

機械の稼動データ圧縮と復元による異常兆候予測の基礎的研究

Basic Study on Prediction of Abnormal States in Machines
By Compression and Recovery Techniques of Operating Data小松孝二*, 清田雄彦**, バチコフガンチョ***, 藤井敏****
Koji KOMATSU, Yuhiko KIYOTA, Gancho VACHKOV and Satoshi FUJII

*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)

****新キャタピラー三菱株式会社 (兵庫県明石市魚住町清水 1106-4)

In this paper, a prediction method of abnormal states of a system is proposed using data compression and recovery technique of complicated operating states in construction machines. This compression technique utilizes the effectiveness of the unsupervised learning which is able to represent a huge number of data during the operation. The compressed data are further transmitted to the maintenance center through a communication module. At the maintenance center, the acquired data are stored in a database by the special procedure. After that, these data are used to calculate the relationship between selected pairs of parameters by using the moving window average and the density distribution method. Computer simulations with real data from a construction machine are performed in order to validate the applicability of the proposed method for prediction of abnormal conditions.

Keywords: Health Monitoring, Maintenance, Unsupervised Learning, Data Compression

キーワード: ヘルスモニタリング, メンテナンス, 教師なし学習, データ圧縮

1. まえがき

近年, 機械設備のメンテナンスを行う場合, 稼動情報を示す信号を計測して, そのデータを解析することにより機械設備の健全度を診断する研究が行われている. 特に建設機械においては, その稼動現場が機械を管理しメンテナンスを行うサービス部門から遠く離れていることや, いったん故障が発生すると工事の遅延などの影響が大きいことから, 機械の稼動状態を示すデータを通信により自動的にサービス部門に送信し, 受信したデータを解析することにより劣化や異常の兆候を予測する予知保全が強く求められてきた^{1,2)}. しかし, リアルタイムに計測するデータ数は膨大であるため, 通信に要する費用が大きく, 計測した全ての稼動データをサービス部門に送ることは困難であったため, 稼動モードの同定による異常検知の手法を提案したが, 実用面で課題が残った^{3,4)}.

そこで, 建設機械を対象に計測した膨大な数の稼動データの特徴をニューラルネットワークの教師なし学習のアルゴリズムを応用して少数のニューロンに学習させ, そのニューロンをサービス部門に送信し, 受信したサー

ビス部門ではニューロンが持っている情報を解析することにより, 稼動データ群に近い特性を復元, 視覚化することで機械の劣化や異常の兆候を予測する基礎的研究を行った.

本論文では, 膨大な数の稼動データの特徴を少数のニューロンに学習させることを稼動データの「圧縮」と称することとし, その手法およびニューロンから稼動データの特徴を復元させる手法について記述, かつ土木現場で稼動する建設機械に適用した結果についてまとめた. なお, 本手法は構造物などにも活用できると考える.

2. 供試機械と車載コンピュータ

図-1に本研究の概念を示す. 研究に供した建設機械として油圧ショベルを選んだ. 油圧ショベルは, エンジンにより油圧ポンプを駆動し, その油圧で旋回モータ, 油圧シリンダ, 走行モータを駆動させる. したがって, エンジンと油圧ポンプに異常が生じた場合は深刻度が大きいので, これらを最重要コンポーネントと位置づけ, 劣化や異常の兆候を予測することにした.

供試した油圧ショベルには、研究用に試作した小容量の簡易コンピュータを搭載し、稼動データの収録と圧縮の演算および圧縮後のニューロン情報の送信を行わせた。各プロセスの詳細は次のとおりである。

①稼動データの収録：システムに汎用性をもたせるため、機械の電子制御装置から得られるデータを用いることとし、劣化や異常の予測に有効であるエンジン回転数、エンジンオイル圧力、給気圧力、燃料消費量、排ガス温度、油圧ポンプ吐出圧力など9項目（以下、パラメータと記す）を選んだ。

また、油圧ショベルの稼動は負荷変動が早いので稼動データの取得を1秒間隔として、1日の全稼動データを連続して計測した。なお、このうちエンジンの暖機時やアイドリング時のデータは除外した。

②稼動データの圧縮：1日の稼動が終了すると、9項目のパラメータからなる稼動データの特徴を教師なし学習によりニューロンに変換した。これにより数千から数万個あった膨大な稼動データは、数十個の極めて少ないニューロンに圧縮されたことになる。

③ニューロンの送信：データ圧縮により得られたニューロンのデータサイズは極めて小さいため、携帯電話網を活用してサービス部門に送信することにより、安価な通信コストを可能にした。

受信したサービス部門では、ニューロン情報の解析から近似的に稼動データの特徴を復元し、機械の劣化や異常の兆候を診断した。

3. 稼動データの圧縮

3.1 教師なし学習を用いた手法

多次元空間で構成された膨大な稼動データ群を圧縮する手段として、ニューラルネットワークにより学習を行った。本研究では、学習アルゴリズムに自己組織化マップ（Self-Organizing Map: SOM）を応用した⁹⁾。

SOMとは、コホーネンにより提案された手法であり、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おり、入力データに相当する稼動データ群の隠れた特徴を自動的に抽出して2次元空間に分類し、視覚化するものである。この特長を利用して、これまでパターン認識をはじめとした各分野に応用されており、近年では土木分野でもその優れた分類能力を活用して斜面崩壊予測システムの前処理手法として用いている例もある⁹⁾。

本研究では、2次元空間に分類する従来のSOMとは異なり、SOMの競合および近傍学習を応用して、 n 項目のパラメータを座標軸とする n 次元空間にニューロンを配置することにより稼動データを学習させる。すなわち、多数の稼動データを少数のニューロンに圧縮させる手法を提案した。以下に圧縮の手順を示す。




図-1 研究の概念図

①学習条件の設定

まず、ニューロンの学習条件として初期ニューロン数 N 、初期学習率 α_0 、初期近傍領域、総学習回数 T を設定する。

②入力層と競合層間の初期重みの設定

つぎに、 n 次元空間の競合層にニューロンをランダムに配置するとともに、全ニューロンに対し式(1)の初期結合重みベクトル $\mathbf{w}(j)$ を与える。

$$\begin{aligned} W &= \{\mathbf{w}(j)\} \\ &= \{w_1(j), w_2(j), w_r(j), \dots, w_n(j)\}, \\ j &= 1, 2, \dots, N \quad r = 1, 2, \dots, n \end{aligned} \quad (1)$$

ここに、

j : ニューロン番号 N : 初期ニューロン数
 r : パラメータ番号 n : パラメータ数

③稼動データのベクトルの設定

稼動データのベクトル $\mathbf{d}(i)$ を式(2)のとおり設定する。

$$\begin{aligned} D = \{\mathbf{d}(i)\} &= \{d_1(i), d_2(i), d(i), \dots, d_n(i)\}, \\ i &= 1, 2, \dots, m \end{aligned} \quad (2)$$

ここに、

i : 稼動データ番号 m : 総データ数

④稼動データとニューロンとの類似度の計算

i 番目の稼動データ $\mathbf{d}(i)$ と、 j 番目のニューロン $\mathbf{w}(j)$ 間のユークリッド距離（以下、距離と記す） $S(j)$ を式(3)により求める。

$$S(j) = \sqrt{\sum_{r=1}^n [d_r(i) - w_r(j)]^2} \quad (3)$$

この距離 $S(j)$ が最も小さいニューロンを勝者ニューロンと呼ぶ。また、勝者ニューロンのまわりの近傍領域に該当するニューロンも同時に決定する。

⑤勝者ニューロンと近傍ニューロンの学習

勝者ニューロンの重みベクトル $w(c)$ は、学習率 α_t により更新される。また、近傍のニューロンも同様に更新されるが、その更新量は勝者ニューロンと近傍ニューロンとの間の距離、および近傍関数に依存する。更新後の勝者ニューロンは式(4)により求める。

$$w(c)^{new} = w(c)^{old} + \alpha_t \{d(i) - w(c)^{old}\} \quad (4)$$

$$\alpha_t = \alpha_0 \left(1 - \frac{t}{T}\right)$$

ここに、

α_t : 学習回数 t における学習率 α_0 : 初期学習率

$w(c)^{new}$: 更新後の勝者ニューロン

$w(c)^{old}$: 更新前の勝者ニューロン

t : 現在の学習回数

T : 設定総学習回数

上記のステップ②から⑤を設定した学習回数 T まで繰り返し行う。こうしてニューロンは、移動データを徐々に学習し最終的に固定させた。

3.2 ニューロンの持つ情報

学習後のニューロン群は、移動データ群の特徴を見出しており、以下に示す3つの情報により移動データ群の特徴を定量的に表すこととした。

①ニューロンの座標

n 個のパラメータを座標軸とする n 次元空間にある位置を各ニューロンについて求めた。

②ウェイト

各ニューロンがいくつの移動データに対して勝者になったかを示すもので、各ニューロンに対して求めた。

③最小距離の平均値

各ニューロンとそれが勝者になった移動データ間の最小距離の平均値を各ニューロンに対して計算した。

4. 稼働データの復元

4.1 受信ニューロンによる近似的復元

油圧ショベルからの信号を受信したサービス部門では、ニューロンの持つ情報から近似的に稼働データの復元を行い、1日の稼働特性を視覚化することで劣化や異常の兆候を予測する。稼働特性の視覚化には、ニューロンの移動平均と密度分布により行った。

4.2 ニューロンの移動平均

n 次元空間におけるニューロン情報のうち、座標とウェイト情報から任意の2つのパラメータの2次元平面に分布するニューロンの移動平均処理による稼働特性の視覚化を行った。

図-2はウェイトを考慮した移動平均処理の手法を示したものである。模式図のとおり、任意の2つのパラメータ間 X, Y に関するニューロン情報を取り出し、そのう




図-2 ウェイトを考慮したニューロンの移動平均処理

ち基準となるパラメータ X のレンジに対し予め設定したウィンドウ幅 WL に分割して、各ウィンドウに該当するニューロンの重心を計算する。このウィンドウの処理にオーバーラップ幅 WO を設定することで重心点をそれぞれ求める。すなわち、2つのパラメータ間 X, Y の重心 C_X^j および $C_Y^j, j=1, 2, \dots, m$ は、 j 番目のウィンドウにおける X, Y に存在するニューロンを用いて次式により求める。

$$C_X^j = \frac{\sum_{i=1}^{N_j} x_i^j w_i^j}{N_j}, \quad C_Y^j = \frac{\sum_{i=1}^{N_j} y_i^j w_i^j}{N_j} \quad (5)$$

ここに、 x_i^j と y_i^j はそれぞれ j 番目ウィンドウ内に存在するニューロンの座標を表している。なお、 w_i^j は対応するニューロンのウェイト、 N_j はウィンドウ内のニューロン数を示している。

4.3 ニューロンの密度分布

ニューロンのもつ情報である座標、ウェイト、平均距離の情報をを用いてニューロンの密度分布を求め稼働特性の視覚化を行った。密度分布による視覚化方法は、任意の2つのパラメータ間のニューロンを平面にとり、そのウェイトを高さ、平均距離を平面座標の広がりとする。このようにすることで、生データの密度と広がりを視覚的に表現できる。

5. 実機による稼働データの解析結果

5.1 正常稼働データによる稼働特性

(1) 稼働データの学習結果

土木現場で稼働する油圧ショベルの1日の稼働データ6000個を教師なし学習により80個のニューロンに圧縮した。この時の稼働データ群とニューロン群のデータサイズを比較すると、約50分の1に圧縮されたことになる。また、ニューロンの学習にあたり、事前に初期学習率、初期近傍領域、設定総学習回数の最適化を図った。

稼働データおよびニューロンは9項目のパラメータで構成されている。つまり9次元空間に分布しており、それらの分布は任意の2個のパラメータを座標軸とする2次元平面で見ることができるが、ここではエンジン回転数に対する給気圧力の関係の中で稼働データの圧縮と近似的復元について述べる。

図-3は稼働データ群をエンジン回転数と給気圧力の2次元平面で見たものであり、図-4はこの稼働データ群の特徴を学習した後の勝者ニューロンの分布を示したものである。なお、両図のデータは正規化したものであり、学習済みのニューロンがデータの密度の高い領域に分布していることが視覚的にわかる。

学習終了後、一度も勝者にならなかったニューロンおよび極めて少数のデータ点を代表したニューロンはデータ圧縮に寄与しないものとして削除した⁷⁾。

ニューロンには、9次元空間におけるニューロンの座標、いくつかのデータの勝者になったかを示すウェイト、データ点までの平均距離の3つの情報が圧縮されており、これらを使ってニューロンの移動平均および密度分布を求めた。

(2) ニューロンの移動平均

図-5は4.2項で述べた手法によるニューロンの移動平均を示しており、ウィンドウ幅 WL の分割数、オーバーラップ幅 WO を設定して重心点を求めたものである。同図には検証のため稼働データ（生データ）から直接求めた移動平均を示したが、ニューロンの移動平均はほぼ生データの移動平均と同じであり、ニューロンの移動平均が稼働データの特徴を近似的に復元している。

(3) ニューロンの密度分布

ニューロンの情報である座標、ウェイト、平均距離から稼働データ群の分布の特徴を知るため、3次元空間上に分布を近似的に示し視覚化を行った。その結果の一例




図-3 取得した稼働データ（生データ）の分布




図-4 学習後のニューロンの分布




図-5 生データの移動平均とニューロンの移動平均結果の比較




図-6 ニューロンの密度分布




図-7 稼働時間に対するニューロンの移動平均結果の比較 (エンジン回転数-給気圧力)




図-9 異常稼働の生データとニューロンの分布 (エンジン回転数-給気圧力)




図-8 稼働時間に対するニューロンの移動平均結果の比較 (給気圧力-燃料消費量)




図-10 正常稼働と異常稼働のニューロン移動平均結果の比較 (エンジン回転数-給気圧力)

を図-6に示す。多くのデータ点を代表しているニューロンは、ウェイトが高く表示されている。

5.2 稼働データの時系列変化の追跡

本研究で提案している手法は、油圧シヨベル上で1日の稼働データを取得して、その特性をニューロンに圧縮し、これをサービス部門で解析することにより劣化や異常の兆候を早期に発見しようとするものである。したがって、機械が正常に運転している場合は、ニューロンから復元した稼働特性に大きな変化がないことを検証する必要がある。

そこで、各期間における稼働データを収録し、計測開始後 1000 時間までの経時変化を追跡した結果を図-7 および図-8に示す。なお学習後のニューロンは、9次元空間に分布しているパラメータ間の関係を示すことが

できるが、ここでは機械の異常を顕著にあらわすエンジン回転数、給気圧力、燃料消費量の特性から考察する。

図-7はエンジン回転数と給気圧力で比較したものであり、図-8は給気圧力と燃料消費量で比較したものである。両図とも正常に稼働していれば、ニューロンの移動平均結果にほとんど差がないことがわかる。なお、追跡調査の間、作業内容、使用環境、運転者などが変わっているが、これらの影響は稼働特性には表れていない。

5.3 提案手法の異常判定性能の検証

正常稼働時における機械の稼働特性の変化がほとんどないことが確認できたため、実機に模擬的に異常を発生させて稼働特性の変化を検知することが可能か試みた。異常の内容として、過去の故障履歴により頻度の高い不具合を調査した結果、エンジンの燃料噴射系に関する異




図-1 1 正常稼動と異常稼動のニューロン移動平均結果の比較（給気圧力-燃料消費量）

常が多かったことから、機械にこの不具合の状態を再現させて解析を行った。実験に供した油圧ショベルは、動力に6気筒のディーゼルエンジンを搭載しており、このうち1気筒の燃料噴射ノズルを故障状態にしてデータを収録し、学習を行った。

図-9は故障状態における稼動データと、その稼動データを学習したニューロンをエンジン回転数と給気圧力の2次元平面に示したものである。図-10は先に示したニューロンを用いて移動平均処理を行ったものである。正常稼動データから求めたものを同図に併記して比較すると、正常時に比べて故障時の結果はエンジン回転数に対して給気圧力が低下していることがわかる。

図-11は上記と同様のデータを用いて、パラメータの組み合わせを給気圧力と燃料消費量に変えて示したものである。故障時には給気圧力に対して燃料消費量が多くなっており、特に低負荷域での燃料消費量の増加が顕著に見られる。これは、出力低下によるエンジン停止を防ぐため燃料噴射量を多くしたためである。

以上の解析結果から、圧縮したニューロン情報の近似的な復元により、機械を管理するサービス部門では基準となる正常な稼動特性と日々の結果を閲覧、比較することで正常な特性から逸脱した場合は劣化や異常の兆候が生じている可能性を予測できることの示唆を得た。

6. まとめ

本研究では、油圧ショベルの膨大な稼動データに対して、機械に搭載した簡易コンピュータにニューラルネットワークの教師なし学習を応用したアルゴリズムを組み込むことで、オンボードで圧縮・送信処理を行い、サービス部門で稼動特性を復元することにより機械の劣化や異常の兆候を予測する手法を提案した。

本研究により得られた結果を以下にまとめる。

- (1) 構築した稼動データ圧縮アルゴリズムは、ニューラルネットワークの教師なしアルゴリズムを応用することで、多次元空間で構成されるパラメータに対し、1日の稼動特性を少数のニューロン情報に代表させることができた。
- (2) ニューロンの座標およびウェイト情報を用いて任意のパラメータ間の移動平均を求めることで、稼動特性を近似的に復元できることを確認した。
- (3) 本提案手法の有効性を検証するため、模擬的に故障を発生させ、その稼動特性を正常時の特性と比較することで、機械に異常が発生した場合は稼動特性の差を見ることで異常の兆候を発見できる可能性を示した。
- (4) 本システムは、取得した稼動データ群の特徴を学習により圧縮することから、油圧ショベルに限らず他の対象物にも応用可能である。近年はIT技術を応用して建設工事を高度化しようという動きがあることから、このような手法を応用することで稼動向上に寄与できる。

今後は、供試油圧ショベルの台数を増やしてデータ計測とメンテナンス履歴の追跡を行い、かつ市場で発生する不具合事例の多い順に模擬的に故障を作ってデータ計測をして、正常時と異常時の各パラメータの変動量と異常の因果関係を整理してデータベースを構築し、予測の信頼性を高めていく予定である。

参考文献

- 1) 日本工業出版：建設機械，Vol.38, NO.4, 2002.
- 2) 日本工業出版：建設機械，Vol.39, NO.1, 2003.
- 3) 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.
- 4) 小松孝二，清田雄彦，パチコフガンチョ，木村信行：建設機械の稼動モード認識による異常検知，構造工学論文集，Vol.51A, pp.331-340, 2005.3.
- 5) T. コホネン著，徳高平蔵他訳：自己組織化マップ，シュプリンガー・フェアラーク東京，1996.
- 6) 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.
- 7) 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, 157-164, 2002.

(2005.9.10 受付)