

# 制御入出力信号の非定常検出技術

Anomaly Detection Technology for Control Input-output Signals

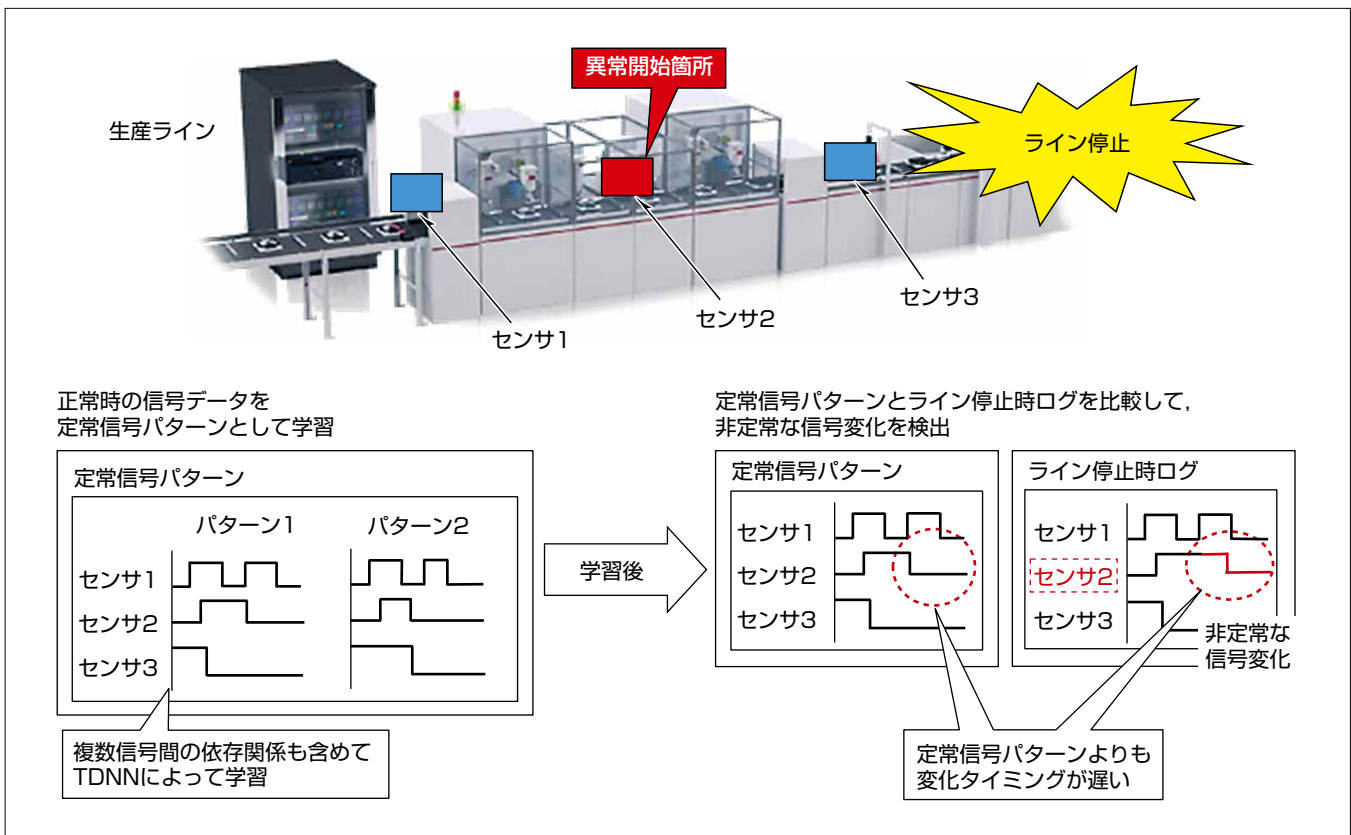
## 要旨

製造業では、IoT(Internet of Things)技術を活用した工場のスマート化が進められている。それに伴い、生産現場でのデータ利活用が加速しており、生産設備から取得したデータを生産現場の生産性向上へ活用する取組みが行われている。その一環として、生産設備のトラブル発生時に起きる非定常な状態や動作を検出する異常検出技術の開発が進められている<sup>(1)</sup>。

従来技術では、電流や振動等のアナログ信号だけを監視するものが多く、トラブル要因箇所の特定後であれば、関連する信号に注目することで予防保全等が可能である。一方、トラブル要因箇所が不明な場合に複数の信号間の依存関係を含めて多数のアナログ信号を同時に監視しようとすると処理負荷が高く、実用的ではない。

そこで、三菱電機では、信号の予測・学習モデルとしてTDNN(Time Delay Neural Network)を採用し、生産設備の制御にも活用される2値の制御入出力信号(ビット信号)を、複数の信号間の依存関係を含めて監視することで異常開始箇所を特定する技術<sup>(2)</sup>を開発した。ビット信号であれば、アナログ信号よりも処理負荷が小さく、製造現場で活用される産業用パソコン等で実用可能な処理負荷にとどめることができる。実証実験の結果、9割以上の精度で異常開始箇所を検出でき、実装置へ適用可能であることを確認した。

この技術によって、異常開始箇所をいち早く把握し、迅速なトラブル要因の特定が可能になることから、生産設備のダウンタイム短縮に大きく貢献できる。



## 非定常検出技術

非定常検出技術では、生産設備の異常時に発生する非定常な信号変化を検出することで、異常開始箇所としてユーザーへ提示する。まず、生産ラインの正常稼働時の信号データを一定期間収集し、信号間の依存関係も含めて定常時の信号パターンだけTDNNによって学習する。学習後は、トラブル発生時の信号データと定常時の信号パターンとを比較することで、非定常な信号変化の発生時刻と箇所を検出する。

## 1. ま え が き

近年、製造業で、IoT技術を活用した工場のスマート化が進み、それに伴い、生産現場で取得されるデータを生産現場の稼働率向上に活用する取組みが活発化している。

生産現場では、ライン停止等の生産設備でのトラブル発生時で、異常箇所を迅速に突き止めることが求められており、当社では、生産設備で発生したトラブルの異常開始箇所を自動検出する技術の開発に取り組んでいる。この技術では、生産設備の制御に活用される複数のビット信号間の依存関係に基づいて、異常時に発生する非正常な信号変化を検出し、異常開始箇所としてユーザーへ提示する。

本稿では、当社で開発した非正常検出技術と、実装置にこの技術を適用して実施した実証実験について述べる。

## 2. 非正常検出技術

### 2.1 開発方式

一般的な教師あり機械学習を利用した非正常検出方式では、検出対象とする非正常な信号データも合わせて機械学習する。しかし、生産現場で非正常な信号パターンを網羅的に収集することは現実的ではない。そのため、開発方式では教師なし学習、すなわち正常な信号データだけで機械学習する。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して次の信号値を予測するモデルを構築する。学習後の、生産ライン稼働時の開発方式の手順は次のとおりである。

- (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によって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) 異常度から非正常な時刻と信号を特定

開発方式では、正常な信号パターンに時間的なずれが生じる場合でも対応可能なTDNNを採用し、ビット信号の学習・予測を行う。そして、ビット信号の予測値と実測値から負の対数尤度(ゆうど)を異常度として算出する。TDNNについては2.2節で、異常度の算出については2.3節で詳細を述べる。

### 2.2 TDNN

TDNNは主に時系列データを扱う際に利用されるNN(Neural Network)であり、過去の数セットのデータを入力とする。開発方式で利用するTDNN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から十分な期間収集し、TDNNに入出力のパターンを学習させる。この学習によって、TDNNは過去一定時間長の信号値を基にして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正常検出を行う間は、信号値をリアルタイムで取得し、そのたびにTDNNによって次の信号値の予測を行う。

生産現場では、装置が正常に稼働している場合でも、信号が変化するタイミングにずれが生じることがある。TDNN以外の手法(パターンマッチングや状態遷移モデル等)では、最悪の場合、こうしたずれも含めて全ての信号パターンを学習・登録する必要があるため、学習データ量や学習モデルサイズが膨大になり、実用的ではない。一方、この方式で採用したTDNNでは、信号変化タイミングのずれも含めて一つのモデルで表現できる。例えば、図2のように正常な信号変化タイミングにある程度の時間範囲がある場合でも、幾つかの信号パターンでの依存関係も加味して正常な範囲として学習できる。また、学習結果とし

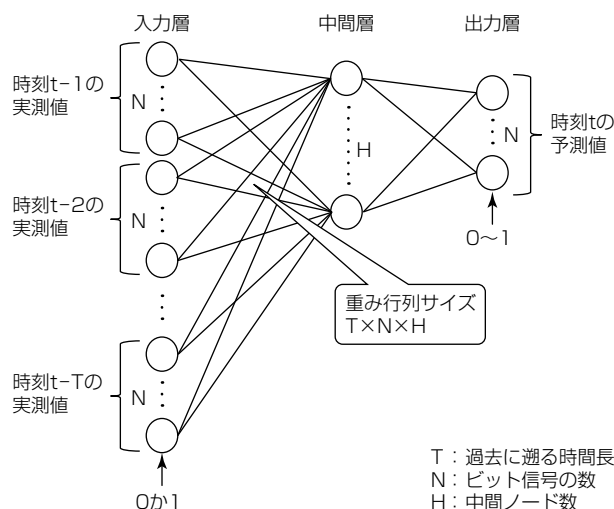


図1. この方式でのTDNN




図2. 変化タイミングに時間範囲がある信号パターン例

て保持する重み行列のサイズ(図1のT×N×Hの部分)は、信号数の1次相関(図1のNの部分)及び遡る時間長の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、行列のサイズが指数関数的に増大することなく、データ量を抑えることが可能である。

### 2.3 異常度の算出

開発方式の異常度の算出について述べる。開発方式でのTDNNによる信号の予測値は0から1の間の小数値になる。予測値は信号値の期待値であり、式(1)から各信号で“1の値を取る確率”とみなすことができる。

同時に、“1-予測値”を各信号で“0の値を取る確率”とみなすことができる。

$$\begin{aligned}
 p &= E[X] \\
 &= 1 \times P(X=1) + 0 \times P(X=0) \\
 &= P(X=1) \dots\dots\dots (1)
 \end{aligned}$$

ここで、 $p$ ：予測値  
 $X$ ：信号値

各信号が実測値を取る確率の負の対数尤度を異常度とする。実測値と予測値によって、異常度は式(2)で表される。

$$E = -x \log p - (1-x) \log(1-p) \dots\dots\dots (2)$$

ここで、 $E$ ：異常度  
 $x$ ：実測値( $x=0$ 又は $x=1$ )  
 $p$ ：予測値( $0 \leq p \leq 1$ )

稼働時には、全信号の異常度の合計を算出し、それがしきい値以上であるか否かによって非正常の判定を行う。しきい値は、例えば、正常データでの異常度の最大値で設定することが考えられる。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、ユーザーに提示できる。予測誤差を $\epsilon$ とし、予測誤差に対する異常度を図3に示す。この方式は、予測値を確率とみなして負の対数尤度を異常度とすることで、ユークリッド距離等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。




図3. 予測誤差に対する異常度

## 3. 実証実験

生産現場の様々な装置に開発方式が適用可能であるか検証する実証実験を実施した。具体的には、実装置へ適用した際の学習時間と検出時間、そして非正常検出可否(非正常発生時刻と非正常信号の特定)を確認する。

この検証では、漏電遮断器の組立てを行う製造ラインで稼働する遮断器組立て・試験装置と遮断器部品組立て装置を対象にして、各装置から収集する信号データの想定環境を表1に示す。また、2章で述べた方式に基づき非正常検出を行うプログラムの動作環境を表2に示す。さらに、この検証での目標性能を表3に示す。表3で、製造現場で許容可能と考えられる時間を学習時間の目標値として、リアルタイムでの非正常検出可能な時間を検出時間の目標値として設定した。

なお、装置で発生する正常でない事象を“エラー”と呼び、この方式が学習データとは異なると判断した事象を“非正常”と呼ぶことにする。

### 3.1 信号値の予測

対象装置から収集した正常な信号データを学習したところ、予測精度の低い信号データが幾つか存在することが判明した。予測精度の低い信号の特徴を次に示す。

- (1) プッシュボタン等人手の操作に応じて変化する信号
- (2) 他の装置の動作や、他の装置から送られる信号値に基づいて変化する信号
- (3) エラー発生時等動作サイクルと関係なく不定期に変化する信号
- (4) 変化の前兆が長時間(数十秒以上)前にある信号

表1. 想定環境

サンプリング周期 (ミリ秒)	使用信号数 <sup>(注1)</sup> (個)	学習データ量 (セット)
100	1~256	100~1,000

(注1) この方式で対象となる、定期的に変化のあるビット信号の数

表2. プログラムの動作環境

項目	内容
CPU	Intel Core <sup>(注2)</sup> i7-7700K CPU@4.20GHz
メモリ	64GB
OS	Windows <sup>(注3)</sup> 10 Enterprise 64bits
GPU	GeForce GTX <sup>(注4)</sup> 1080 Ti

(注2) Intel Coreは、Intel Corp.の登録商標である。  
 (注3) Windowsは、Microsoft Corp.の登録商標である。  
 (注4) GeForce GTXは、NVIDIA Corp.の登録商標である。

表3. 目標性能

学習時間	検出時間	検出精度
72時間以内	サンプリング周期以内	ライン停止エラーを100%検出

- (5) アナログ値を2進数で表現し、各桁のビット値を取り出した信号
  - (6) 短い間隔(10ミリ秒程度)でON/OFFを繰り返す信号
- (1)~(6)以外のビット信号は、精度良く変化を予測できており、この検証では、(1)~(6)に該当する信号データを対象から外した上で、学習及び非正常検出を実施した。

### 3.2 学習時間と検出時間

各装置の学習時間と検出時間の結果を表4に示す。なお、学習時間は、学習誤差の減少が収束するまでにかかる時間としている。装置ごとに使用する信号数や学習データ量に差異はあるが、全ての装置で目標とする学習時間及び検出時間の目標を達成する結果が得られた。

### 3.3 非正常検出結果

各装置で発生したエラーの種類数と、そのうち非正常検出ができたエラーの種類数及び割合を表5に示す。どちらの装置でも、発生したエラーに対して9割程度を検出した。

表4. 学習時間・検出時間

対象	使用信号数 (個)	学習時間 (分)	検出時間 (ミリ秒)
遮断器組立て・試験装置	237	360	全て100ミリ秒以内
遮断器部品組立て装置	119	190	

表5. 非正常検出結果

対象	エラー種類数 (個)	検出種類数 (個)	検出割合 (%)
遮断器組立て・試験装置	28	27	96
遮断器部品組立て装置	12	11	92




図4. 非正常検出例

### 3.4 考察

非正常検出について、エラー発生前後のデータに対して開発方式を適用した結果の一例を図4に示す。図4から、信号1~信号3は定常動作として予測した変化とは異なる非正常な信号変化になっており、開発方式によって、信号1~信号3を非正常変化がある信号と判断してそれぞれの信号と非正常変化箇所を検出している。

信号1~信号3は、非正常変化の検出時刻より後に発生したエラーに関連する信号であり、開発方式で、エラーに関連する非正常変化を適切に検出できたと言える。

一方で、エラー発生時の動作サイクルとは関係なく不定期に変化する信号(3.1節の(3)で示した予測対象外の信号)に関連するエラーについては検出できなかった。

このことから、予測対象とする信号で動作サイクルに応じた非正常変化が発生するエラーであれば、この方式で検出可能であると考えられる。

## 4. むすび

TDNNを利用した制御入出力信号の非正常検出技術について述べた。この技術は、生産設備のトラブル発生時の異常開始箇所を特定するものであり、実証実験によって、この技術が製造現場の装置へ適用可能であることを実証した。

非正常検出に関しては、9割程度の種類のエラーを検出しており、予測対象とする信号に動作サイクルに応じた非正常変化が現れるエラーであれば、この技術によってエラーに関連する信号及び信号変化を検出可能であることを確認した。また、学習時間と検出時間の面では、目標とする数値を達成し、製造現場の装置が対象であっても、十分な性能を実現できることを確認した。

この技術では、さらにアナログ信号も対象にできれば、ビット信号とアナログ信号の関係性から非正常検出し、装置の動作をより詳しく確認できるようになる。そのため、今後は、アナログ信号等の現状では対象にできない信号にも対応可能になるように方式の改良を目指す。

### 参考文献

- (1) Vodenčarević, A. et al.: Data Analytics for Manufacturing Systems, 2015 IEEE 20th Conference on Emerging Technologies & Factory Automation, 1~4 (2015)
- (2) 柴田昌彦, ほか: デジタル制御入出力信号の非正常検出方式の検討, 情報処理学会 第80回(平成30年)全国大会講演論文集(1), 157~158 (2018)