

## 建設機械の稼動モード認識による異常検知

### Detection of abnormal operation in construction machines by use of operation modes recognition

小松孝二\*, 清田雄彦\*\*, バチコフガンチョ\*\*\*, 木村信行\*\*\*\*

Koji KOMATSU, Yuhiko KIYOTA, Gancho VACHKOV and Nobuyuki KIMURA

\*博(学), 香川大学助手, 工学部メンテナンス工学講座 (〒761-0396 香川県高松市林町 2217-20)

\*\*博(エネルギー科学), 香川大学客員教授, 工学部メンテナンス工学講座 (香川県高松市林町 2217-20)

\*\*\*Ph.D, 香川大学客員教授, 工学部信頼性情報システム工学科 (香川県高松市林町 2217-20)

\*\*\*\*工修, 四国機器株式会社 (香川県高松市観光町 2-2-15)

In this paper a new algorithm for classification and real-time recognition of different (preliminary assumed) operating modes for construction machines is proposed. This algorithm utilizes the effectiveness of the Self-Organizing Maps (SOM) for creating the so called Separation Models, that are able to distinguish each operation mode separately. After training, these models are used in a real-time procedure, which calculates at each sampling time the minimal Euclidean distances from the current data point to a certain node of each SOM. The Separation Model (SOM) that has produced the least minimal distance determines the number (class) of the operating mode.

Simulation results and consequent analysis, based on experimental data from a hydraulic excavator have shown that the proposed algorithm clearly leads to a higher percentage of true recognitions.

*Keywords: Abnormal Detection, Operating Modes, Self-Organizing Map, Construction Machines*

キーワード: 異常検知, 稼動モード, 自己組織化マップ, 建設機械

## 1. まえがき

近年, 建設施工においてコスト削減および工期短縮による効率化を図るために情報化技術を応用した施工が重要になってきている. このような建設施工の高度化にともない, 建設機械の信頼性を向上し高い稼動率を実現することが求められている<sup>1)</sup>.

建設機械の稼動率を向上させるためには, 対象機械の異常の兆候を早期に発見し, 安定的な稼動を提供する健全度判定の概念が重要である. 健全度判定とは, 劣化や性能を診断するために対象機械の稼動状態に関する情報信号をセンサより得て, 信号処理により健全度を予測するものである<sup>2)</sup>.

一般的に建設機械は, 現場で使用され不定期に移動し, 地理的に離れた場所で稼動することが多いため機械の健全度を把握することは容易ではない. したがって, IT 技術を活用して通信により稼動信号を取得し, この信号を推論により解析して異常の判定を行うことで, 効率的なメンテナンスの実施を可能とする健全度判定技術が必要である. しかし, 建設機械の稼動は, 定常状態の運転ではなく絶えず変化するので, こうした機械の状態を解析

し劣化の予兆を検知するためには運転性能, すなわち, 全ての稼動状態を正確に識別し, その特性変化を評価しなければならない.

そこで本研究は, 建設機械の予知保全システム構築を念頭において, 機械の稼動状態を高精度で識別するために, クラス分けのアルゴリズムである自己組織化マップ (Self-Organizing Map: SOM<sup>3,4)</sup> (以下, SOM) の学習法を応用することで健全度を判定し, 対象機械に異常が生じた場合は稼動状態の識別レベルで異常の兆候を検知するシステムを構築した. なお, 建設機械にはいくつかの種類があるが, 油圧ショベルは建設現場で最も多く稼動しており, 出荷台数も全体の 70% を超えていることから, ここでは油圧ショベルを対象に研究をすすめた.

## 2. 対象機械

油圧ショベルは, 図 1 に示すようにエンジンにより 2 個の油圧ポンプ (A,B) を駆動し, その油圧で旋回モータ, 走行モータ, 油圧シリンダを作動させている. したがって, エンジンおよび油圧ポンプは油圧ショベルの主要なコンポーネントであるので, これらを対象に異常の




図1 油圧ショベルのシステム構成

兆候を予測することとし、エンジン回転数、ブースト圧力（過給後の吸気圧力）、油圧ポンプ A の吐出圧力、油圧ポンプ B の吐出圧力を 1 秒毎に計測した。この計測データは、油圧ショベルに搭載した信号取得装置に収録し、解析に供した。

なお、本論文ではこれら 4 つの計測信号を総称してパラメータと呼ぶこととする。

### 3. 分離モデルの導入

本研究では、油圧ショベルの稼働状態を下記の 4 つの稼働モードに分け、計測したデータがどの稼働モードに該当するかを SOM の手法により識別し、どの稼働モードにも該当しないケースが増加したときに異常の兆候があると判断するアルゴリズムを構築した。

- ・稼働モード 1：バケットで土砂をすくい始めてからすくい終わるまでの動作（土砂掘削）。
- ・稼働モード 2：土砂をすくった後、車体を旋回してトラック荷台上方まで移送する動作（土砂移送）。
- ・稼働モード 3：土砂を荷台上へ積込むために、バケットを開き土砂積載完了までの動作（土砂積載）。
- ・稼働モード 4：バケットを堆積した土砂の位置まで戻し稼働モード 1 に入るまでの動作（リターン）。

稼働モードを識別する過程で用いた SOM は優れた分類能力を有する。SOM とは、コホーネンにより提案された教師なし学習アルゴリズムのひとつであり、入力層と競合層からなる 2 層構造ネットワークで構成されている。SOM は、入力層の多次元データのみを用いて空間における相互関係をニューロンとして競合層に写像するものであり、勝者ニューロンだけでなくその近傍のニューロンも学習することの特徴としている。

近年では、SOM アルゴリズムを改良してより高い分類能力が得られるような理論的研究が行われている。同時に応用研究も行われてきており、例えば、斜面崩壊の予

測において斜面データの分類に SOM を用い、崩土到達距離の予測に BP 法（誤差逆伝播法）を用いるという、2 つの異なるニューラルネットワークを適用して予測精度を向上させている研究がある<sup>5)</sup>。また、変電所の制御において SOM により電圧などを予測してファジィ推論ルールのチューニングを行っている研究もある<sup>6)</sup>。このように、SOM の高い分類能力を目的に応じて複合的に組み合わせて SOM を実際の問題解決に適用している。

本研究では、稼働モードごとに SOM を作成し、作成した SOM は、ある稼働モードの多次元データ群で構成された稼働データを学習する。この学習により得られたニューロンは、データ群の多次元空間における分布と密度を代表することから、これらニューロンで構成された SOM と入力データの類似度により稼働モードを明確に識別できると考えられる。稼働モードと同数の学習済み SOM モデルを統合したものを、ここでは分離モデルと呼ぶ。このようにすることで、稼働モードの分類に高い識別率を得ることが可能になる。

本アルゴリズムは、教師なしアルゴリズムである SOM の学習法の活用により、稼働モードと同数の SOM を作成し学習することで、実稼働データに対して教師あり学習のように予測することが可能となると考えられる。このように、実稼働データを予め設定した稼働モードにリアルタイムに識別し、異常の兆候を検知する手法は健全度の判定に有効であると判断した<sup>7,8)</sup>。

## 4. システムの構築

### 4. 1 分離モデルの構築

一般の SOM は、入力データを任意のクラスに分類するため、ひとつ（単独）の SOM モデルを用いて多次元入力に対して学習を行い、2 次元の競合層で視覚的に表現するものである。

しかし、油圧ショベルの稼働モードは各モード間のデータ構造が類似しているため、単独モデルを用いて 2 次元空間上に複数の稼働モードの特徴を代表させ、正確に各モードを識別することは難しい。図 2 は、稼働モード 1～4 の繰り返しに対して取得したエンジン回転数と油圧ポンプ A 吐出圧力を示すもので、単に稼働データを時系列でみるだけでは機械の動的挙動、すなわち、現在どの稼働モードに該当するかを識別することはできない。

つぎに、各稼働モードに対しパラメータのデータ分布をみることにした。図 3 はその一例であり、稼働モードの特徴をよく表すパラメータとして、エンジン回転数、ブースト圧力を選び 2 次元平面状にプロットした。各稼働モードの特徴として、稼働モード 1 は中ブースト圧力側に高い密度を示す中負荷運転、稼働モード 2 は高ブースト圧力側に高い密度を示す高負荷運転、稼働モード 3 は低ブースト側に高い密度を示す低負荷運転であり、稼働モード 4 は全般に広く分布しており高い密度の領域はない。このように、各稼働モード間におけるデータ点の




図2 各稼働モードに対する実稼働データ例

分布と密度にそれぞれ特徴はあるものの、かなりの部分でデータ点がオーバーラップしていることから、一般的に用いられる単独モデルの SOM を用いて全稼働モードに対し高い識別性能を得ることは困難であると考えられる。

そこで本研究は、このような類似度の高いデータを高精度で識別できる分離モデルのアルゴリズムを構築し、稼働データから現在の稼働モードを識別する手法を考案した。本分離モデルは、リアルタイムに取得するデータと各 SOM モデルの類似度により稼働モードを分類することから、学習時の多次元入力データを低次元の競合層において視覚化する必要がないという利点を有する。

また、稼働モードを追加したい場合は、これまでの単独モデルによる学習では、全稼働モードを最初から学習する必要があるが、分離モデルを用いた本アルゴリズムでは新たに稼働モードに対応する SOM モデルを部分的に追加し、学習するだけでよいという利点もある。

## 4. 2 解析手法

本研究で構築した稼働モード識別のための処理プロセスを図4に示す。本システムは、下記に示すオフライン学習とリアルタイム解析の2つのステップから構成されている。以下に、本システムの解析手順の概要を示す。

### <オフライン学習>

予め取得した（既知）データ群を用いて各稼働モードに対し学習を行うステップである。

- ①稼働データ取得と同期：データ取得と同時にビデオ撮影を行い、それぞれの生データに対して稼働モードをラベリングする。
- ②最適 SOM 学習：上記で同期させたデータを稼働モードごとに複数の SOM を作成し、この中か




図3 全稼働モードに対する稼働データの分布

ら最適 SOM を求める。

- ③最適分離モデル作成：上記で求めた各稼働モードの最適 SOM を用い、これを統合して最適分離モデルを作成する。

### <リアルタイム解析>

実稼働（未知）データ群を用いて各稼働モードをリアルタイムで判定するステップである。

- ④類似度の計算：実稼働データを取得し、当該データと作成した分離モデルを構成する各最適 SOM との類似度を求める。
- ⑤稼働モードの判定：最も類似した SOM を当該データの稼働モードとし、いずれのモードにも類似しないものは未知のモードあるいは異常稼働モードと判定する。

### (1)オフライン学習ステップ

まず、各クラス（稼働モード） $C_1, C_2, \dots, C_z$  に対応した SOM, すなわち  $SOM_1, SOM_2, \dots, SOM_z$  を作成する。本研究は稼働モードを4つに分類しているため、4個の SOM を持っている。これを稼働モードと同期させた既知データ群を用いて稼働モードごとに学習パラメータを変更して複数学習させることで、各稼働モードは複数の候補 SOM を持つ。

次に、稼働モード毎に作成した複数の候補 SOM に対し最適に学習された SOM を求める。この最適学習の基準として、ニューロンとデータの空間上の分布状態についてユークリッド距離（以下、距離）を用いて平均最小距離および全ての最小距離の標準偏差を求める。




図4 取得データの識別プロセス図

すなわち、ある稼動モードについて最小距離  $MD(i)$ ,  $i=1,2,\dots, TD$  は、 $i$  番目のデータ点と SOM 空間内の各ニューロン間の距離の最小値と定義し、この最小距離となった  $j$  番目のニューロンの距離を次式により求める。

$$MD(i) = \min_{1 \leq j \leq n} \{r(i, j)\}, i = 1, 2, \dots, TD \quad (1)$$

ここに、 $r(i, j)$  は、 $i$  番目のデータ点と  $j$  番目のニューロン間の距離を示す。なお、 $TD$  は学習データ数を表す。

この最小距離  $MD(i)$  を用いて、平均最小距離  $AV_{min}$  を次式により求める。

$$AV_{min} = \frac{1}{TD} \sum_{i=1}^{TD} MD(i) \quad (2)$$

最小距離  $MD(i)$ ,  $i=1,2,\dots,TD$  の全てに対する標準偏差  $STdev$  は、学習した  $n$  個のニューロンで構成された SOM 学習の良否を決定づけるもうひとつの要素であり、次式により求める。

$$STdev = \sqrt{\frac{1}{n-1} \sum_{i=1}^{TD} [MD(i) - AV_{min}]^2} \quad (3)$$

このようにして、作成した複数の候補 SOM に対して求めた平均最小距離  $AV_{min}$  と標準偏差  $STdev$  のうち、最小の  $AV_{min}$  と  $STdev$  を持つ候補 SOM を最適 SOM と呼ぶ。この手順を全ての稼動モードの候補 SOM に対し、式(1)から式(3)を用いて同様に求める。

ここで、先に示した最小距離  $MD$  は、学習データ点がいずれのニューロンに対して最も類似しているかを求めるステップであるが、この過程で一度も最小距離として




図5 アイドリングニューロンの選定例

選択されないニューロン、すなわちアイドリングニューロンが発生することがある。このニューロンは、学習データ点を代表しないことから必要のないニューロンとしてラベリングし、学習後に削除する<sup>9)</sup>。これら一連のステップ終了後、学習済みの SOM は固定される。

この学習データ点とニューロンの関係を概念的に表したものが図5である。図中には10個の学習データ点と7個のニューロンが存在し、全ての学習データはいずれかのニューロンに該当している。しかし、ニューロン  $n3$  と  $n7$  は、どの学習データ点に対しても勝者ニューロンになり得なかったニューロンであるため削除される。

上記の学習によって求めた各稼動モードにおける複数

の候補 SOM のうち、最小の  $AV_{min}$  と  $STdev$  をもつニューロンで構成された候補 SOM を当該稼働モードの最適 SOM と定義する。同様の手順で全稼働モードの最適 SOM を計算し、この最適 SOM ( $SOM1, SOM2, \dots, SOMz$ ) を統合して最適分離モデルとする。

## (2)リアルタイム解析ステップ

オフライン学習ステップで得た最適分離モデルを用いて、リアルタイムに取得するデータをサンプリングごとに各稼働モードに識別し稼働モードの判定を行う。

まず、現サンプリングのデータと各 SOM のニューロン間の距離を求め類似度  $SD(k)$  とする。この  $SD(k)$  を先に求めた  $AV_{min}$  を用いて次式により相対距離  $RD(k)$  とし、現データの稼働モード決定に使う。この計算は、分離モデルを構成する全 SOM に対して行ない、 $RD(k)$  が 1 に最も近い SOM が当該データに対する稼働モードとなる。

$$RD(k) = SD(k) / AV_{min} \quad (4)$$

ここで求めた  $RD(k)$  が  $RD(k) > 1 + \delta$  ( $\delta$  は閾値) であれば入力データは既知の稼働モードのいずれにも該当しないことを示し、その稼働モードは未知もしくは異常稼働モードとする。また、 $RD(k)$  が  $RD(k) < 1 + \delta$  の場合は、稼働モードの候補が複数存在することを示し、この候補稼働モードについて距離を基準にして可能性の高い順番に並べることにする。

## 5. 解析結果

油圧ショベルの実稼働データを取得して本アルゴリズムを用いてオフライン学習による分離モデルを作成し、リアルタイム解析による稼働モード識別について解析を行った。

### 5.1 オフライン学習

#### (1)稼働データ取得と稼働モードの同期

学習に使用するデータは、取得データと各稼働モードを明確に対応させる必要があるため、ビデオ撮影を行って4つのパラメータで構成される取得データに各稼働モードをラベリングして、同期したものを学習データとして用いた。

分類した稼働モードは、既に述べた稼働モード1：土砂掘削、同2：土砂移送、同3：土砂積載、同4：リタンの4つである。解析に使用する学習用（既知）データは1448データであり、このデータ群は正常な稼働データのみを用いた。

#### (2)最適分離モデルの作成

油圧ショベルの実稼働データを取得して、稼働モード識別を行うためには、同期させた各稼働モードに対応するデータ群から候補 SOM を複数作成し、最適な SOM を選定した。各稼働モードの候補 SOM から最適 SOM を求

表1 各稼働モードにおける最適 SOM の学習パラメータ

| 稼働モード | データ数 | N   |     | $\alpha$ | W   | T    | 距離         |        |
|-------|------|-----|-----|----------|-----|------|------------|--------|
|       |      | 初期  | 学習後 |          |     |      | $AV_{min}$ | STdev  |
| 1     | 227  | 81  | 78  | 0.5      | 1.1 | 1000 | 0.0451     | 0.0258 |
| 2     | 557  | 141 | 141 | 0.6      | 1.1 | 500  | 0.0482     | 0.0281 |
| 3     | 346  | 81  | 80  | 0.3      | 1.1 | 500  | 0.0511     | 0.0316 |
| 4     | 318  | 121 | 115 | 0.5      | 1.1 | 500  | 0.0489     | 0.0273 |

めたものを表1に示す。

最適 SOM を求めるために変更した学習パラメータは、ニューロン数 N、学習率  $\alpha$ 、近傍領域 W、学習回数 T であり、学習後のニューロン数が初期ニューロンより少ないのは、アイドリングニューロンを削除したためである。この学習パラメータを変更して複数の候補 SOM を作成し、最終的に最小の  $AV_{min}$  と  $STdev$  をもつ各稼働モードの候補 SOM を最適 SOM として選択し、この最適 SOM を統合したものが最適分離モデルとなる。この最適分離モデルを用いてリアルタイムデータとの類似度を求めることで分類が可能である。

最適 SOM の学習結果の一例として、稼働モード2について学習データ点に対するニューロンの配置を図6に示す。実際には4パラメータで学習しているので4次元空間にニューロンが配置されているが視覚化のため、2次元パラメータで示した。

この図では2次元空間上に展開しているが、実際には多次元データ群と同次元のニューロンで代表させるため、どのパラメータ間の比較についても、学習データ点に対してニューロンが学習データ点の分布と密度を代表している。稼働モード2は、土砂を移送する最も高負荷運転のモードであり、各油圧シリンダ、旋回モータを同時に作動させていることから高いブースト圧力と油圧ポンプ吐出圧力を示している。

本アルゴリズムは SOM の競合・近傍学習を応用しているが、通常の SOM のように2次元の格子状平面に視覚化することは行わず、入力データのパラメータ数と同次元の空間上にニューロンを配置して、多次元空間上で生データの特性をニューロンに代表させることが特徴である。

各稼働モードにおいて最適 SOM となったニューロンの分布を図7に示す。この図は、前に示した図3のデータ点に対しニューロンを配置したものである。視覚化のためエンジン回転数とブースト圧力を比較した。これにより、ニューロンが学習によりデータの分布と密度をうまく捉えていることがわかる。

各稼働モードの特徴として、稼働モード1は土砂掘削であり、エンジン回転数が中高回転で中ブースト圧力の傾向を示しており中負荷作業である。稼働モード2は土砂移送であり、エンジン回転数が低くブースト圧力が高




図6 稼働モード2に対する学習データと勝者ニューロンの分布

いところにニューロンが集中していることから高負荷運転である。稼働モード3は土砂積載であり、エンジン回転数が高くブースト圧力が低いところにデータが集中しており、稼働モード2と逆の傾向を示す低負荷作業となっている。稼働モード4はリターンであり、稼働モード2の戻りのモードであるが、バケットの土砂が空なので高負荷領域はなく空間にデータ点が広く分布している。

このように、各稼働モードで稼働特性は様々であるが、稼働モード間でかなりの部分についてデータがオーバーラップしている。SOMモデルは、このオーバーラップしたデータに対して稼働モードごとに学習することから、分離モデルは高い分類能力が得られる。次節で得られた最適分離モデルを用いて学習済み（既知）データおよび未学習の実稼働データに対する識別性能を検証した。

## 5.2 リアルタイム解析

### (1) 学習済みデータによるアルゴリズムの識別性能

表2はオフライン学習ステップで求めた各稼働モードのSOMから構成される分離モデルを用いて、学習に用いた実稼働データの識別性能を検証した結果を示したもので、表中の識別率とは全ての稼働モードにおいて正しく識別されたデータ数を総データで除したものである。

また表中の識別稼働の-1は、いずれの稼働モードに

も識別されなかったケースを示しており、この比率の大きさが異常兆候の予測を行おうとするものである。ただし、学習に用いたデータセットは正常稼働時のものであるので、-1への識別は誤識別であると考える。

表に示すように、平均の識別率は87%であり良好であると考えてよい。ただし、稼働モード別にみると稼働モード4の識別率は80.5%とやや低く、モード1と誤識別したケース(9.2%)がかなりある。これは、図7からも明らかとなりモード1とモード4の生データの分布がオーバーラップし、かつモード4の生データの分布が広く、密度の高い部分が少ないことからモード1への誤識別が多くなったと考える。

### (2) 実稼働データによるアルゴリズムの識別性能

本アルゴリズムの実稼働データに対する識別性能をみるため、オフライン学習で作成した分離モデルを用いて409サンプルの実稼働（未知）データにより解析を行った結果を表3に示す。なお、実稼働データは識別性能をみるために学習データと同様に同期し、ラベリングしたデータを解析に供した。

各稼働モードの識別率は表に示すとおりであり、平均識別率は75%である。学習済みデータを用いたものと比較して識別性能が12%低下したが、識別に使用したデー




図7 各運転モードに対する学習データとニューロンの分布

タは未知のデータであることから、ほぼ満足できる数値であるとともに、異常の検知に用いる-1の識別率は学習済みデータを用いたものと比較してあまり増加していないことから、実際の運用には問題ないと判断した。

しかし、全体的に他の稼動モードへの誤識別した比率が高いことから分離モデル作成のステップで学習パラメータの調整について、さらに検討を進めることとする。

### 5.3 稼動モード識別率向上の検討

上記で求めた識別率をさらに向上できるかどうかを検討するため、これまで使用した4パラメータ（エンジン回転数、ブースト圧力、油圧ポンプA吐出圧力、油圧ポンプB吐出圧力）に加え、燃料消費量とエンジンオイル圧力を追加し、計6パラメータにより解析を行った。

ここでは、すでに使用した学習（既知）データと実稼動（未知）データを用いて、分離モデルの作成と識別を行った。なお、各稼動モードにおけるSOMの学習パラメータもすでに設定した表1に準拠した。

既知データを用いた各稼動モードの平均識別率は91%、4パラメータ時と比較して平均識別率で4%の改善が行われた。つぎに未知データを用いた各稼動モードの平均識別率は76%、識別できなかった（-1）稼動率は5%であり、4パラメータ時と比較して平均識別率はほぼ同

表2 学習済みデータによる各稼動モードの識別率

平均識別率: 86.9% N=1448

| 識別稼動<br>実稼動 | 1             | 2             | 3             | 4             | -1         | 計            |
|-------------|---------------|---------------|---------------|---------------|------------|--------------|
| 1           | 193<br>(85.0) | 18<br>(7.9)   | 4<br>(1.8)    | 12<br>(5.3)   | 0<br>(0)   | 227<br>(100) |
| 2           | 32<br>(5.7)   | 487<br>(87.4) | 6<br>(1.1)    | 26<br>(4.7)   | 6<br>(1.1) | 557<br>(100) |
| 3           | 5<br>(1.5)    | 1<br>(0)      | 332<br>(96.1) | 4<br>(1.2)    | 4<br>(1.2) | 346<br>(100) |
| 4           | 29<br>(9.2)   | 9<br>(2.8)    | 15<br>(4.7)   | 256<br>(80.5) | 9<br>(2.8) | 318<br>(100) |

上段: データ数 下段: 識別率 (%)

識別稼動の-1は識別できなかったモード

表3 実稼動データによる稼動モードの識別率

平均識別率: 75.3% N=409

| 識別稼動<br>実稼動 | 1            | 2             | 3             | 4            | -1         | 計            |
|-------------|--------------|---------------|---------------|--------------|------------|--------------|
| 1           | 28<br>(63.6) | 4<br>(9.1)    | 4<br>(9.1)    | 7<br>(15.9)  | 1<br>(2.3) | 44<br>(100)  |
| 2           | 20<br>(12.4) | 122<br>(75.8) | 2<br>(1.2)    | 15<br>(9.4)  | 2<br>(1.2) | 161<br>(100) |
| 3           | 3<br>(2.6)   | 1<br>(0.8)    | 101<br>(87.1) | 6<br>(5.2)   | 5<br>(4.3) | 116<br>(100) |
| 4           | 14<br>(15.9) | 9<br>(10.2)   | 3<br>(3.4)    | 57<br>(64.8) | 5<br>(5.7) | 88<br>(100)  |

上段: データ数 下段: 識別率 (%)

識別稼動の-1は識別できなかったモード

比率，－1の稼働率は約2%大きく（悪く）なった．これらの結果について，以下のとおり考察する．

解析に使用した4および6パラメータは，稼働モード識別には重要なパラメータである．しかし，学習（既知）データを用いた結果では6パラメータ使用時の識別率が高くなったものの，実稼働（未知）データの識別率はほとんど変化がなかった．

学習の入力パラメータ数，ここではニューロンの次元数が高くなるとモデルはより多くの情報をデータより得られることから再現性が高くなる．すなわち，6次元の学習データを用いたモデルのほうが既知である学習データに対する識別率は4次元と比較して高くなる．しかし，実稼働データは未知であるため，入力データの類似度が低くなることから識別率が低下する．類似度が低くなるということは，どの稼働モードにも属さないことから異常稼働モードとなる可能性が高くなる．

本システムは，この－1に該当する稼働モードの比率で異常の兆候を判定することから，実稼働（未知）データにおいて－1と識別された稼働モードの比率の低い4パラメータで行うこととした．

#### 5. 4 稼働モード識別率の時系列変化

本システムは，－1と識別された稼働モード（以下，異常稼働モードと称す）の比率の変化により健全度を推定することから，異常が起らない限り異常稼働モードが変化しないことを証明する必要がある．

異常稼働モードを含む各稼働モードの時間推移を図8に示す．計測をはじめた（600 時間）時点のデータを使用して学習を行い分離モデルを構築し，稼働モードの時系列変化を稼働モード比率でプロットしたものである．なお，実稼働においては待機状態（アイドルモード）があることから，このモードを新たに学習データとして追加した．現在，対象油圧ショベルは3000時間稼働していることから，機械の劣化および季節などの使用環境は変化していると推察される．

稼働モードの比率は，時間の経過による使用条件の変化から時期により変化しているものの，異常稼働モードの比率は1～3%とほぼ一定で推移している．この機械の3000時間までのメンテナンス履歴を見ると，この期間に故障履歴がないことから，異常稼働モード比率は油圧ショベルが正常である限り大きく変化しないことが理解できた．

#### 6. システムの異常検知性能の検証

本システムを用いることにより，油圧ショベルの稼働モードの判定が可能であることを示した．しかし，対象とした油圧ショベルは異常が発生していないため，これまで取得したデータに人為的に変動を加え異常を発生させてシミュレーションを行った．また，別の現場において同型機のエンジン部分に不具合が発生したため，この




図8 各稼働モード比率の時系列推移  
(Mode0：アイドルモード，  
Mode-1：異常稼働モード)

データ取得も行いこの不具合についても解析を行った．以下，その結果について示す．

#### 6. 1 シミュレーションによる異常判定

対象とした油圧ショベルは，実際に異常が発生していないため，ここでは異常を想定してこれまで用いた409サンプルの実稼働（未知）データをベースに人為的にパラメータを変動させて異常を発生させ，5章で求めた分離モデルを適用して異常モード判定比率がどのように変化するかを求めた．ここで変動パラメータは，市場で稼働する油圧ショベルの故障頻度が高いとされるエンジンについて，現実に変動が起りうる比率のなかで下記比率を掛けることによって作成した．

- ・ケース1：P1（エンジン回転数）－10%
- ・ケース2：P1（エンジン回転数）＋10%
- ・ケース3：P2（ブースト圧力）－20%
- ・ケース4：P2（ブースト圧力）＋20%
- ・ケース5：正常稼働

なお，ケース1と2はエンジンの制御系トラブル，ケース3と4はターボチャージャーのトラブルを想定して行い，ケース5に比較として正常データを用いてそれぞれ解析した．

これら5ケースについて，先で求めた分離モデルを用い，各ケースに対して稼働モードを分類した結果のうち，異常稼働モードと判定した比率を表4に示す．人為的にパラメータを変動させた場合，正常稼働であるケース5と比較して全体的に異常稼働モードと判定した比率が大きいことがわかる．

ケース1と2はエンジン回転数を変動させたものであ

るが、正常状態（ケース 5）の異常稼動モードと比較して異常と判定した比率が著しく大きいことから、異常の検出は可能である。しかし、ケース 3 のブースト圧力の変動には顕著な変化は現れていない。

エンジン回転数、ブースト圧力ともにデータの変動幅が大きい場合、このように比率を掛けても異常稼動モードと識別されるまでデータが逸脱しないケースがあった。今後、学習パラメータのチューニングによりモデルの識別精度を高めることで、このような問題に対応することとする。

## 6. 2 故障データによる異常判定

現在、データ取得中の対象油圧ショベルに異常が生じないことから、別の現場で発生した同型油圧ショベルの不具合データを取得し解析を行った。しかし、既に作成した解析システムの分離モデルの学習データは同型機種であるものの、別の機械のため機械そのものの個体差、稼動状況の相違も考えられる。

そこで故障時のデータの取得とともに、修理完了後に再度データを取得して、これを正常時データとして比較し検討した。取得した異常時および正常時のデータ数はそれぞれ 134, 219 データである。データ数が信頼できる解析を行うに十分ではないが、著者らが実験で取得している油圧ショベルと比較して車載 PC メモリの容量が少なかったことから、各稼動モードの比率には言及せず、異常稼動モードの比率についてのみ述べる。

正常時の稼動データは、134 データ中 15 データが異常稼動モードと判別し、その比率は 11%であった。異常時の稼動データは 219 データ中 135 データが異常稼動モードと判別し、その比率は 62%であった。識別に用いた学習データとここで取り扱った油圧ショベルのデータは違うものの、異常稼動モードの比率を追跡することで異常の兆候が検知できるものとする。

表 4 パラメータ変動時の異常稼動の識別率

|       | 異常稼動モード |
|-------|---------|
| ケース 1 | 71.6 %  |
| ケース 2 | 42.2 %  |
| ケース 3 | 3.6 %   |
| ケース 4 | 20.9 %  |
| ケース 5 | 3.2 %   |

## 7. 効果的な異常検知システムの構築

現在、建設機械のライフサイクルコスト低減と稼動率向上を目的として様々なシステムが提案されている。これらシステムの大半は、稼動データそのものを管理センターに送信して知識ベースを参照して異常を同定し、機械の管理者に通報するものである。高精度の知識ベースを備えることで、システムの信頼性は高くなると思われるが、データベース構築と通信費に多大なコストが生じ、このコストは機械管理者である顧客の負担となる。

特に通信関係は近年、NTT が提供する DoPa や衛星通信の一種であるオープンコムなどが運用されており、建設機械の稼動データ通信には有効である。しかし、稼動データを全て送信して健全度判定に利用することはコスト的に問題があることから、本研究では異常の兆候を簡便に検知できるシステムを図 9 に示す。

まず、本稼動モード識別アルゴリズムを対象機械に実装し、オンボードで稼動モードを識別する。次に、この稼動モードの比率を通信により管理センターに送信し、管理センターではこの比率をデータベースに蓄える。この異常モードの比率がある閾値に達したとき、機械に対しメンテナンスを実施する。




図 9 オンボード稼動モード判定による異常検知システム

本システムのメリットとして、稼動モード比率のみを送信するためデータサイズが小さいこと、情報がシンプルなので高度な知識ベースなどを構築しなくてよいことである。つまり、簡便なシステム構築で運用可能であり、通信コストも抑制できる。これにより、現在問題になっているライフサイクルコストの低減と稼動率向上に寄与できるものとする。

## 8. まとめ

油圧ショベルからの稼動データに対し、SOM の学習法を応用して稼動モードを適切にクラス分けすることにより、油圧ショベルに何らかの不具合の兆候が起こったことを識別できる手法を構築した。このモデルの検証として、人為的にパラメータを変動させたデータおよび実際の異常データを用いて解析することで稼動モードを判定し、その比率を求めることで、異常兆候の検知が可能であることを示した。

本研究で得られた知見を以下にまとめる。

- (1) 本システムの分離モデルは、ひとつの稼動モードを明確に代表するエキスパートとして機能させるため、複数の稼動モードの判定に高い識別率を示すことができた。さらに、新たに稼動モードを追加するときは従来の単独モデルによる SOM では最初から学習する必要があるが、本アルゴリズムでは新たに追加したい稼動モードだけを部分的に学習するだけでシステムの更新が可能である。
- (2) 油圧ショベルの異常状態を作成するために、パラメータを人為的変動させることで、機械に異常が生じた場合は異常稼動モード比率の変化で異常を検知できる見通しを得た。
- (3) 稼動モード識別アルゴリズムを油圧ショベルに実装することで、オンボードで稼動モードを識別し、その比率のみを通信で送信することから、データサイズをコンパクトにでき、通信コストも抑制できる。
- (4) 本システムは油圧ショベルに限らず、対象物のデータを用いて学習することで、他の建設機械に応用可能である。特に近年は、IT 技術を応用して建設工事を高度化しつつあることから、稼動モード判定による健全度判定技術を活用することでライフサイクルコストの低減と稼動率向上に寄与できる。

今後は、さらにモデルの識別精度を高めるために稼動データのパラメータ選定、SOM モデルの学習法の検討、および稼動モードの判定の最適化を行う予定である。あわせて不具合に関するデータベースを整理し、各パラメータと不具合の物理的な関係を明確にして、信頼性の高い異常検知が行なえるように研究を進めることとする。

## 参考文献

- 1) 日本工業出版：建設機械，Vol.39, No.1, 2003.
- 2) 山本鎮男編：ヘルスマニタリング，共立出版，1999.
- 3) T. Kohonen: Automatic Formation of Topological Maps of Patterns in a Self-Organizing System, Proceedings of the 2nd SCIA, Scand. Conference on Image Analysis, Helsinki, Finland, pp.214-220, 1981.
- 4) T. Kohonen: The Self-Organizing Map, Proc. IEEE, vol. 78, No. N-9, pp.1464-1497, 1990.
- 5) 白木渡，長瀬裕俊，宮下英明，伊藤則夫：自己組織化マップ（SOM）による斜面崩壊予測システム，構造工学論文集，Vol.44A, 1998.
- 6) 乾正博，杜紅，中元俊平，大木誠，大北正昭：ファジィ制御と SOM の活用による配電用変電所母線電圧の維持と送電損失の低減，日本ファジィ学会誌，Vol.14, No.2, pp.176-189, 2002.
- 7) 小松孝二，清田雄彦，バチコフ・ガンチョ，藤井敏：自己組織化マップを用いた機械のリアルタイム稼動モード認識に関する研究，第 2 回評価・診断に関するシンポジウム，pp.84-87, 2003.
- 8) G. Vachkov, Y. Kiyota, K. Komatsu and S. Fujii: Real-Time Classification Algorithm for Recognition Machine Operating Modes by Use of Self-Organizing Maps, Turkish Journal of Electrical Engineering & Computer Sciences, pp.27-42, Vol.12, No.1, 2004.
- 9) E. Uchino, M. Kawamura and K. Nagata: Dynamic Deletion of Units for Self-Organizing Map by Introducing a New Measure of Unit's Contribution to Learning, Journal of Japan Society for Fuzzy Theory and Systems (SOFT), Vol. 14, No. 6, pp.157-164, 2002.

(2004.9.17 受付)