[%] である。学習データと比べると、再現率が特に低く故障の検出漏れ（見逃し）が多く発生することがわかる。これは学習モデルに対して、過学習気味であることが影響していると考えられる。

Table 4.6: Evaluation values (test data).

	nodes = 18	nodes = 6
accuracy	81.9 [%]	78.6 [%]
recall rate	64.7 [%]	83.5 [%]
precision rate	21.9 [%]	21.9 [%]
false detection rate	16.9 [%]	21.8 [%]

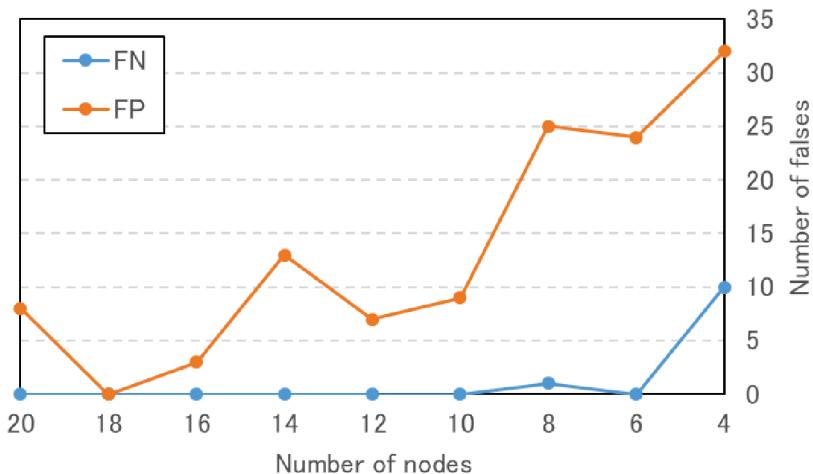


Fig. 4.4: Number of FN and FP

これに対し汎化能力を持たせるため、ニューラルネットワークの隠れ層のノード数を減らして評価を行う。Fig.4.4 にノード数を 20 個から 4 個まで 2 個ずつ減らしたときの *FP* および *FN* の数を示す。*FP* の数はノード数を減らすに連れて増加する傾向がある。*FN* の数はノード数を徐々に減らしていくとノード数を 4 個のときに *FN* の数が急に増加する。*FN* の数が少なく、故障を正しく判別させられることを考慮し、ノード数を 6 個の場合を評価する。

このときの正解率 *A*, 再現率 *R*, 適合率 *P*, 誤検出率 *F* は、それぞれ 96.0[%], 100.0[%], 93.1[%], 8.5[%] である。ノード数を 18 個としたときよりも精度は劣るが、高い正解率が得られており、故障を識別するには十分なモデルであると判断する。

Table 4.7: Evaluation values (test data).

	Logistic	DNN	SVM
accuracy	73.1 [%]	83.0 [%]	70.3 [%]
recall rate	88.2 [%]	88.2 [%]	76.5 [%]
precision rate	18.7 [%]	27.1 [%]	15.6 [%]
false detection rate	28.0 [%]	17.4 [%]	30.2 [%]

ノード数を 6 個として学習させたモデルに評価データを入れて故障予測の精度を評価した結果を Table 4.6 に示す. 正解率 A , 再現率 R , 適合率 P , 誤検出率 F は, それぞれ 78.6[%], 83.5[%], 21.9[%], 21.8[%] である. ノード数を 6 個とした場合, 正解率は, やや下がるもののが高い精度を維持できていることを確認している. また, ノード数が 18 個の場合よりも再現率が高く, 故障の見逃しが少ないと言える.

つぎに, ほかの機械学習手法を使用した場合の評価結果を示す. まず, ロジスティック回帰モデルの評価を行う. 学習させたロジスティック回帰モデルに対し, 評価データを入力して故障予測の精度を評価すると, Table 4.7 に示すように正解率 A , 再現率 R , 適合率 P , 誤検出率 F は, それぞれ 73.1[%], 88.2[%], 18.7[%], 28.0[%] である.

つぎに, DNN の学習を行う. なお, DNN の隠れ層は 3 層としノード数は 1 層目を 18 個とし, 2 層目を 6 個, 3 層目を 3 個とする. その他のハイパーパラメータは Table 4.4 に示す値を用い, 学習回数は 6,000 回, 学習率 $\eta = 0.3$ とし, 勾配法はニューラルネットワークと同様に Momentum 法 ($\alpha = 0.2$) とする. 学習させた DNN モデルに対し, 評価データを入力すると故障予測の精度は Table 4.7 に示すように正解率 A , 再現率 R , 適合率 P , 誤検出率 F は, それぞれ 83.0[%], 88.2[%], 27.1[%], 17.4[%] である.

最後に, SVM モデルを評価する. なお, ガウスカーネル関数のガンマ係数は, $\gamma = 1 \times 10^{-5}$ とする. 評価データを入力して故障予測の精度を評価すると, Table 4.7 に示すように正解率 A , 再現率 R , 適合率 P , 誤検出率 F は, 70.3[%], 76.5[%], 15.6[%], 30.2[%] である.

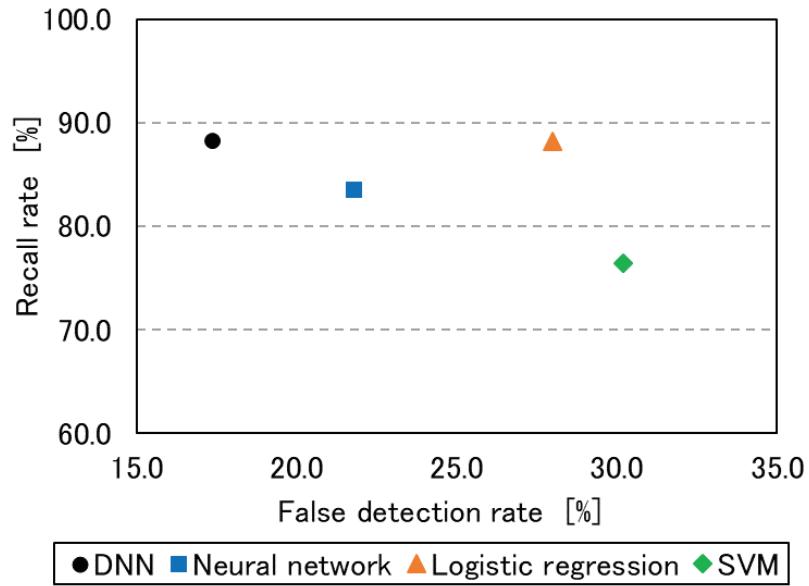


Fig. 4.5: Comparison of machine learning models

これらの結果を比較するため、Fig.4.5 に横軸に誤検出率、縦軸に再現率をとったグラフを示す。DNN およびロジスティック回帰を使った場合に高い再現率を示しており、実際の故障に対して、正しく予測できているデータ数が多いことがわかる。誤検出率を比較すると、DNN・ニューラルネット(n=6)・ロジスティック回帰・SVM の順に低くなることがわかる。したがって、今回使った機械学習手法の中では、DNN が最も再現率が高く、誤検出率も最も低い。SVM の場合、再現率が低く、誤検出率も最も高い。

4.3 油圧ショベルの残存耐用時間予測

油圧ショベルの下部走行体における故障の兆候を早期に見つけ、残存耐用時間を予測する方法を示す。まず、4.2 節で示した機械学習による故障予測モデルを作成し、未知の稼働データに対して、正常もしくは故障の判定を行う。故障と判定された油圧ショベルはメンテナンス時期を知る必要があるため、故障データを使ってクラスタリング結果から故障のグループを分類する。なお、故障データには過去に故障歴を含まない機械を選定する。故障データが十分に含まれているクラスタの残存耐用時間の予測モデルを作成し、残存時間を予測する。このような方法にすることで、正常と診断されるデータも含めてすべての機械の残存時間を評価する必要がなく、効率的に保全が必要な機械を判断することが期待できる。機械学習を用いた故障予測方法については、前節において示しているため、以下では故障データのクラスタリングと残存耐用時間の予測方法を示す。

4.3.1 故障データのクラスタリング

油圧ショベルに代表される建設機械は、特に機械特有の高負荷・長時間稼働・高温多湿などの過酷な使われ方により、稼働状況が機械ごとに異なるので、その違いを考慮する必要がある。稼働状況が近い機械ごとにグループ分けするため、故障データをクラスタリング手法のひとつである k-Means 法により、いくつかのクラスタに分類を行う [38]。この際、前節で示した下部走行体の故障予測を行う機械学習モデルを構築するために使った 13 変数(ポンプ圧力分布、ポンプトルク分布、作業別の稼働時間)を用いて、クラスタリングを行う。故障が発生する頻度は低くデータ数が少ないことが想定される。また、大多数は近い運転状態で、少数の稼働状態がいくぶんか存在していると推測される。したがって、十分な量を確保できているクラスタに対して残存耐用時間の予測モデルを作成し、その評価を行う。

4.3.2 残存耐用時間の予測方法

下部走行体の故障に対して、故障データから残存耐用時間を予測するモデルをつくる。予測モデルの作成には、4.2 節において使用した故障データを利用する。故障データの詳細を Table 4.8 に示す。82 台の機械の故障データがあり、Table 4.9 に示す 13 個の入力変数を含んでいる。ただし、Table 4.9 の入力変数は、たとえば「低圧力」であれば P_{lo} [MPa]未満、「中圧力」であれば P_{lo} [MPa]以上かつ P_{mi} [MPa]未満の圧力範囲 (P_{lo}, P_{mi} は任意の値) で稼働した状態を示し、「トルク T_l 」であれば T_o [Nm]以上かつ T_l [MPa]未満のトルク範囲 (T_o, T_l は任意の値) で稼働した状態を示す。これらの故障データは機械ごとに日々、取得されているデータであるため、入力変数ごとに積算する。そして任意の日数間隔ずつデータを抽出し、残存耐用時間の予測モデルを作成する。

Table 4.8: Overview of failure data

	values	unit
sample data	13,116	data
machine	82	unit
sampling	1	per a day
input variable	13	variable

Table 4.9: Input variables

classification	variables	items	conditions
pressure distribution	x_1	low pressure	$x_1 < P_{lo}$
	x_2	middle pressure	$P_{lo} \leq x_2 < P_{mi}$
	x_3	high pressure	$P_{mi} \leq x_3 < P_{hi}$
	x_4	ultra-high pressure	$P_{hi} \leq x_4$
torque distribution	x_5	torque T_1	$T_0 \leq x_5 < T_1$
	x_6	torque T_2	$T_1 \leq x_6 < T_2$
	x_7	torque T_3	$T_2 \leq x_7 < T_3$
	x_8	torque T_4	$T_3 \leq x_8 < T_4$
	x_9	torque T_5	$T_4 \leq x_9 < T_5$
	x_{10}	torque T_6	$T_5 \leq x_{10} < T_6$
operation time	x_{11}	digging time	
	x_{12}	traveling time	
	x_{13}	idle time	

残存耐用時間の予測モデルには、医療分野の生存時間解析や工学分野の信頼性分析などで用いられている Cox 比例ハザードモデル

$$\log\left(\frac{t}{t_0}\right) = a_0 + a_1 x_1 + \cdots + a_n x_n \quad (4.7)$$

を使う [39]。ここでは t は、その時点における故障までの残存耐用時間[hr]を示し、 t_0 は稼働開始から故障までの累積稼働時間[hr]を表す。 x_n は説明変数を示し、ポンプ圧力やポンプトルクなどの Table 4.9 に示す 13 個の入力変数とする。

また、 a_n は説明変数の回帰係数を示す。この(4.7)式に学習データの入力変数と累積稼働時間 t_0 [hr]、および残存耐用時間 t [hr]を使って、重回帰分析を行うことにより回帰係数 a_n ($n=0,1,\dots,13$)を決定する。これにより、残存耐用時間の予測モデルが作成できる。作成したモデルに検証データを入力し、実際の残存時間と予測した残存時間を比較・評価を行う。

4.4 残存耐用時間の評価方法

十分にデータ量を確保されたクラスタに対し残存耐用時間を予測するモデルを作成し、その評価を行う。4.2 節で機械学習による故障予測モデルを作成し、評価を行った際に使った故障データを学習データと検証データに分類する。学習データに該当する機械のデータを使って、(4.7)式により残存耐用時間の予測モデルを作成する。作成したモデルに検証データを入力することで予測残存耐用時間を算出する。実際の残存時間と予測した残存時間を基準時間に対する比率で表し、実際の残存時間比率と予測した残存時間の比率の相関を評価する。さらに任意の故障日数前での実際の残存時間比率と予測した残存時間比率の差分を評価し、ばらつきが少なければ良好な精度が得られていると判断する。

また、k-Means 法によるクラスタリングを行わずに残存耐用時間の予測モデルを作成し、検証データを入力し結果を評価する。クラスタに分けた場合と比較することで、油圧ショベルの稼働状況の違いに分けて残存耐用時間を予測することの有効性を評価する。

4.5 結果

稼働データにより構築されたニューラルネットワークにより、油圧ショベルの下部走行体の故障を予測できることが 4.2 節において示されている。ニューラルネットワークのノード数が 18 個と 6 個の場合を比較し、前者のほうが正解率は高く誤検出も低く、後者は再現率・適合率が高いことが示されている。以下では故障データのクラスタリングと残存耐用時間予測の結果を示す。

4.5.1 k-Means クラスタリングの結果

油圧ショベルの稼働状況による使われ方の違いを考慮するため、4.2 節で機械学習による故障予測を行う際に使った故障データの入力変数(ポンプ圧力分布、ポンプトルク分布、作業別の稼働時間)を使い、k-Means 法($k=4$)によりクラスタリングを行う。最も多くの機械が含まれるクラスタ内に、残存耐用時間の予測モデルを作成するのに十分なデータ量を確保できており、クラスタの数を $k=4$ とする。

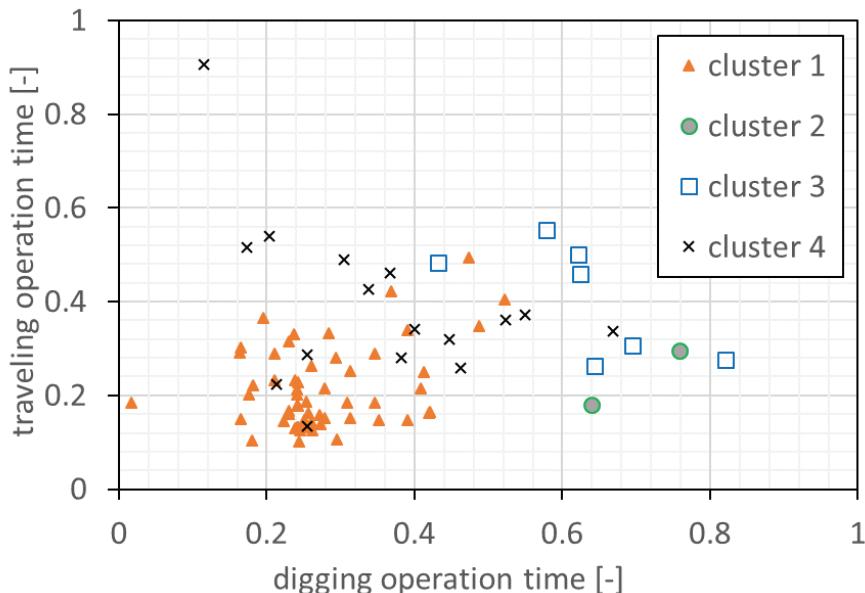


Fig. 4.6: k-Means clustering ($k=4$)

油圧ショベルの使われ方は掘削や走行などの作業別の稼働時間によって表されることが多いため、横軸に掘削作業時間、縦軸に走行時間をとったものを Fig.4.6 に示す。なお、横軸と縦軸は共に 0 から 1 の間の値となるように正規化している。各クラスタの特徴としては、クラスタ 1 は掘削作業の割合と走行作業の割合が近い機械が多い傾向があり、クラスタ 2 およびクラスタ 3 は掘削作業が比較的高い割合の傾向がある。クラスタ 4 は他のクラスタと比較し、掘削作業割合に対して走行作業の割合が大きい機械が多い傾向が見られる。

また、各クラスタに分けられた台数を Table 4.10 に示す。クラスタ 2 に分けられた機械が最も少なく、クラスタ 1 に分けられた機械が最も多い。クラスタ 2 は、他のクラスタと比べて掘削作業の割合が相対的に多く、特有な使われ方をされていると考えられる。クラスタ 1 に分けられた機械は、掘削作業時間と走行作業時間が機械ごとに近いため、機械の使われ方も同じような稼働状況で使われているものと考えられる。

Table 4.10 Number of data in clusters

	Units
cluster 1	57
cluster 2	2
cluster 3	7
cluster 4	16

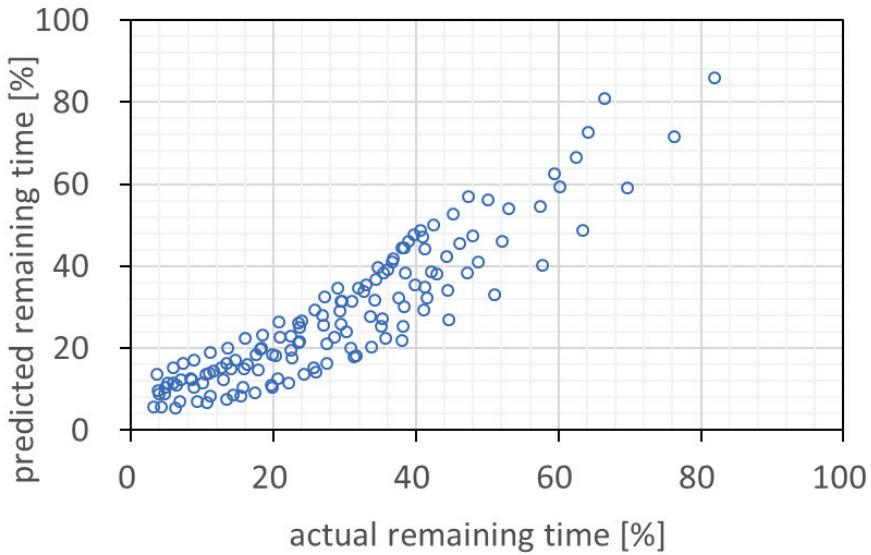


Fig. 4.7: Comparison of remaining time (cluster 1)

4.5.2 残存耐用時間の予測結果

4 個に分けられたクラスタの内、分類された台数が多く、学習データを十分に確保されたクラスタ 1 に該当する機械のデータを使って、(4.7)式により下部走行体の残存耐用時間を予測するモデルを作成する。学習モデルを作成するために、528 データ分(45 台)の故障データを使用する。

作成した残存耐用時間を予測するモデルに対し、検証データ(140 データ、12 台分)を入力した結果を Fig. 4.7 に示す。横軸に故障までの残存時間をとり、縦軸は検証データから予測した残存耐用時間を示す。なお、横軸と縦軸は共に 0[%]から 100[%]の間の値となるように正規化している。相関係数が 0.84 程度であり、また、グラフからもわかるように、実際の残存耐用時間を比較的高い精度で予測できている。

つぎに、基準時間に対する実際の残存時間と予測した残存耐用時間の差の比率を考える。例えば、故障の 20 日前における時点での比率のヒストグラムを Fig.4.8 に示す。横軸に 5[%] 間隔で差の比率の範囲をとり、棒グラフの縦軸には、範囲に該当するデータ数を示す。また、折れ線グラフは、横軸の差の比率の範囲が小さい方から順に該当データ数を累積して比率

で示したものである。グラフからわかるように 80[%]以上 の機械が基準時間に対して, -5[%]から+5[%]以内の誤差での予測が可能である。

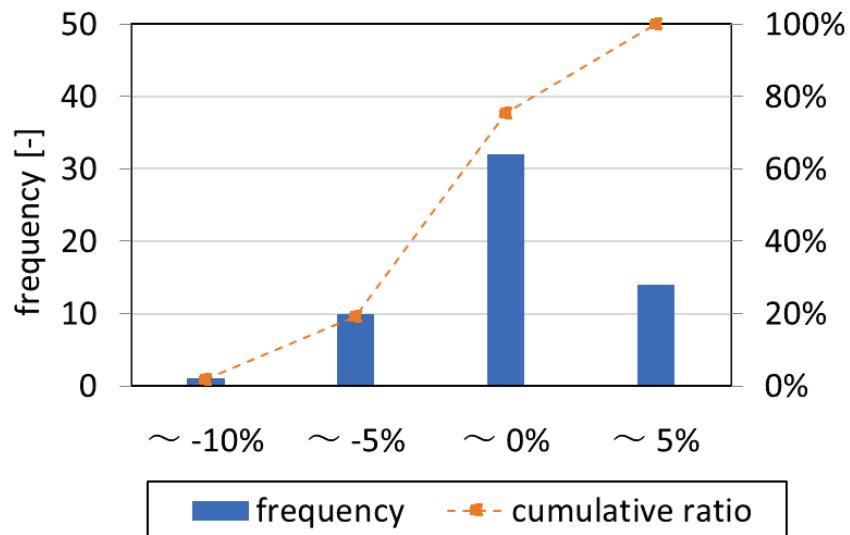


Fig. 4.8: Histogram of the difference between actual and predicted
(20 days before failure)

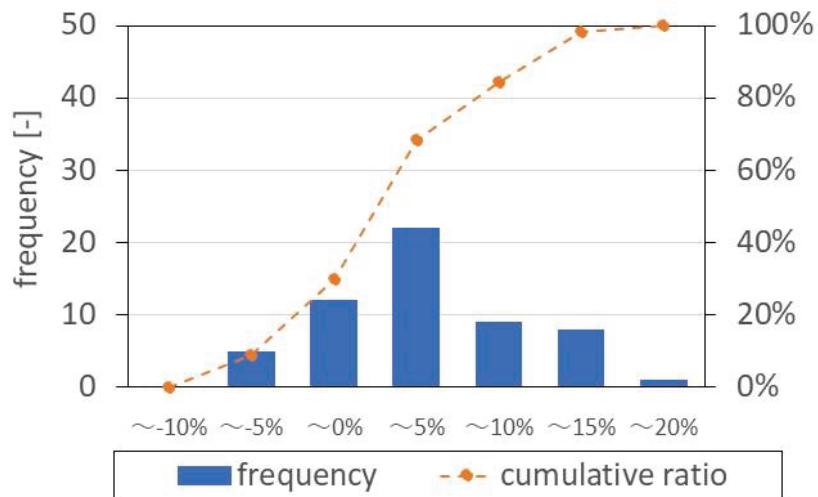


Fig. 4.9: Histogram of the difference between actual and predicted
(60 days before failure)

同様に故障の 60 日前における時点での比率のヒストグラムを Fig.4.9 に示す。基準時間に対して-5[%]から+5[%]以内の誤差で予測される機械は 60[%]程度であり、故障の 20 日前における時点よりも少ない。また、+5[%]から+20[%]以内の誤差で予測される機械が 30[%]程度見られる。したがって、故障までの日数が短い方が、残存耐用時間をより正確に予測できているといえる。

また、油圧ショベルの機械ごとにおける稼働状況の違いを k-Means クラスタリングにより分類する有効性を評価するため、クラスタに分けずに残存耐用時間の予測モデルを作成する。クラスタ 1 から 4 に該当する 828 データ分(65 台)の故障データを使用し予測モデルを作成する。作成した予測モデルに対して、クラスタ 1 の残存時間予測モデルを検証したデータを入力し評価する。

クラスタ 1 のときと同様に、実際の残存時間と予測残存時間を比較した結果を Fig.4.10 に示す。相関係数が 0.88 程度であり、クラスタ 1 と同等の精度で予測できているが、グラフを見ると予測残存時間が y 軸のプラス方向へオフセットしていることがわかる。

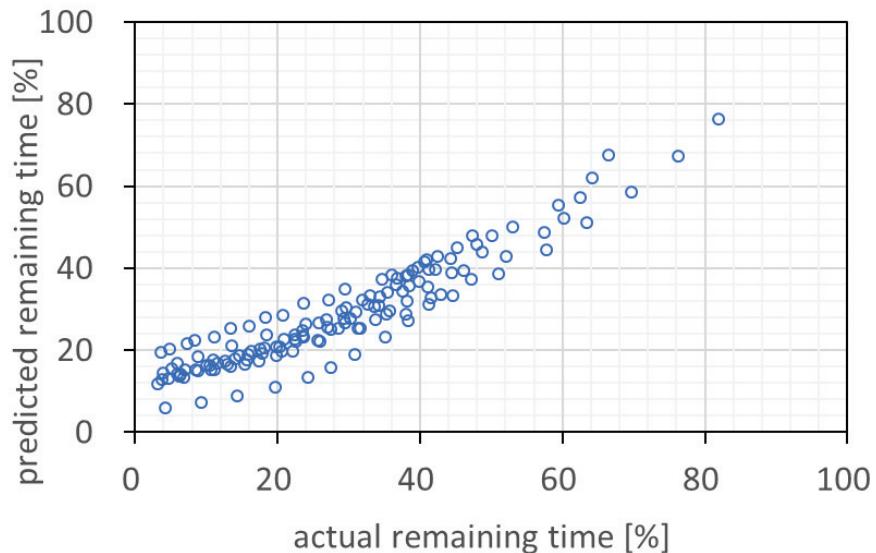


Fig. 4.10: Comparison of remaining time (all clusters)

Table 4.11 Comparison of mean and standard deviation

	average	standard deviation
cluster	-2.49	3.64
without cluster	-6.93	4.18

Table 4.11 に示すように、故障の 20 日前における時点での検証データで平均値と標準偏差を比較すると、クラスタ 1 を用いた予測モデルの方が、平均値が 0 に近くて標準偏差も小さいことがわかる。したがって、クラスタ 1 の予測モデルを使った方が少ないばらつきで評価できるため、機械ごとの稼働状況を考慮したクラスタリングは有効であるといえる。

4.5.3 考察

4.2 節で示した機械学習による故障発生有無の予測モデルと残存耐用時間を予測するモデルを用いた一例として、実際の油圧ショベルのアフターサービスにおける運用を例にとり、本手法を用いた予知保全活動の方法を提案する。Fig.4.11 に、提案する予知保全活動の方法をフローチャート図に示す。

まず、ニューラルネットワークなどの機械学習を使った故障発生の有無を予測するモデルに対して、未知データを入力し評価を行い、特定の故障が発生する可能性を判定する。この際、少ないノード数で構築したニューラルネットワークなどの汎化能力を持たせた予測モデルで評価を行う。これにより、誤検出が発生しても、故障発生の見逃しを少なくすることが可能となる。

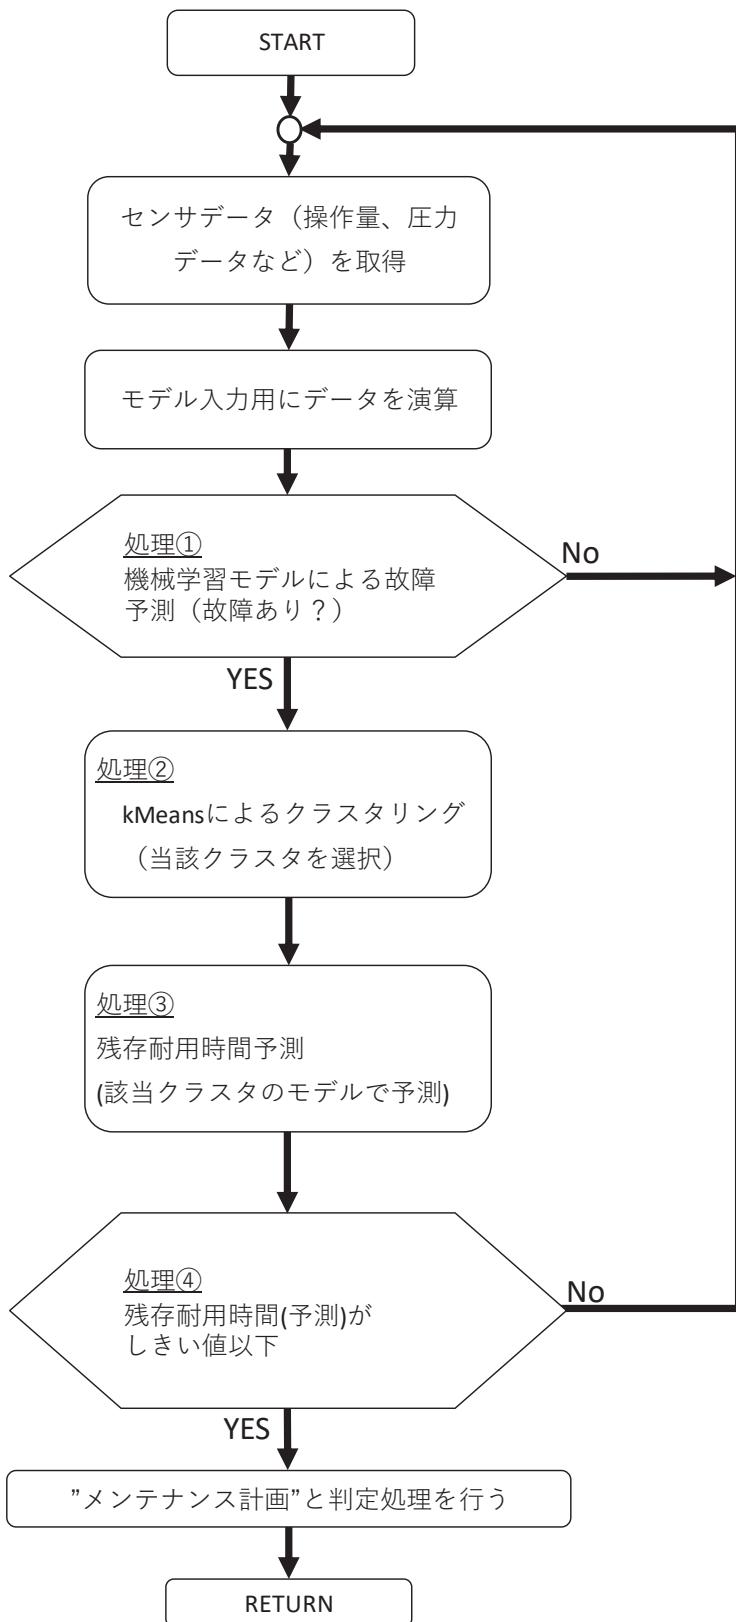


Fig. 4.11: Proposed predictive maintenance flow chart

故障と判断されるデータを事前に決めたクラスタのいずれかに分類する。その結果、機械の稼働状況による使われ方の違いが反映されていることが示される。クラスタ分類を行った後に、実際には、まだ故障に至っていない機械や誤検出の可能性がある。故障データが十分に含まれるクラスタであれば、残存耐用時間を予測するモデルを使って故障までの残存時間を予測できる。メンテナンスを行うために必要な準備期間（保守部品の手配、施工計画など）を考慮して、目標とする残存時間をしきい値として設定する。しきい値を下回ると予想される機械に対して、メンテナンス計画と実施を行う。

油圧ショベルのような建設機械の場合、数千から数万台の機械が市場で稼働している。これらの機械全てに対して、日々、残存耐用時間を予測し続けるには、膨大な計算量となる。したがって、このような提案手法を実施することで故障発生を予測し、対象機械を絞り込み、故障の疑いがある機械の稼働データから残存耐用時間を予測する。それにより、少ない計算量で効率的にメンテナンスが必要な機械を判定することが可能となる。

4.6 結言

本章では油圧ショベルの下部走行体を対象に故障が発生する前に、早期に故障の兆候を捉えて保全活動へ繋げる方法を提案した。稼働データからニューラルネットワークなどの機械学習モデルにより故障発生の有無を予測し、残存耐用時間を予測することで保全が必要な機械を判定する方法を示した。

データベースに大量に蓄積されたビッグデータを用いてニューラルネットワークなどの機械学習による故障予測モデルを構築することにより、油圧ショベルの下部走行体構造物に対して、故障前に予測が可能なモデルを作成した。今回用いた機械学習による故障予測モデルの中では DNN によるモデルが、隠れ層の 1 層目のノード数を 18 個、2 層目のノード数を 6 個、3 層目のノード数を 3 個にした場合において、再現率が最も高く、誤検出率も最も低かった。

油圧ショベルの残存耐用時間の予測において、故障データを k-Means クラスタリングにより使われ方ごとに分類を行い、故障データを十分に確保できているクラスタに対して予測モデルを作成することで、少ない誤差で残存時間を予測できることを示した。

また、これらの異常診断を行うモデルを用いて特定部位の故障発生、および故障までの残存耐用時間を予測する実際のアフターサービスを運用する上で有効な予知保全活動の一例を提案した。

第5章 結論

油圧ショベルなどの建設機械は、機械特有の高負荷・長期稼働などの使用環境や想定外の使われ方によって早期に故障することがある。このような故障を防ぐためには、メーカ推奨の定期点検をはじめとした時間計画保全だけでは困難である。さらに、施工計画通りに機械を運用するためには、アフターサービスや保全活動を行うことが欠かせない。予期しない突発的な機械故障や長期間の稼働停止は、施工計画の遅延や保全コストの損失に繋がる。そのような理由により、近年では IoT やセンサデータなどを活用した「状態基準型」の保全が行われており、故障に至る前に兆候を捉えて事前にメンテナンスを行えば、長期間にわたる作業停止を防ぐことができる。

本研究では、油圧ショベルの保全活動に対して機械のデータを入力とし、機械学習などの予測モデルを作成することで、油圧ショベルの故障前にその兆候を捉えて保全に繋げられないかと考えた。そのため、本研究では油圧ショベルの稼働中に得られるデータに基づいた故障の予測を目的とした。

そこで、まず油圧ショベルの掘削作業を対象として、稼働中の時系列データから故障を予測した。その中で、オートエンコーダによる故障予測方法と、畳み込みオートエンコーダ(CAE)を用いた操縦者の技量差異分析法を提案し、実際のデータに適用し有効性を検証した。次に、ポンプの故障を対象として、掘削作業の動作分類を利用して、特定状態の動作の作業データを抽出してモデルを作成することで、誤検知を抑制して故障を予測できることを示した。最後に、油圧ショベルの下部走行体を対象として、データベースに蓄積されている情報から機械学習による故障予測と、故障データのクラスタリングと残存耐用時間の予測を行うことで、効率的な故障予測が行えることを示した。以下に、本論文の各章に対する

概要と結論を総括する。

第 2 章では、油圧ショベルの掘削作業におけるオートエンコーダによる故障予測方法を提案した。一般的な故障予測方法は、事前に教師データとなる故障データが必要であるが、教師なし学習であるオートエンコーダにより、正常な状態の作業データを学習することで故障を予測する方法を用いた。また、このようなオートエンコーダを用いた方法は、油圧ショベルの操作影響により判定が誤検知となるという課題があった。それに対し、学習データの特徴のみを復元できる畳み込みオートエンコーダ(CAE)を用いて操縦者の技量差異分析法を提案した。この結果、まず、油圧ショベルの稼働中の時系列データを用いることによって、正常な状態のデータにより LSTM オートエンコーダモデルを学習することで異常を含んだ状態のデータでは再構成誤差が大きい値を示し、故障の予測ができる事を示した。つぎに、CAE を用いた掘削作業における技量差異分析手法を提案した。主成分分析と CAE を用いて、熟練操縦者の作業データを再構成した時の結果を比較すると、CAE では作業データの情報を損なうことなく特微量分布を獲得できることを確認した。さらに、一般操縦者の作業データを CAE で再構成させると、一般操縦者の特徴が熟練操縦者と異なる場合、CAE では復元できていないことを示した。また、一般操縦者が熟練操縦者の操作に近い場合は、再構成誤差が小さいことを確認した。

第 3 章では、掘削作業の特定動作に着目したポンプの故障予測方法を提案した。油圧ショベルの一般的な動作である掘削作業動作は「掘削」、「持上旋回」、「排土」、「復帰」、「待機」に分類される。これらの動作をセンサデータにもとづいて分類できるモデルを長期的な時間依存性を学習できるといわれる LSTM を用いて作成し、操作スキルの異なる「熟練操縦者」、「一般操縦者」、「非熟練操縦者」の作業データを分類し、さらに予測されたクラスの特徴と各動作の予測確率を比較した。また、機械特性に着目しアクチュエータの流量からポンプ流量を重回帰式により求められるモデルを作成し、ポンプの故障を予測した。油圧ショベル特有のシステムにより操作によって誤検知の可能性があるため、掘削作業の動作分類を

用いることで特定状態における動作に着目した故障予測モデルとした。この結果、まず、LSTM により掘削作業動作の分類モデルを作成し、5 つの動作を分類した。操縦スキルが異なる「熟練操縦者」、「一般操縦者」、「非熟練操縦者」の分類結果を比較すると、熟練操縦者と一般操縦者は周期的な動作をしていることがわかった。それに対し、非熟練操縦者は、他の操縦者と比べて分類精度が低く、不安定な操作や低い操縦スキルによる影響が見られた。つぎに、掘削作業動作から特定状態の動作を抽出することによって、ポンプの故障を予測する方法を提案した。掘削作業の動作分類により「持上旋回」や「排土」の作業データを抽出して、ポンプ流量の予測モデルを作成することで、ポンプの故障を予測できることを示した。

第 4 章では油圧ショベルの下部走行体の故障を予測する方法を提案した。機械の構造上、下部走行体には損傷具合を測定できるセンサが搭載されていないため上部旋回体に設置された既存のセンサから取得されたデータを用いた。データベースに蓄積されたバッチデータから機械学習による予測モデルを構築し下部走行体の故障を予測した。また、故障するまでの残存耐用時間も併せて予測した。油圧ショベルは、過酷な環境下で使われるが多く、機械ごとの稼働状況が異なるため、稼働状況が近い機械ごとに分類し、データを十分に確保できているクラスタに対して残存耐用時間を予測した。この結果、まず、故障前に予測が可能な機械学習モデルを作成した。今回用いた故障予測モデルの中では DNN によるモデルが、ほかのモデルを用いたときよりも再現率が最も高く、誤検出率も最も低かった。次に、油圧ショベルの下部走行体の残存耐用時間の予測において、k-Means クラスタリングにより事前に稼働状況ごとに分類を行った。さらに、十分にデータを確保できているクラスタに対して予測モデルを作成することで、残存耐用時間を少ない誤差で予測できることを示した。

本論文では、油圧ショベルを対象として、機械学習などの予測モデルを作成し、データを用いることで機械の故障を予測し、また動作分類や操作技量差異の分析方法を示した。これらの結果から、油圧ショベルの稼働データにより、機械的な故障を予測するとともに、油圧

ショベルの掘削作業動作を分類し、さらに異なる操縦者の操作技量を評価できることが本研究により示唆された。しかしながら、本論文では、油圧ショベルの特定の故障や限定的な動作に対する故障予測、動作分類、技量評価を実施しているのみであった。そのため、保全活動での実運用の想定や実際の作業現場での動きに応じた動作や操作に対しては、検証が行えていない。したがって、今後、それらは拡張していく必要がある。

最後に、油圧ショベルの故障予測に関する研究に対する今後の展望を述べる。冒頭の序論でも述べたように、建設現場での生産性向上が求められており機械の故障による長期間の稼働停止は、現場の生産性にダメージを与えることになる。そのため、建設機械の稼働を止めることができないようにデータを収集し、蓄積・管理できる統合データ基盤の開発が必要である。これらの開発において、大量のデータを集約できるシステムや様々な故障予測モデルを処理できる実行環境の構築などが求められる。このような開発を行うことは、建設業のみならず社会的にも大きな意義があると思われる。一方で、油圧ショベル製造メーカーとして、油圧ショベルを使って仕事をする人にとってメリットがあることが重要である。すなわち、油圧ショベルのソリューションを含めたユーザ価値の考慮が必要である。油圧ショベルを使って仕事をする人が享受する価値が増えることによって、ユーザの所属するコミュニティや社会に対しても新しい価値を与えることができるものと考える。また沢山のデータが集まり、それらが高度に処理されることで、建設業のみならず、様々な人々や社会にも大きな影響が与えられると考える。油圧ショベルを使って仕事をする人が生成するデータによって新たな価値を生み出していける社会となるために、データを中心とした社会基盤を構築していきたい。

参考文献

- [1] 国土交通省：「建設業を取り巻く現状について 参考資料」
<https://www.mlit.go.jp/kensei/sangyo/kensetsu/ninaite/ccus/1811shiryou3.pdf>,
(2022年11月21日)
- [2] 国土交通省：「建設業の働き方改革の現状と課題 令和3年11月」,
<https://www.kensetsu-kikin.or.jp/news>, (2022年11月21日)
- [3] 国土交通省：「i-Construction 『ICT技術の全面的な活用』の取り組みについて」,
<https://www.mlit.go.jp/common/001118343.pdf>, (2022年11月21日)
- [4] 国土交通省：「i-Construction 建設現場の生産性革命」,
<https://www.mlit.go.jp/common/001137123.pdf>, (2022年11月21日)
- [5] 国土交通省：「i-Construction の推進」,
<https://www.mlit.go.jp/common/001149595.pdf> , (2022年11月21日)
- [6] 中川 智廣, 小熊 尚太, 亀山 浩行, 中島 一, 友近 信行, 「機械稼働データを活用した予知保全の仕組の実現」, R&D 神戸製鋼技報, Vol.68, No.1, pp.69-73 (2018)
- [7] 切通 恵介, 泉谷 智範:「機械学習を用いた工場機器の故障予測」, 第9回データ工学と情報マネジメントに関するフォーラム(DEIM Forum 2017) (2017)
- [8] 森山 健, 前田 俊二, 鈴木 忠志:「センサーデータに基づく設備の異常検知及びその原因特定」, 電気学会論文誌 C, Vol.139, No.12, pp.1517-1526 (2019)
- [9] 渋谷 久恵, 前田 俊二:「運転パターン情報を用いた異常検知技術」, 電気学会論文誌 C, Vol.133, No.10, pp.1998-2006 (2013)
- [10] 渋谷 久恵, 前田 俊二:「高速局所部分空間法による異常検知技術」, 電気学会論文誌 C, Vol.134, No.5, pp.643-650 (2014)

- [11]朝日 翔太, 松井 彩華, 田村 哲嗣, 速水 悟, 井指 諒亮, 古川 輝, 内藤 孝昌:「再帰型オートエンコーダを用いた振動データによる工場設備の故障予測手法の提案」, 日本機械学会論文集, Vol.86, No.891 (2020)
- [12]朝日 翔太, 松井 彩華, 田村 哲嗣, 速水 悟, 井指 諒亮, 古川 載, 内藤 孝昌:「工場設備の故障予測における Autoencoder を用いた異常度算出手法の分析」, 電子情報通信学会論文誌 D, Vol.J104-D, No.4, pp.207-216 (2021)
- [13]K. Koiwai, Y. Liao, T. Yamamoto, T. Nanjo, Y. Yamazaki, Y. Fujimoto: "Feature Extraction for Excavator Operation Skill Using CMAC", Journal of Robotics and Mechatronics, Vol.28, No.5, pp.715-721 (2016)
- [14]境田 右軌, 中後 大輔, 川端 邦明, 嘉悦 早人, 深間 一:「熟練オペレータによる油圧ショベル操作の解析」, 第 23 回日本ロボット学会学術講演会 (2005)
- [15]小岩井 一茂, 今地 大武, 山本 透, 上田 浩司, 山崎 洋一郎:「機械学習を用いた油圧ショベルの掘削操作における特徴分析法の一提案」, システム制御情報学会論文誌, Vol.31, No.9, pp.328-335 (2018)
- [16]楳野 泰大, 小熊 尚太, 大野 修一, 岩崎 和宏:「深層学習を用いた掘削動作分類に基づく異なる操縦者の特徴の比較」, 電気学会研究会資料(制御研究会), pp.13-15 (2021)
- [17]金子 和樹, 中村 拓馬, 矢入 郁子, 平田 均:「OpenPose を用いたサッカーの熟練度の分類」, 第 34 回人工知能学会 (2020)
- [18]崔 雄, 高橋健太郎:「身体動作の特徴パラメータを用いた居合道の熟練度に関する定量化」, 武道学研究, Vol.45, No.1, pp.35-45 (2012)
- [19]三嶋 賢一, 金田 さやか, 中西 弘明, 堀口 由貴男, 楠木 哲夫:「特異値分解を用いた動作における個人間の類似と差異の抽出」, 第 52 回自動制御連合講演会 (2009)
- [20]A. van den Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, K. Kavukcuoglu: "Wavenet: A Generative Model for Raw

Audio”, arXiv:1609.03499 (2016)

[21]R. Chalapathy, S. Chawla: “Deep Learning for Anomaly Detection: A survey”, arXiv:1901.03407 (2019)

[22]入江 文平, 川人 光男:「多層パーセプトロンによる内部表現の獲得」, 電子情報通信学会論文誌 D, Vol.J73-D2, No.8, pp.1173-1178 (1990)

[23]巣籠 悠輔:「詳解 ディープラーニング TensorFlow/Keras・PyTorch による時系列データ処理 [第2版]」, マイナビ出版 (2019)

[24]S. Hochreiter, Y. Bengio, P. Frasconi, J. Schmidhuber: “Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies”, A Field Guide to Dynamical Recurrent Neural Networks, pp.1-15 (2001)

[25]S. Hochreiter, J. Schmidhuber: “Long Short-Term Memory”, Neural Computation 9, pp.1735-1780 (1997)

[26]曾我部 東馬:「Pythonによる異常検知」, オーム社 (2021)

[27]D. Kingma, B. Jimmy: “Adam: A Method for Stochastic Optimization”, arXiv:1412.6980 (2014)

[28]Y. Makino, S. Oguma, S. Ohno, K. Iwasaki: “Digging Motion Classification of Hydraulic Excavator by LSTM Using Time Series Data”, Annual Conference of Electronics, Information and Systems Society, IEEJ, pp.1353-1354 (2021)

[29]檍野 泰大, 小熊 尚太, 大野 修一, 岩崎 和宏:「深層学習を用いた油圧ショベルの掘削動作分類」, システム制御情報学会研究発表講演会講演論文集, Vol.65, pp.618-620 (2021)

[30]H. Imaji, K. Koiwai, T. Yamamoto, K. Ueda, Y. Yamazaki: “Human Skill Quantification for Excavator Operation using Random Forest”, Journal of Robotics, Networking and Artificial Life, Vol.4, No.3, pp.195-200 (2017)

- [31]R. Miyazaki, M. Akiyama, K. Koiwai, M. Kozui, K. Yamashita, T. Yamamoto: "Construction of a Skill Evaluation System Based on database-driven Approach for a Hydraulic Excavator", IEEJ Trans. on Electrical, and Electronic Engineering, Vol.16, No.10, pp.1390-1396 (2021)
- [32]S. Guo, J. Cui, Y. Zhao, Y. Wang, Y. Ma, W. Gao, G. Mao, S. Hong: "Machine learning-based operation skills assessment with vascular difficulty index for vascular intervention surgery", Medical & Biological Engineering & Computing, pp1707-1721 (2020)
- [33]内閣府：「Society5.0 とは」, https://www8.cao.go.jp/cstp/society5_0/society5_0.pdf, (2022年11月24日)
- [34]山田 直史, 高島 洋典, 木村 康則:「超スマート社会(Society5.0)実現に向けて CPS/IoT とその後」, Journal of Information Processing and Management, Vol.60, No.5, pp.325-334 (2017)
- [35]原 辰次, 本多 敏:「超スマート社会におけるシステム科学技術概論」, 計測と制御, Vol.55, No.4, pp.284-287 (2016)
- [36]袖子田 志保, 木村 麻衣, 鈴木 由宇, 近藤 智佳子:「データ解析による予防保全技術の開発」, IHI 技報, Vol.54, No.2, pp.26-31 (2014)
- [37]植木 洋輔, 雨川 洋章, 沼田 逸平, 山東 篤生, 中島 誠:「時系列計測データを活用したダメージ基準生存時間解析に基づく機器の寿命モデル化（化学プラント機器への適用の試み）」, 日本機械学会論文集, Vol.86, No.886 (2020)
- [38]K. G. Mehrotra, C. K. Mohan, H. M. Huang: "Anomaly Detection Principles and Algorithms", Springer (2017)
- [39]高木 英明:「サービスサイエンスの事訳」, 筑波大学出版会 (2017)

引用既発表論文

A. 学術雑誌等掲載論文

- [1] 小熊尚太, 大松繁, 大野修一, 岩崎和宏, 宮戸義昭 :「建設機械の稼働データを活用した残存耐用時間予測の一提案」, システム制御情報学会論文誌, Vol.34, No.4, pp.107-112, (2021)
- [2] 小熊尚太, 大松繁, 大野修一, 岩崎和宏 :「油圧ショベルの時系列データを用いた故障予知の研究」, システム制御情報学会論文誌, Vol.35, No.4, pp.84-92, 2022

B. 国際学会等講演論文

- [1] Shota Oguma, Yasuhiro Makino, Shuichi Ohno, Kazuhiro Iwasaki : “Feature Comparison of Different Operator Data of a Hydraulic Excavator using LSTM”, Proceedings of the 10th IIAE International Conference on Industrial Application Engineering 2022, pp.34-38, 2022

その他既発表論文

C. 学術雑誌等掲載論文

- [1] Shota Oguma, Shigeru Omatsu, Shuichi Ohno, Kazuhiro Iwasaki, Yoshiaki Shishido :
“Failure Prediction Based on Operational Data of Hydraulic Excavator with Machine
Learning”, IEEJ Transactions on Electrical and Electronic Engineering, Vol.16, No.10,
pp.1438-1440, 2021
- [2] 槇野泰大, 小熊尚太, 大野修一, 岩崎和宏:「油圧ショベルにおける畳み込みオートエン
コーダを用いた技量差異分析法の一提案」, 電気学会論文誌 C (電子・情報・システム部門
誌), Vol.143, No.3, (2023 年 3 月号採録決定)

謝辞

本研究の推進および本論文の作成は、多くの方々のご支援・ご助言を頂きながら進め、完成させることができました。ここに謝意を表すとともに、厚く御礼を申し上げます。

広島大学 大学院 先進理工系科学研究科 先進理工系科学専攻 山本 透 教授には、研究の推進ならびに論文作成にあたり、丁寧なご指導とご高配を賜りました。

また本論文をまとめるにあたり、有益なご助言と貴重なご意見を賜りました、広島大学 大学院 先進理工系科学研究科 先進理工系科学専攻 高橋 勝彦 教授、中野 浩嗣 教授に深く感謝いたします。

さらに、大阪公立大学 情報学研究科 大野 修一 教授には、本研究を進めるにあたり、様々なアドバイスやご指導をいただき、深く感謝いたします。

コベルコ建機株式会社 代表取締役社長 山本 明 氏、相談役 尾上 善則 氏、専務取締役 岩満 裕明 氏には、博士課程後期に進学する機会をいただき、このような研究を行う場を与えて頂いたことに深く感謝いたします。

コベルコ建機株式会社 顧問 辻井 剛 氏、ICT 推進部 部長 山崎 洋一郎 氏、同部 データ活用グループ グループ長 岩崎 和宏 氏には、小生が会社に所属したまま博士課程後期に進学し、研究活動に従事できる環境を提供いただくと共に、研究内容についても的確なご助言をいただき、心より感謝いたします。

末筆になりますが、コベルコ建機 夢源力共創研究所の皆様とは共に研究に励み、互いに励まし合いながら研究を進められたことをうれしく思うとともに、心から感謝いたします。