

AIを活用した時系列データ予測による設備異常予知システム

Equipment Trouble Prediction System by Time-series Data Prediction Utilizing AI

江 亦 然* 畠 中 伸 也*
Yiran Jiang Shinya Hatakenaka

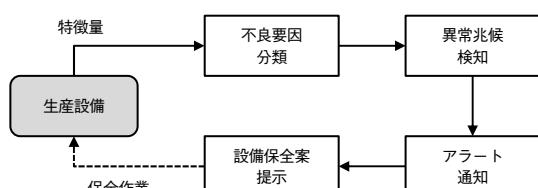
生産設備の品質・稼動ロスの削減のため、設備の異常を事前に予知し、かつ最適オペレーションを提示するシステムが現場に求められている。ディープラーニング技術の応用に着目し、時系列データを用いた将来の加工品の加工後の形状を予測するモデルを開発した。時系列データのノイズと急激な変動に対応するために、データに前処理を行い、より長期的な過去データを活用できるニューラルネットワーク構造を構築した。これにより、加工不良の発生を予測することで、設備異常の予知を実現する。

In order to reduce quality and operational losses in production equipment, a system that predicts equipment abnormalities in advance and presents the optimal operation is required at the manufacturing site. Focusing on the application of Deep Learning technology, we have developed a model that predicts the inspection data of future processed products using time-series data. For dealing with noise and rapid fluctuation of time-series data, we preprocessed the data and constructed a neural network structure that can utilize longer-term past data. This makes it possible to predict equipment trouble by predicting the occurrence of machining defects.

1. 設備異常予知システムの概要

モノづくり現場における設備を中心とした生産工程では、不良の発生につながるプロセスの変化を捉えて事前に設備保全案を提示し、適切に保全することで、品質ロスを削減しつつ設備稼動を向上させることが求められている。

開発した設備異常予知システムの処理フローを第1図に示す。



第1図 設備異常予知システム処理フロー

Fig. 1 Process flow of the equipment trouble prediction system

本システムでは、対象とする設備で加工、検査した加工品の検査データ、合否判定結果、および加工品の設計情報を利用し、傾向を監視して判断を行うことで、加工品の不良、および設備状態が異常になる兆候を検知する機能を提供する。また、異常傾向に基づく設備保全案を提示することで、熟練工ではなくても適切な予防保全を実施することが可能となり、品質と設備稼動の向上を支援することができるシステムとなっている。

現在は、社内の加工設備を用いて検証を進めている。

2. 設備異常予知システムの開発内容

検証中の複数の部材を積層する加工設備で生産される加工品の検査では、加工品端面の各部材の座標を計測し、その幾何学的位置関係に基づいて合否判定が行われる。この位置関係は、加工設備の摩耗や劣化、材料の品質の影響を受けて変化し、やがて不良の発生につながる。

設備内のスペースや保全作業性の確保、コストの問題により、異常検知のためにセンサを設置して設備データを取得することは困難であることが多い。本システムでは、加工品端面の幾何学的位置関係が加工設備の摩耗や劣化によって変化することを利用して検査データを不良の要因別に分類し、要因別に傾向を分析することで、設備異常の検知性能の向上、および作業者への適切な保全案の提示を実現した。

2.1 ディープラーニングによる不良要因分類

不良の分類には、ニューラルネットワークで学習した画像分類器を用いる。工場から収集した検査データから合否判定結果が不良と判定されたデータを抽出し、ラベル付けを行った画像を作成し、その一部を訓練データとして学習する。画像に付与するラベルは、部材の傾きやすれなど、幾何学的位置関係から判断可能な不良要因を付与することで、不良要因となる特徴が学習されるようにする。サイズが大きい検査結果の生画像を用いるのではなく、計測された座標から形状を特定できる最小限のサイズの画像を生成し、学習を容易にしている。

学習が容易なことから高性能なモデルを必要としない

* マニュファクチャリングイノベーション本部

マニュファクチャリングソリューションセンター

Manufacturing Solution Center, Manufacturing Innovation Div.

ため、運用時の処理負荷軽減のため比較的高性能でありながら、処理が高速なNetwork in Network[1] (NiN) モデルを採用している。また、画素数の縮小、およびネットワーク構造の簡素化による最適化を図っている。

学習した分類器を用いて、訓練に使用していない評価用の画像を分類した際の分類結果を第1表に示す。Case 1のモデルに対し、上記の最適化を図ったモデルがCase 2からCase 4である。Case 1からCase 3において誤分類された画像は、有識者が確認しても分類が困難なものであり、画像分類器として十分な分類精度を確保しつつ処理負荷軽減が可能なCase 3を運用モデルとして選択した。

第1表 検査データ分類結果

Table 1 Inspection data classification results

	Case 1	Case 2	Case 3	Case 4
モデル	NiN	NiN	NiN	NiN
層数	12	9	9	9
各CNN層のフィルタ数 Case1を1とした指數	1	0.5	0.5	0.5
画素数	128×128	128×128	96×96	64×64
正解数／対象数	546/551	545/551	545/551	536/551
精度 [%]	99.1	98.9	98.9	97.3

2.2 ディープラーニングによる異常兆候検知

本システムでは、既存の検査データをリアルタイムに監視することで、設備の異常度を3段階（正常、予兆、異常）で判断する。作業者は、判断結果をお天気マークで受け取ることで、例えば雨マークであれば直ちに対策を探らなければならない、ということに容易に気付くことができる。

設備の異常度の判断にはディープラーニングを用いた時系列モデルを使用している。過去の生産実績から、2.1節の画像分類器で要因別に不良を分類し、不良が多発する期間を異常期間として異常ラベルを付与する。次に、予兆のラベルを付与する期間を設定するため、生産実績を時系列に並べたデータから、異常期間の特徴が表現されている特微量データを生成する。この特微量は、熟練工が設備異常の判断に用いる生産実績の特徴に合わせて生成する。例えば、各加工品間で加工品端面の各部材の座標が大きくばらついている状態を設備異常と判断するのであれば、そのばらつきを最も適切に表現する特微量を生成する。そのうえで、異常期間の特徴と同じ特徴が出ている期間を予兆期間とし、予兆ラベルを付与する。それ以外の期間を正常期間として正常ラベルを付与し、上記の特微量の時系列データを学習することにより、熟練工に近い判断を実現している。

2.3 設備保全案の提示

設備の異常度が予兆、もしくは異常の場合、事前に作成

したFault Tree Analysisに基づくフローチャートから、異常要因を解決するための保全案を作業者に提示する。提示する保全案の元となる保全案のリストは、過去に実施した保全作業に基づいて作成する。このリストは、保全作業を実施するたびに更新されるようになっており、より適切な保全案を自動的に提示できるようにしている。

3. 時系列データ予測アルゴリズムの開発および検証

加工品の不良の予測、および設備状態異常の早期発見を実現するために、本章は前述の加工品の検査データの時系列変動をSeq2Seq [2] (Sequence to Sequence) モデルで学習して設備状態の異常を事前に予測する方法を説明し、検証結果を示す。

時系列変動において、3.1節で説明する移載ばらつき（ノイズ）、および3.2節で説明する突発不良（急激な変動）が存在している。これらの問題を解消するため、検査データに前処理を行い、より長期的な過去データを活用できる多層構造のSeq2Seqモデルを構築した。

3.1 データ前処理

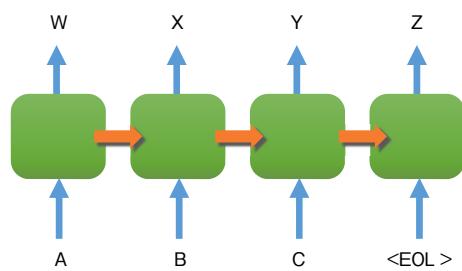
加工品の検査では、加工品を加工部から検査部に移載するプロセスがある。移載時に移載ばらつきが発生することにより、加工品端面の各部材の座標の計測値それぞれが移載ズレ分増減することになる。学習と予測において、このようなノイズに影響されないようにするために、データの前処理として、座標の計測値の差分を取ることにした。

また、予測結果を対策案（保全策）に紐（ひも）付け、適切なレコメンドの提示を実現するため、本アルゴリズムでは、座標の計測値から幾何学的な図形形状特徴を抽出して、計測値の差分と合わせて、学習と予測を実施している。

3.2 ニューラルネットワークの構成

本アルゴリズムでは、多層LSTM (Long short-term memory) のSeq2Seqモデルによりデータを学習している。

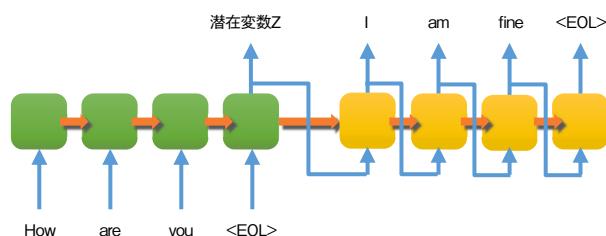
LSTMは、自然言語処理の分野で高い成果をあげ、最も注目されている再帰型ニューラルネットワーク（RNN）の一種である。RNN構造のイメージ図は、第2図に示している。データ（A, B, C）を順番に学習済みモデル（緑色ブロック）へ入力する時、学習済みモデルは、順番に予測結果（W, X, Y, Z）を出力する。予測結果は、毎回入力された値だけで計算することではなく、前回の入力によるモデルの内部状態も引き継がれて計算する。しかし、単純なRNNは直前の内部状態と入力にかなり依存している、いわゆる、短期記憶情報だけで処理している問題がある。この問題を解決するため、さらに、RNN構造に対して、長・短



第2図 RNNイメージ図
Fig. 2 RNN conceptual diagram

期記憶ユニットが追加され、LSTMというモデルが提案されており、現在のRNNの主流となっている。今回の検査データでは、突発不良（加工品検査データの急激な変動）が存在しているため、RNNを利用すると、予測結果が直近の突発不良に影響され、予測精度が落ちると考え、より長期的な過去データに依存するLSTMを採用する。

また、長期的な未来予測のため、本アルゴリズムは複数のLSTMで構成されたSeq2Seqモデルを利用している。Seq2Seqモデルは系列（Sequence）を別の系列へ変換するモデルであり、構造のイメージ図は第3図に示している。例えば、「How are you」の文字列（系列）を単語ごとに入力する時に、入力が終わった後に、「I am fine」の文字列が一齊に出力される。Seq2Seqモデルは自然言語処理だけでなく、一般の系列に対して利用できるモデルと考えられる。さらにデータから、より抽象的な特徴を抽出できるため、本アルゴリズムでは多層LSTM構造のSeq2Seqモデルを構築し、実験を実施した。



第3図 Seq2Seqイメージ図
Fig. 3 Seq2Seq conceptual diagram

3.3 予測実験

今回はリアルデータを参考にして、リアルデータに近い時系列データを120系列作成した。一系列表は、500個の加工品の検査データで構成される。100系列表を学習データとして、残りの20系列表をテストデータとして、Seq2Seqモデルの予測実験を実施した。データの前処理による効果確認のため、前処理されていない座標の計測値も同条件で学習した。

3.4 実験結果

連続100個の加工品の座標の測定値をテストデータから抽出し、前処理した後に、学習済みモデルに入力する。学習済みモデルから出力された次の100個の加工品に対する座標の予測値を実際のデータと比較し、予測値が実際のデータと一致しているかどうかを確認した。結果として、加工品端面の座標の計測値が徐々に変化している場合、予測結果が実際のデータとほぼ一致した。また、前処理されていない座標の計測値の予測結果と比較し、予測データのロス（実際のデータと予測値の差）が0.0016から0.0003までに減少したことを確認した。

本節では、加工品端面の座標計測値と計測値の幾何学的な图形形状の特徴を用い、再帰型ニューラルネットワークで学習、予測することで、加工品不良の事前予測を検証した。

4. 今後の取り組みと展望

実生産においては、材料交換、および設備調整などによる測定値の変化が予測に影響を与える可能性があるため、運用検証による精度向上の積み上げを進めていく必要がある。

実用化が図れれば、プレス、および成型、プロセス装置などさまざまな加工工程において応用展開が期待できる。

参考文献

- [1] Min Lin et al., "Network in Network" arXiv: 1312.4400v3, Mar. 2014, <https://arxiv.org/abs/1312.4400>, 参照 Oct. 26, 2020..
- [2] Ilya Sutskever et al., "Sequence to sequence learning with neural networks." Advances in neural information processing systems. 2014, <https://papers.nips.cc/paper/5346-sequence-to-sequence-learning-with-neural-networks.pdf>, 参照 Oct. 26, 2020.