

学習データが限定された環境下における 汎用予測制御実現のためのアプローチ -汚泥乾燥機自動制御-

松山 蓮^{1,a)} 渡邊 真也^{†1,b)}

概要: 一般的に機械学習を実現する上で高品質で豊富な学習データは必要不可欠なものである。しかし、実問題においてそのようなデータを準備することは、導入・運用コストの面から難しい場合が少なくない。本研究ではこの問題に対応するため、過去のデータから操作量を予測する LSTM と、異常検知手法として有名なオートエンコーダ、そして専門知識に基づいて操作量を決定するエキスパートシステムを組み合わせた汎用制御手法を提案する。提案手法の有効性を検証するため、汚泥乾燥機システムに提案手法を適用し、検証実験を行った。

Approach for realizing general-purpose control in an environment where learning data is limited -control of sludge dryer machine-

Abstract: High-quality and rich learning data is indispensable for machine learning. However, it is very difficult to prepare such data in actual problems, due to the high installation and operational costs. Focusing on this problem, In this paper, we propose a general-purpose control method that combines an LSTM that predicts the operation from past data, an autoencoder that is famous as an anomaly detection method, and an expert system that determines the operation amount based on specialized knowledge. In this paper, we verify the effectiveness of this method by applying it to a sludge dryer system.

1. はじめに

下水処理場の処理過程や工場の廃液処理過程では、汚泥と呼ばれる水分を含んだ泥状の固体が排出される。一般にこの処理には、脱水や焼却などによって減量化後、最終処分が行われるが、多くのケースにおいては脱水処理を経た後であっても水分を多量に含んでいるため、焼却場への運搬費や処理費の観点から問題視されている [1]。そこで、脱水汚泥の水分を更に除去し、運搬や処理、資源化に優れた乾燥汚泥にするために使用されるのが汚泥乾燥機である。

しかし、汚泥乾燥機に投入される脱水汚泥の量や含水率

は様々な気象要因によって常に変動しており、乾燥汚泥の品質基準をクリアするためには、それらを上手く考慮しながら運転しなければ、汚泥の乾燥不足による余分な処理コストの増加や、乾燥超過による余分な燃料コストの増大という問題を招いてしまう。そのため、現在は運転員が汚泥の状態に合わせて汚泥乾燥機の操作を逐一決定している。月島機械(株)ではこのような作業による運転員への負担を軽減すべく、機械学習によって自動で汚泥乾燥機の操作を行うシステムの導入を検討している。

近年、こういった機械学習を企業システムに適用する研究は活発に行われており、目覚ましい発展を遂げている [2]。それに伴い、機械に学習させるためのデータの質と量は重要視され、新たに計測器を導入しデータの計測を始めている企業も多く存在する。

一方で、機械学習で高精度の予測を行う場合、膨大な量のデータが必要となるため、計測のためのコストや時間的

¹ 室蘭工業大学大学院
The Graduate School of Engineering, Muroran Institute of Technology

^{†1} 室蘭工業大学 しくみ解明系領域
Presently with College of Information and Systems, Muroran Institute of Technology

a) 20043053@mmm.muroran-it.ac.jp

b) sin@csse.muroran-it.ac.jp

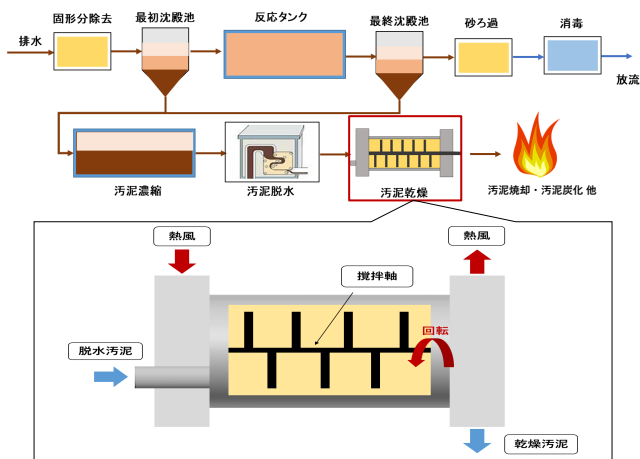


図 1 汚泥乾燥機概念図

制約から十分な量のデータを揃えることが困難な場合がある。そして、この問題は本研究にも当てはまることであり、それによって現状の一般的な過去履歴データに基づく機械学習手法では信頼できる自動制御を実現することが難しい。

そこで本研究では、学習データが限定された環境下における汎用的な制御手法として、過去履歴データに基づく機械学習手法に inputs が未知データか既知データなのかを判別するオートエンコーダ、未知データの場合に操作量を補正するエキスパートシステムを組み合わせた手法を提案する。

ここで未知データと既知データとは、過去履歴データの外挿入力と内挿入力を指す。一般に、ある過去データで構築したモデルに外挿入力を与えた場合、出力される結果の精度は著しく低下する一方、内挿入力を与えた場合は高い精度の結果が出力される。そこで提案手法では、この与えられる入力の特徴把握のため、その入力が過去データの外挿入力か内挿入力なのかをオートエンコーダを用いて判別し、入力が外挿入力として判別された場合、過去データとの異常(乖離)度合に応じて専門的知識による補正をモデルの予測結果に加えるというアプローチを用いた(本研究では本補正をエキスパートシステムと呼ぶ)。

一時的な予測を行うためのモデルには、時系列のデータを学習できるアルゴリズムとして知られている LSTM(Long Short-Term Memory)、過去データと入力データの差異を検出するモデルには異常検知手法として有名なオートエンコーダを利用し、具体的な対象である汚泥乾燥機に対し、本提案システムの検証実験及び分析を行った。

2. 関連研究

これまでにも、異常検知を活用して現実の制御性能向上に応用した研究が幾つか存在する。

吉澤ら [3] によると、代表的な異常検知技術の手法には、正常時のデータにおけるルールを学習して、そこから外れ

るものを異常とするルール学習、データの集合を似たデータ同士にグループ化して分類するクラスタリング、あらかじめ正常か異常かのラベルが付いたデータを学習し、未知のデータを分類するクラシフィケーション、正常時のデータから回帰式を構築し、その回帰式からの逸脱度合で異常を判別する回帰の 4 種類が存在すると述べられている。

矢入 [4] による研究では、過去の正常データからシステムの正常な挙動を表す統計モデルを作成し、入力データが異常かそうではないかの判別を行っている。この論文ではこれを人工衛星の状態監視に応用しており、人工衛星を稼働させながらもオンライン的な異常検知技術(データ駆動型異常検知)の提案をしている。ここでは検証期間中、稀な運用を前例のない挙動として検出したもの、運用者が事前に想定していなかった事象の計 2 回を異常イベントとして検出しており、結果として、異常判定の結果に対する運用者の経験と専門知識による最終判断が必要であると述べられている。

一方、陳山 [5] による研究では統計的分布であるワイブル分布を用いた機械の異常診断を行っている。この論文では異常検知の精度を向上させるために簡易診断と精密診断という 2 段階の検知を行っており、これによって異常を見逃すといった事故の予防手法について提案している。著者は簡易診断時に最も重要なことは振動信号の特徴を表す良好な特徴量の選択、および適切な状態判定基準の作成であると述べており、対象機械や設備に関する専門知識の重要性が主張されている。

上述のいずれの研究においても、異常検知技術の現場への適用にはそれぞれの対象機械や設備に関するドメイン知識、つまり対象分野の専門家をもつ分野固有の知識が必要だということが述べられており、異常検知システムが運用者の完全な代替になることは難しいことを指摘している。

本研究では、入力データを正常な学習データで構築したオートエンコーダに与えることで、その入力が過去に前例のないデータかそうではないかの判定を行う。

しかし、ここで判定される過去に前例のないデータについては、過去前例のない(学習データに存在しない)正常なデータと過去に前例のない異常なデータの 2 通りのケースが考えられる。そこで我々は、対象分野の専門家をもつ専門知識をエキスパートシステムとして活用することで、学習データの外挿部分の補完を図る。これにより、異常入力に対して専門知識からのフィードバックを反映させることができ、学習データが限定されている状況下にも対応可能な汎用制御を目指す。

3. 機械学習アルゴリズム

ここでは、本研究で使用する機械学習アルゴリズムについて概説する。

3.1 LSTM

LSTMはS.Hochreiter,J.Schmidhuber(1997)によって提案された,RNN(Recurrent Neural Network)の拡張として登場したアルゴリズムである[6].時系列データを学習する深層学習アルゴリズムとして有名なRNNでは,ニューラルネットワークの中間層の出力値を次のデータの入力とすることで学習を行っていた.しかし,学習するデータの時刻が増えていくことで中間層の深さが増大したため,順伝播型ニューラルネットワークと同じようになり,勾配消失や勾配爆発の問題が発生していた.

それらを解決するために改良を加えたものがLSTMであり,入力ゲート,出力ゲート,忘却ゲートを取り入れることによって情報の取捨選択が可能になり時系列データの学習精度が向上した.

入力と出力が可変長のデータを扱うことができ,RNNと同様に過去に計算した中間の記憶を保持することが可能であるため,時系列データのような複数点に及ぶ過去の情報を考慮する必要がある問題に対し連続的な予測を行うことができる.最大の特徴は従来のRNNでは学習できなかった長期依存を学習可能にしたということであり,RNNに比べてより長い時系列幅の入力に対応することが出来る.

3.2 オートエンコーダ

オートエンコーダ(AutoEncoder)はG.E.Hinton,et al.(2006)によって提案された,ニューラルネットワークの構造を使った次元圧縮のためのアルゴリズムである[7].三層ニューラルネットワークにおいて,入力データと教師ラベルに同じデータを用いて教師あり学習を行っており,基本的には入力を一旦圧縮し,再び復元するといったネットワーク構造を持つ.そのため,隠れ層の前後で入力データと出力データが一致するような重みの学習が行われており,オートエンコーダの前半部分(エンコーダ)を特徴抽出器,オートエンコーダの後半部分(デコーダ)を生成器として独立に利用することが出来る.また,入力と出力が一致するような学習を行うことから,学習データと入力データの特徴の違いを検出することができ,主に異常検知の分野で使用されている.

正常品のデータを学習したオートエンコーダに正常品のデータをを入力した場合,得られる出力データは正常品のデータとなる.一方,不正常品のデータをを入力した場合,学習データ中に不正常データの特徴が含まれていないことによって,不正常品の特徴を再現することができず,不正常箇所が除去されたような出力値が得られる.したがって,入力データと出力データの差分の大きさから学習データに存在しない不正常データを検知することが可能となる.

この考え方は画像データだけでなく時系列データといった数値データの場合にも応用でき,学習データとして正常波形のデータを学習させ,異常検知を行いたいデータを入

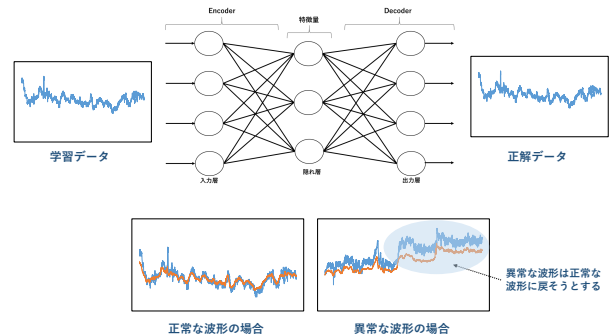


図2 オートエンコーダによる異常検知

力データとして与えることで,出力データと入力データの差分の大きさから学習データ上に存在しない異常が発生しているか否かを検知することができる(図.2).

4. エキスパートシステム

エキスパートシステムとは,ある分野の専門家の持つ知識をデータ化し,専門家のように演繹的な判断ができるようにするコンピュータシステムで,人工知能研究から生まれた応用分野の一つである.

エキスパートシステムでは,専門家の判断を「AならばBである」といったような単純な条件やルールに分解して表現される.専門知識をルールの集合として表すのは難しく,互いに矛盾するようなルールや例外が存在してしまう問題がある.しかし,すべての知識を活用するのではなく,一部を活用するだけならば,単純な条件やルールが設定できるため,調整や追加を簡単に行うことが出来る.

5. 提案手法

機械学習を行う上で高品質で豊富な学習データは必要不可欠なものとなっている.しかし,実問題においてそのようなデータを準備することは,導入・運用コストの面から非常に難しい場合が少なくない.この問題に対し,本論文では,限定された学習データから成るLSTMモデルに対し,入力データが学習データの外挿入力か否かの異常検知を行うオートエンコーダと,外挿入力の場合に演繹的に予測の補正を行うエキスパートシステムを組み合わせた汎用制御手法を提案する.

提案手法の流れとしては,まず過去の操作履歴データを教師データとしてモデル1を構築する.そして複数の入力パラメータをモデル1を通して分析することで,モデル1に沿って最適として推測された回転数を出力する.ここで,モデル1とは,LSTMの学習で更新および保存された重みを意味する.

続いて,モデル1の構築で使用した同様の過去の操作履歴データを教師データとした,次元圧縮と復元を行うモデル2を構築する.そして,モデル1に入力したデータをモ

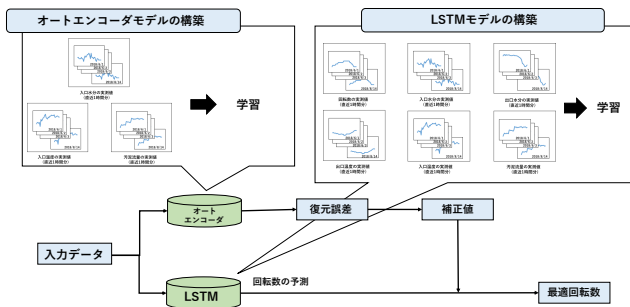


図 3 提案手法の流れ

表 1 モデル構築に使用したパラメータ

パラメータ	LSTM	オートエンコーダ
乾燥機入口温度	使用	使用
乾燥機出口温度	使用	×
入口汚泥含水率	使用	使用
出口汚泥含水率	使用	×
入口汚泥投入量	使用	使用
攪拌軸回転数	使用	×

デル 2 に通して分析することで、入力したデータと学習したデータの特徴の差異を検知する。これにより、入力データが外挿データに該当するのかを判断する。また、ここで挙げたモデル 2 とは、オートエンコーダの学習で更新および保存された重みを意味する。

そして最後に、提供していただいた回転数制御に関する専門知識を基に、モデル 2 において検出した特徴量の差異に応じて、モデル 1 で推測した回転数に補正を加える処理を行う。

以下、提案手法の流れを本研究で使用した本問題に特化したアルゴリズムの設定を交えて説明する。

5.1 予測の流れ

本論文において具体的な実験対象とした月島機械(株)の事例では、回転数を制御する際に 20 近くのパラメータから攪拌軸の回転数の操作量を決定している。また、実際の制御では回転数を決定する際には過去の回転数も判断の材料にされていることから、本研究では時系列データを学習するアルゴリズムである LSTM を用いて、多変量の入力に対応したモデルを作成した。

しかし、約 20 ものパラメータの中には、回転数への寄与率が極めて高いものからそれほど高くないものまでの複数が存在し、それらすべてを使用すると、計算負荷の増大から実用に足るモデルを作成することが難しいと推測された。そこで本研究では、これら 20 近くのパラメータの内、運転員が主に回転数操作の判断基準としている計 6 種類のパラメータをモデル構築に使用し、一時的な現在の回転数の予測を行う(表 1)。

LSTM では RNN 同様、再帰的な運用で計算を行うため、

次点を予測した結果をそのまま次の入力として使用することが可能である。しかし、モデルの精度が向上する前にこの方法を用いると、予測の精度は著しく低下するため、まずは教師データを用いてモデルの学習を行う。そして LSTM を始めとした時系列予測アルゴリズムにデータを学習させる上で最も重要になるのが、入力時系列の幅をどうするか、つまりいくつ前までのデータを予測に使いたいのである。入力時系列の幅の決定には主に、フーリエ解析などで計算した対象問題の周期を利用する方法と、対象問題の設定・特性に準じた幅にする 2 通りの決定方法が存在している。本問題では処理場に流れる汚水が日周期である約 48 点(24 時間)の傾向を持つことを考慮し、後者のケースで実験を行った。

また、学習に使用するデータは図.1 の計 6 種類のパラメータとなっており、構築するモデルは 6 入力 1 出力の多変量 LSTM モデルとなる。そのため、モデルに与えるデータの形式としては

$$\text{Input} = \left(\begin{pmatrix} x_1(t-47) \\ \vdots \\ x_1(t) \end{pmatrix} \cdots \begin{pmatrix} x_6(t-48) \\ \vdots \\ x_6(t-1) \end{pmatrix} \right) \quad (1)$$

となる。これが 1 回の予測を行う上で与える入力データの形式なり、学習及び検証する区間に応じて上述のデータセットを整形する。ただし、予測する対象は現在の回転数となるため、入力として与える回転数の timestep だけは 1 点繰り下がっている。

5.2 異常検知の流れ

LSTM では学習データに基づき、入力データに対しての予測を行う。そのため、予測精度は入力データが学習データの外挿入力か内挿入力であるかに大きく左右される。本処理ではこの点に着目し、オートエンコーダを使用することで入力データが学習データの外挿入力であるか内挿入力であるかを検知する。それと同時に、入力データが学習データとどのように異なっているか(上振れや下振れ)を判断することで、エキスパートシステムでの補正值決定に役立つ。

まずは、判別対象のデータであるテストデータで異常検知を行う前に、5.1 節の予測モデルに使用した学習用データでオートエンコーダのモデルを訓練する。ただし、オートエンコーダは内部で次元を圧縮後、再び復元処理を行うため、正解データには入力に使用したデータを設定する。

続いて、テストデータと学習データの特徴の違いを検出するため、オートエンコーダのモデルに対して予測モデルに入力したテストデータを与える。

この処理によって復元されたデータと入力したテストデータが一致している場合、テストデータは学習データの内挿入力であり、LSTM の予測は高精度で行えると言え

表 2 ヒアリングに基づいた専門的知識

パラメータ	増加時	減少時	信頼度
乾燥機入口温度	回転数を減らす	回転数を増やす	低
入口汚泥水分	回転数を増やす	回転数を減らす	高
入口汚泥投入量	回転数を増やす	回転数を減らす	中

る。一方、復元されたデータと入力したテストデータに異なる部分が存在している場合、テストデータは学習データの外挿入力であり、LSTM の予測は低精度であることが推測される。この特徴を活かし、復元データと入力データの差分を測定することで、学習データと入力に使用したテストデータの特徴の違いを顕在化させる。

また、本研究では先述のオートエンコーダの特徴 (図.2) より、下記の式 (2), (3) に示すように復元データには、学習データの特徴が反映される傾向があるとし、復元誤差の大きさから入力データと学習データの具体的な特徴の違いを読み取れると仮定した。

$$RE = \text{復元データ} - \text{入力データ} \quad (2)$$

$$\text{復元データ} \simeq \text{学習データ} \quad (3)$$

ここで挙げた具体的特徴とは、学習データが入力データに対して大きいのか小さいのかを意味し、RE が正の値であれば、学習データは入力データよりも上振れの傾向が強いデータ、RE が負の値であれば、学習データは入力データよりも下振れの傾向が強いデータであると判断する。このように、復元データと入力データの差分の大きさによってエキスパートシステムで補正を行う方向と大きさの目安とする。

5.3 補正の流れ

エキスパートシステムでは、5.2 節で求めた復元誤差 (Restoration Error, RE) とヒアリング結果に基づく専門知識 (表 2) を基に、LSTM で求めた予測回転数に補正を加える。

しかし、専門的知識 (表 2) のみでは、細かな回転数の大小操作が曖昧になってしまうため、補正幅を柔軟にコントロールすることが出来ない。そこで本研究では細かな補正の大小操作を行うために、得られた RE の大きさを以下の四段階に分けて補正を行う。

- 復元誤差が正方向に大きすぎているとき
- 復元誤差が正方向に少しずれているとき
- 復元誤差が負方向に少しずれているとき
- 復元誤差が負方向に大きすぎているとき

具体的な補正值には、対応する復元誤差の箇所それぞれ 10 点をパラメータごとにサンプリングし、それらの点で得られた LSTM における予測値と実測値の誤差値を平均して使用した。

ただし、複数パラメータでの補正を行う場合、それぞれ

表 3 実験データ

名称	内訳		
学習データ	2018/6/1	～	2018/8/14(2988 点)
検証データ	2018/8/26	～	2018/9/29(1357 点)
テストデータ [Case1]	2018/9/29	～	2018/10/30(1357 点)
テストデータ [Case2]	2018/12/26	～	2019/1/18(1122 点)
テストデータ [Case3]	2019/1/29	～	2019/2/28(1440 点)

のパラメータで回転数への寄与率が異なる。そのため、補正は同列には扱わず、ヒアリングデータの信頼度を補正值に乗算することで補正の重みづけを行った。本研究ではこれらの処理を検証データにおいて実行し、決定した補正值をテストデータに使用した。

6. 数値実験

本研究の有効性の検証のため、月島機械 (株) の汚泥乾燥機を使用するバイオコールドプラントサービス (株) において、提案システムを使用した場合と使用しなかった場合での汚泥乾燥機回転数の予測精度比較を行った。本章では実験設定と評価手法について説明した後、その実験結果と考察を示す。

6.1 実験設定

実験にはバイオコールドプラントサービス (株) から頂いた、汚泥乾燥機の運転データを使用する。データには学習データ、検証データ、テストデータ [Case1] から [Case3] までの計 5 種類が存在し、それぞれ内訳が異なるデータとなっている。本研究では、学習データをモデルの訓練、検証データをエキスパートシステムでの補正值の決定に使用し、Case1 から Case3 までのそれぞれのテストデータに本提案手法を適用した。そして、その時の稼働結果を一般的な機械制御手法 (LSTM) での稼働結果と比較することで、本手法の性能を評価する。また、実験データの詳細は表 3 の通りである。

6.2 評価手法

本実験における評価手法は以下の通りである。

- 平均絶対パーセント誤差 (Mean Absolute Percentage Error, MAPE)

求めた回転数データと、正解データ (運転員が実際に設定した値) のズレの絶対パーセント誤差の平均値から算出する。大きな誤差も小さな誤差も平等に扱うので、外れ値の値にあまり左右されない全体的な誤差が分かり、値が小さいほど精度が良いことを示す。

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{f_i - y_i}{f_i} \right| \quad (4)$$

上式における $f_1 \dots f_n$ は実測値、 $y_1 \dots y_n$ は予測値、 n は予測値の数を表す。

- 平均二乗偏差 (Root Mean Square Error, RMSE)

表 4 MAPE

	LSTM 単独	提案システム
Case1	5.18	3.66
Case2	11.94	8.27
Case3	10.55	8.25

表 5 RMSE

	LSTM 単独	提案システム
Case1	5.40	3.83
Case2	11.2	7.97
Case3	10.7	8.59

求めた回転数データと、正解データのズレの二乗の総和の平均値の平方根から算出される。ズレを2乗するため大きな誤差が含まれるほど値が大きくなり、外れ値が含まれていると値が著しく大きくなる。値が小さいほど精度が良いことを示す。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (5)$$

上式中の $f_1 \dots f_n$ は実測値、 $y_1 \dots y_n$ は予測値、 n は予測値の数を表す。

6.3 実験結果と考察

表 4, 表 5 に今回行った実験結果の評価値を示す。3種類のテストデータを用いて実験を行ったところ、LSTMでの精度は MAPE, RMSE 共に芳しくないことが分かる。このような結果が得られた原因として学習データがテストデータの特徴を網羅できていないことが考えられる。その理由として本実験で使用したデータは、学習データが6~8月であることに対して、Case1は9~10月、Case2は12~1月、Case3は1~2月のデータとなっている。そのため、季節的な要因による特徴の変動を捉えることができず、時期が異なるほど精度が低下していると推察される。

一方、提案システムでの精度はいずれのテストデータの場合においても LSTM 単独の場合より精度が向上したことが分かる。しかしながら、補正を行ったにも関わらず、学習データとテストデータの時期が異なるごとに MAPE の値が大きくなっており、RMSE もほぼ同様に増加している。そのため、この結果は一部の大きなズレによって引き起こされた事象ではなく、全体的にズレた結果によるものと推察される。その原因として、現在は主に、補正值定量化の判断基準に使用した検証データとそれぞれのテストデータにおける特徴の違いが大きいためと推察されている。検証データとそれぞれのテストデータの時期を見ると、検証データは8~9月のデータとなっており、学習データとはほぼ同時期にある。一方、Case1は9~10月、Case2は12~1月、Case3は1~2月となっており、検証データとは時期が大きく異なっている。

したがって、検証データに基づいて決定した補正值が検証データと時期が異なるほど、適切な補正量ではなくな

り、誤差が発生していると推察される。そのため、現在の補正システムがまだ不十分であることが考えられ、より詳細な補正ルールや重みの大きさを熟考する余地があると思われる。

7. おわりに

本論文では、限られた学習データからの汎用的な制御を実現するため、時系列のデータを学習できるアルゴリズムとして知られている LSTM, 入力データと学習データの差異を検出するオートエンコーダ、専門知識に基づいた補正制御を行うエキスパートシステムを組み合わせた新たなアプローチを提案し、汚泥乾燥機における攪拌軸制御という具体的な応用問題に対してその効果を検証した。

検証から、LSTM 単独での精度に比べて、精度を向上させることを確認することが出来た。しかし、データによっては誤差の大きさは依然高いままであり、エキスパートシステムによって完全に誤差をなくす事は出来なかった。

今後の課題は、システムの完成度を向上させ、より運転員の設定した回転数に近づけることである。具体的には、エキスパートシステムによる補正を行う際にそれぞれのパラメータに対し、復元誤差の値から異常値と判断するための閾値、目的パラメータへの寄与率度合による補正の重みを設けることでルールを詳細に設定することが挙げられる。

謝辞 本研究の遂行にあたり、月島機械(株)からシステム構築に関する助言を頂きましたこと、また、運転データおよび現行制御手法についてバイオコルプラントサービス(株)からご提供頂きましたことに、深謝します。

参考文献

- [1] 奥井正儀, 白髭成義, 飯田雄巳, 高橋正昭: 下水汚泥の乾燥処理による資源化, 廃棄物学会研究発表会講演論文集 第18回 廃棄物学会研究発表会, pp.115 (2007).
- [2] 久保隆宏: 第一人者が解説する テクノロジー最前線 活用が進む「機械学習」企業システムにも適用広がる ライブラリの利用で容易に実装可, 日経 systems, No.262, pp.54-59 (2015).
- [3] 吉澤亜耶, 橋本洋一: 異常検知技術の概要と応用動向について, 技術情報誌 (ITJ) 第17号, pp.42-47 (2016).
- [4] 矢入健久: 衛星の状態監視システムのつくりかた -過去のデータに基づく異常検知-, 情報処理, Vol.56, No.8 (Aug 2015).
- [5] 陳山鵬: 機械設備の異常検知と状態判定基準について (異常検知と変化点検出), REAJ 誌, Vol.37, No.3 (2015).
- [6] Goodfellow, I., Bengio, Y. and Courville, A. (著), 岩澤有祐, 鈴木雅大, 中山浩太郎, 松尾豊 (監訳): DEEP LEARNING 深層学習, 株式会社ドワンゴ (2018).
- [7] 一般社団法人 広島県中小企業診断協会: IOT センサーデータの分析, ニューロビジネス研究会 (2018).