

# デジタル制御入出力信号の非定常検出方式の検討

柴田 昌彦† 中原 大貴† 三井 聡†

三菱電機株式会社 情報技術総合研究所†

## 1. はじめに

近年、製造業において、生産現場で取得されるデータを品質・生産性の向上に活用する取り組みが活発化している。その一環として、生産現場における非定常な状態や動作を検出する技術の開発が進められている[1]。生産現場でライン停止等のトラブルが発生した時に、トラブル要因の特定には装置や制御プログラムの知識・ノウハウが必要であり、経験の浅い保全員には要因の特定が困難な場合が多い。また、トラブル要因を網羅的に特定するための設定やプログラムの作成は現実的ではない。

一方、データ解析の観点では、2 値のデジタル制御入出力信号（ビット信号）の扱いが難しい点で課題がある。FA（Factory Automation）分野では、センサやアクチュエータの ON と OFF を表現するビット信号が多く利用されるが、アナログ信号とは特性が異なり一般的な非定常検出方式の適用が難しい。複数のビット信号を扱う例として、信号値の組合せを状態として捉え、状態遷移確率から信号変化の尤度を算出する方式が考えられる。しかしこの方式では信号数が増大した際に、状態の種類が指数関数的に増大するため、モデルとして保持すべきデータ量の多さや状態遷移の予測精度の低下が課題となる。

本稿ではこの課題の解決のため、ユーザによる網羅的な条件設定なしで、正常な信号データを基に、生産ライン稼働時の信号の非定常な時系列変化を自動で検出・提示する方式を提案する。非定常な信号変化の提示は、異常なセンサやプログラムを特定するための手がかりとなり、保全員のトラブルシューティングに役立つ。

## 2. 提案方式

### 2.1. 提案方式の概要

前章で挙げた課題を解決するため、本稿では正常なビット信号のパターンを機械学習し、予測したビット信号値と実測値の比較から異常度を算出する方式を提案する。

生産現場において非定常な信号パターンを網羅的に収集することは現実的でないため、非定常

なデータは使わず、正常データのみで機械学習する方針とする。具体的には、正常な信号パターンから、過去一定時間長の信号値を基に次の信号値を予測するモデルを構築する。学習と予測のモデルには Time Delay Neural Network (TDNN) を使用する。学習後の、生産ライン稼働時の非定常検出方式の概要を以下に示す。

- (1) 生産ラインから信号データを収集
  - (2) 過去一定時間長の信号値を保持
  - (3) TDNN により過去の実測値から次の信号値を予測
  - (4) 予測値と実測値の比較から異常度を算出
  - (5) 異常度から非定常な時刻と信号を特定
- (3)の信号値の予測については 2.2 節で、(4)の異常度の算出については 2.3 節で詳細を述べる。

### 2.2. TDNN による定常な信号値の予測

TDNN は主に時系列データを扱う際に利用される Neural Network (NN) であり、過去数セットのデータを入力とする。本方式で利用する TDNN の概要を図 1 に示す。NN の入力層には一定時間長のビット信号値を、出力層には次の時刻の信号値を適用する。学習の間は正常な信号のデータを生産現場より十分な期間収集し、TDNN に入出力のパターンを学習させる。この学習により、TDNN は過去一定時間長の信号値を基に次の信号値の予測を出力するようになる。学習後に生産現場で非定常検出を行う間は、信号値をリアルタイムで取得し、その度に TDNN によって次の信号値の予測を行う。

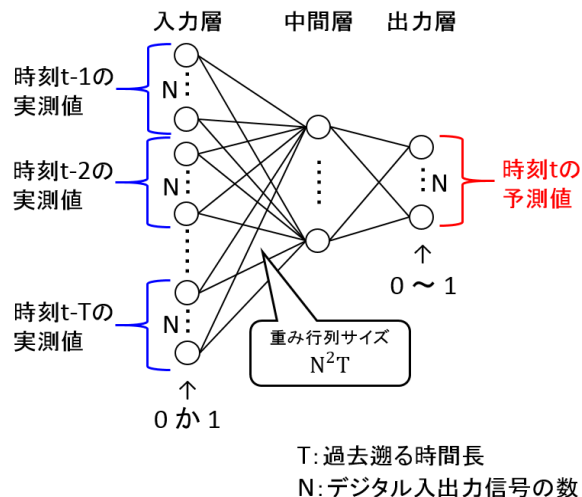


図 1 提案方式における TDNN の概要

“Anomaly Detection Method for Digital Control Input-Output Signals”

†Information Technology R&D Center, Mitsubishi Electric Corporation

以上の方式では、正常な信号のパターンを柔軟に学習できる効果が期待できる。例えば図2のように、正常な信号の変化タイミングにある程度の時間範囲がある場合でも、TDNN ではいくつかの信号パターン（例えば信号パターン1, 3のみ）の学習により正常な範囲として学習できる。他にも、人間による条件設定なしに複数の処理パターン対応可能なことが期待できる。

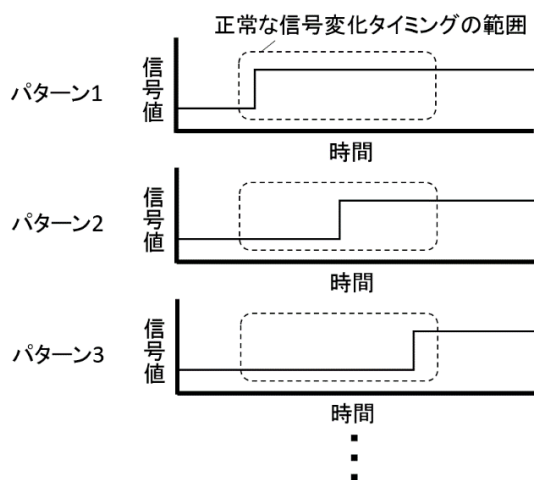


図2 変化タイミングに時間範囲がある信号パターンの例

また、学習結果として保持する重み行列のサイズ（図1の  $N^2T$  の部分）は信号数の2次相関（図1の  $N^2$  の部分）および遡る時間長の1次相関（図1の  $T$  の部分）で増大する。そのため、信号数が増大した場合でも、状態遷移確率行列のように行列のサイズが指数関数的に増大することはない。

### 2.3. 異常度の算出

本方式の異常度の算出について述べる。TDNN による信号の予測値は0から1の間の小数値となる。この予測値を各信号の「1の値を取る確率」とみなし、また同時に「1 - 予測値」を各信号の「0の値を取る確率」とみなすことができる。各信号が実測値を取る確率の負の対数尤度を異常度として算出する。実測値  $x$  ( $x = 0$  または  $1$ ) と予測値  $p$  ( $0 \leq p \leq 1$ ) により、異常度は下記の式で表される。

$$\text{異常度} = -x \log p - (1 - x) \log(1 - p)$$

稼働時には全信号の異常度の合計により非正常であるか否かの判定を行う。そして非正常と判定された場合は異常度の高かった信号を抽出しユーザに提示することができる。本方式では予測値を確率として扱うことで、ユークリッド距離などの一般的な手法に比べ、重大な非正常に対し顕著な異常度を与えることができる。

### 3. 評価

本方式の評価実験を行った。評価では模擬生産ラインを使用した。模擬生産ラインではワーク（加工対象）に対し、約25秒間でプレスや運搬など一連の処理を施す。その際、16個のビット信号を扱う。これらの信号について、まず学習用にワーク約100個分の正常データを収集し、TDNN で学習を行った。さらに評価用にワーク約34個分のデータを収集した。評価用データでは、最後の3個のワークについてはラインで使用するコンプレッサの圧力を下げることにより、ライン停止を伴う異常を作為的に発生させた。

評価用データに対し異常度を算出した結果が図3である。図3では評価用データ合計約820秒間に対し、毎秒信号値の異常度を算出しプロットしている。正常稼働している最初の約720秒間と、異常が発生している最後の約100秒間では異常度に大きな差があることが分かる。正常データにおける異常度の最大値を閾値とした結果、評価用データにおいては異常箇所のみを非正常であると判定することができた。

また、異常度の高かった信号を抽出した結果、異常に大きく関係する信号の特定に成功した。評価により、本方式が非正常な信号変化の検出に有効であることが実証された。

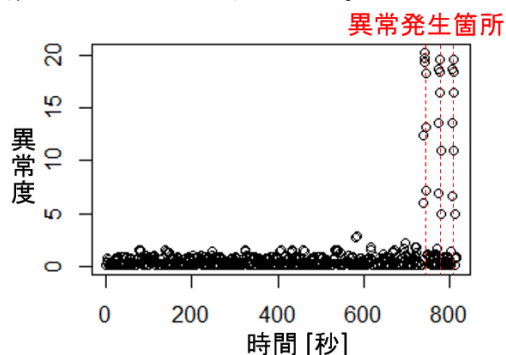


図3 評価用データに対し算出した異常度

### 4. おわりに

本稿では正常なビット信号のパターンを機械学習し、生産ライン稼働時の信号の非正常な時系列変化を自動で検出・提示する方式について述べた。本方式により、生産現場における保全員のトラブルシューティングを容易化し、生産性の向上に寄与できると考える。今後は実際の生産ラインを対象とした実証実験を行う。

### 参考文献

- [1] Asmir Vodenčarević, Thomas Fett, “Data Analytics for Manufacturing Systems,” 2015 IEEE 20th Conference on Emerging Technologies & Factory Automation (ETFA)