

圧延工程における多変量時系列センサデータの教師あり温度異常検知 Supervised Temperature Anomaly Detection of Multivariate Time Series Sensor Data in Hot Rolling Processes

井上 裕仁^{*1}
Yuto Inoue

関本 真康^{*2}
Masayasu Sekimoto

新居 稔大^{*2}
Nii Toshihiro

今成 宏幸^{*2}
Hiroyuki Imanari

小原 一浩^{*2}
Kazuhiro Ohara

内田 真人^{*1}
Masato Uchida

概要

本研究の目的は、金属の加工方法である圧延において温度異常を高精度に推定することである。温度異常は金属の品質に悪影響を及ぼし、工場の操業停止などの重大な問題を引き起こすため、事前に検知する必要がある。従来の研究では圧延前に設定された静的特徴量を用いることが一般的であったが、本研究では圧延工程中に得られる時系列特徴量を活用することを目指す。しかし、時系列データに対して単純に LSTM (Long Short-Term Memory) を適用した場合、精度の高い異常推定は達成できなかった。これは、時系列データの中に非定常なデータが含まれていることが原因と考えられる。そこで本研究では、時系列データを適切に分割する手法を提案し、これにより LSTM の分類性能を向上させることを示す。

1 序論

圧延とは、回転する複数のロールの間に金属を通して引き延ばし、その形状を加工するプロセスである。熱間圧延では、工程中で温度目標が定められており、これを達成するよう設備の初期設定や圧延中の制御が行われる。温度目標からの逸脱、つまり温度異常が発生した場合、異常の度合いやその特徴に応じた対策を講じるが、その判断は熟練者の分析に依るところが大きい。そのため、異常およびその特徴を、事前情報から高精度に推定する技術が求められている。

従来の研究では、圧延前に設定されている静的特徴量(例: ロールの半径や回転速度)を用いた分類が行われている [1]。これらの特徴量に対して、決定木ベースの分類器やディープニューラルネットワークを用いることで、一定の精度が担保されている。しかし、これらの特徴量は過去のデータに基づいて設定されているため、動的な変化に対応することは難しい。そこで本研究では、静的特徴量に加えて、圧延工程中に取得される時系列特徴量を活用することを提案する。圧延工程中のデータから得られる特徴量を活用することで、圧延中の変化を動的に捉えることが可能となる。この時系列特徴量は、圧延材の温度を測定するセンサから得られるものであり、圧延途中の温度データを活用することで、圧延完了後の異常を検知する。これにより、従来の静的特徴量のみでは捉えられないリアルタイムの変化に対応した異常検知が可能となり、品質異常の要因分析につながる手段の提供が期待できる。

異常検知タスクには大きく分けて二つのアプローチが

ある。入力データと対応する正解ラベルを用いる教師あり学習と、正解ラベルが与えられない状態でデータの潜在パターンを学習する教師なし学習である。異常検知タスクでは、正常データと異常データの数に偏りがあるため、教師なし学習が適している場合が多い。例えば、教師なし学習の一つであるオートエンコーダを用いた異常検知 [2] では、正常データのみを訓練データとして使用するため、不均衡データに対して効果的である。

一方で、圧延により製造される鋼板の品質異常には、様々なパターンがある。品質指標の一つである温度でも、例えば、鋼板の長手方向先端から尾端にかけて温度が高くなり、目標温度を逸脱するものや、温度が低くなり、目標温度を逸脱するもの等の異常がある。これらの異常は、それぞれ異なる原因と影響を持つため、異なる異常検出アプローチが必要である。例えば、温度上昇の異常は、圧延過程で圧延材の温度が通常の範囲を超えて上昇する場合に発生するものであり、圧延速度が速すぎる、または冷却システムが適切に機能していないことが原因である可能性がある。過剰な加熱は、圧延材の特性を変化させ、最終製品の品質に悪影響を及ぼす。また、温度下降の異常は、圧延過程で圧延材の温度が通常の範囲を下回る場合に発生し、加熱システムの故障や圧延速度が遅すぎるものが原因である可能性がある。低温では、圧延材が硬くなりすぎて加工が難しくなり、品質に影響を与える。これらの異常には異なる原因と対策が必要なため、別々の異常として分類する必要がある。

そこで本研究では、温度に関する異常のうち、鋼板の先端から尾端にかけて温度が高くなり目標温度を逸脱する温度上昇の異常と、温度が低くなり目標温度を逸脱する温度下降の異常の 2 つの異常に着目した。そのため、正常ラベルと、温度上昇の異常ラベル、温度下降の異常ラベルの 3 つのラベルに対する分類問題とした。教師なし学習では、正常と異常の 2 クラス分類は可能であるが、二つの異常ラベルを区別するのは難しい。そのため、正常ラベルと二つの異常ラベルを正確に分類するために、教師あり学習を採用する。

時系列データの分類において、教師あり学習を用いる手法は多岐にわたる。代表的な手法として、距離ベース [3]、特徴量ベース [4]、および深層学習ベースの手法がある。距離ベースの分類の代表例には、k 近傍法が挙げられる。k 近傍法を用いた時系列分類では、ユークリッド距離やダイナミックタイムワーピング (DTW) [5] などの距離尺度を用いて、時系列データ間の距離を計算し、最も近いデータをもとに分類を行う。この手法の弱点は、ノイズデータに対して脆弱である点である。特徴量ベースの分類では、時系列データから有用な特徴量を抽出し、これをサポートベクターマシンやランダムフォレストなどの機械学習モデルに入力して分類を行う。しかし、特徴量の選択が分類精度に大きな影響を与えるため、適切

*1 早稲田大学

Waseda University, Tokyo, Japan.

*2 株式会社 TMEIC

TMEIC Corporation, Tokyo, Japan.




図 1 圧延イメージ図

な特徴量選択が重要となる。深層学習ベースの手法では、再帰型ニューラルネットワーク (RNN) やその発展形である長短期記憶 (LSTM) [6] が代表的である。RNN は時系列データの短期的な特徴を捉えるのに適しているが、長期的な依存関係を捉えるのは難しい。一方、LSTM は長期的な特徴を捉えることに優れており、時系列データの解析において強力なツールとなる。そのため、本研究では LSTM を用いた分類モデルを提案する。

本研究では、熱間圧延設備の上流側に設置された複数の温度センサから得られる時系列データを用いて、圧延終了後の製品に発生するであろう温度の異常を予測する。なお圧延終了後の製品温度は、圧延設備の下流側に設置された温度計による測定値を想定する。この多変量センサ時系列データの分類に対して、LSTM モデルを活用する。しかし、1 つの圧延材に対する加熱や冷却の条件が異なるため、数百 m にも及ぶ長さの圧延材の全長にわたる温度変動のパターンが異なることも多い。LSTM は長期的な依存関係を捉えるのに優れているが、異なるパターンが混在するデータセットでは学習が難しく、センサデータをそのまま LSTM に入力するだけでは、高い分類精度を得ることはできない。そのため、本研究では、圧延材全長の時系列データを適切に分割し、それぞれの部分のデータを個別に解析することで、分類精度の大幅な向上が期待できることを示す。

ベースラインモデルとして、時系列データを用いたモデルと静的特徴量を用いたモデルを用意した。時系列データのベースラインモデルには、代表的な分類手法である距離ベースの分類モデル、特徴量ベースの分類モデル、そして LSTM モデルを使用した。一方、静的特徴量を用いたベースラインモデルには、決定木ベースのモデルを使用した。以後、時系列データの分割などの工夫を施していない分類モデルを「LSTM」、工夫を施した分類モデルを「提案手法」と表記して区別することとする。本論文では最終的に、時系列データを用いた提案手法と静的特徴量を用いた分類手法をアンサンブルすることで、より高い性能を実現できることを示す。

本論文の構成は以下の通りである。まず、2 節では熱間圧延について説明する。次に、3 節では、時系列データに対して強みを発揮する深層学習モデルである LSTM、および圧延における静的特徴量を用いた研究について説明する。その後、4 節で使用データについて、5 節で提案手法について説明し、6 節では、実験結果について述べる。最後に、7 節では、本論文のまとめを行う。

2 熱間圧延

図 1 は熱間圧延工程の概略を示しており、圧延材は左から右へと流れていく。熱間圧延では、加熱炉で 1200 °C 程度まで加熱されたスラブを、粗圧延、仕上げ圧延に備わる圧延機にて幅方向および厚み方向へ圧延した後に、ランナウトテーブルにて冷却し巻き取り機で巻き取り、製

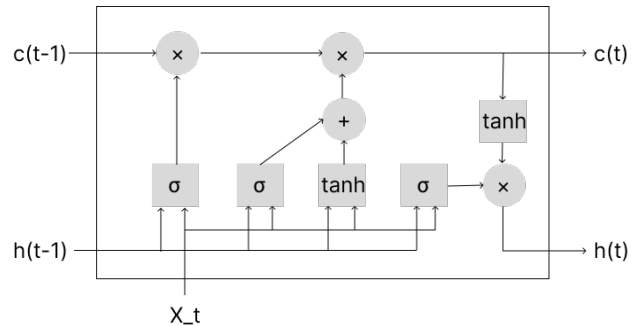


図 2 LSTM

品コイルを製造するラインである。熱間圧延ラインでは、圧延材の温度を測定するセンサが複数備わっている。温度センサは、粗圧延機入側温度 (RET)、粗圧延機出側温度 (RIDT、R2DT)、仕上げ圧延機入側温度 (FET)、仕上げ圧延機出側温度 (FDT) を測定するために、それぞれの場所に設置される。それぞれのセンサは、圧延材の先端から尾端にかけての温度を周期的に測定しており、時系列データが得られる。

本研究では、温度品質異常として 2 種類のラベルを対象とした。第 1 の異常ラベルは、圧延材の中盤部分の時系列データを 1 次近似した際に、温度変化が +20 °C を超えるものである。すなわち、圧延材の先端から尾端にかけて温度が 20 °C 以上上昇する場合である。第 2 の異常ラベルは、同様に圧延材の中盤部分の時系列データを 1 次近似した際に、温度変化が -20 °C を超えるものである。これは、圧延材の先端から尾端にかけて温度が 20 °C 以上下降する場合である。この二つの異常ラベルと正常ラベルを用いて、三値分類問題として取り扱う。

3 関連研究

3.1 LSTM

LSTM (長短期記憶) [6] は、再帰型ニューラルネットワークの一種であり、特に時系列データに対して強みを発揮するニューラルネットワークである。図 2 に示すように、LSTM は長期的なトレンドを捉えるセル c と短期的なトレンドを捉える隠れ状態 h を持ち、忘却ゲート、入力ゲート、出力ゲートの 3 つのゲートを組み合わせることで構成されている。これにより、長期的な依存関係を保持しつつ、不要な情報を忘却することができ、高精度な時系列予測を可能にしている [7]。

それぞれのゲートでの出力とセルでの出力は以下のよう表される。ここで σ はシグモイド関数、 W は重み、 b はバイアス、そして \odot はアダマール積を表す。式 (1)

は入力ゲート i_t , 式 (2) は忘却ゲート f_t , 式 (3) は出力ゲート o_t , 式 (4) は新たなセルの入力 \tilde{c}_t を示している。これらの出力をもとにして, 式 (5) においてセル c そして式 (6) において隠れ状態 h を得る。

$$i_t = \sigma(W_{ii}X_t + W_{hi}h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{if}X_t + W_{hf}h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(W_{io}X_t + W_{ho}h_{t-1} + b_o) \quad (3)$$

$$\tilde{c}_t = \tanh(W_{ig}X_t + W_{hg}h_{t-1} + b_c) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

LSTM を用いた時系列データの予測や分類は, さまざまな分野に応用されている。例えば, 医療 [8], 交通システム [9], 株価予測 [10] などが挙げられる。

3.2 圧延工程における温度予測

Hwang ら [1] の研究では, 圧延工程における圧延力と圧延材の温度の予測が行われている。圧延工程では, 圧延材をロールの間に通して目標の板厚になるまで引き伸ばす。この際, 目標とする板厚を得るためには, 圧延力 (ロールで挟み込む力) を事前に設定する必要がある。この圧延力は圧延工程を数回に分割し, その分割された各工程において設定される。各工程における圧延力の設定は, 圧延材の品質に直結するため, 非常に重要である。

まず, Hwang らは圧延力のみを予測する機械学習モデルを作成した。しかし, 圧延工程は複数の段階に分かれており, 各段階での出力が次の工程に影響を及ぼすため, モデルの安定性に問題があった。特に, モデルに異常な入力変数が含まれる場合, 誤った出力がされてしまうという問題があった。これを解決するために, 各工程における温度を予測するモデルも作成し, 温度が異常値を示した場合には温度に依存する特徴量に制限を設けることで, 圧延力を制御する方法を導入した。

さらに, Hwang らは圧延力と温度の予測にディープニューラルネットワークと勾配ブースティングに基づく決定木モデルを採用した。モデルへの入力には, 圧延工程における静的な特徴量 (例えば, ロールの半径や圧延機の回転速度) を使用し, これらの既存の特徴量に算術演算を施して新たな特徴量も作成した。

従来の研究では, 予測モデルの入力として静的特徴量や圧延材表面の代表点のみが多く用いられてきた [11]。本研究では, 圧延材の表面温度の代表点ではなく, 時系列データを用いる。静的特徴量だけでなく, 圧延材の表面温度の時系列データを使用することで, より精度の高い予測が可能となる。ただし, 時系列データを単純なニューラルネットワークや古典的なモデルへの入力として用いることは困難である。そのため, 本研究では, 時系列データに対して強みを発揮する LSTM を用いて異常検知を行う。

4 対象データの特徴と処理

4.1 データの構造

本研究では, 圧延されたコイルごとのデータを扱う。ここで, コイルの総数を N とする。このコイルごとのデータには, 以下の三つの特徴量が含まれている。

一つ目は, 静的特徴量である。静的特徴量は, 圧延工程前に設定された値を指し, 本研究では 51 種類の特徴量が含まれている。 n 番目のコイルの静的特徴量を s_n と表す。

二つ目は, 時系列特徴量である。この時系列特徴量は, 圧延工程中に設置された複数の温度センサから得られたもので, それぞれの時系列データはコイルの先端から尾端にかけての温度分布を示す。センサが複数設置されているため, データは多変量時系列データとなり, その変量を m とする。本研究では, 各センサの時系列長を統一しており, この長さを L と設定する。 n 番目のコイルの時系列データを $X_n^{m,L}$ と表す。

三つ目は, 正解ラベルである。圧延後の圧延材の温度分布が先端から尾端にかけて大きく下降している場合, または大きく上昇している場合を異常として定義する。温度の大幅な下降とは, これは, 圧延材の前半 20 % から 80 % の時系列データを 1 次近似したときに温度が 20 °C 以上低下したものである。温度の大幅な上昇とは, 圧延材の前半 20 % から 80 % の時系列データを 1 次近似したときに温度が 20 °C 以上上昇したものである。正常ラベルを c_0 , 温度が下降する異常ラベルを c_1 , 温度が上昇する異常ラベルを c_2 とし, n 番目のデータの正解ラベルを y_n とすると, $y_n = \{c_0, c_1, c_2\}$ と表すことができる。 c_0, c_1, c_2 はいずれか 1 つのみが 1 となり, 残りの二つは 0 となるため, y_n は One Hot ベクトルとなる。

これら三つの特徴量を統合すると, データセット D は次のように表される。

$$D = \{s_n, X_n^{m,L}, y_n\}_{n=1}^N$$

このデータセット D を用いて, 説明変数 s_n と X_n から目的変数 y_n を予測する。

4.2 データの前処理

本研究で使用するデータは, 6349 本分の圧延で得られたデータである。このデータには, 説明変数として, 圧延工程前の静的特徴量および圧延工程中に 4 つの温度センサから取得された時系列データが含まれる。したがって, $m = 4$ および $N = 6349$ である。また, 目的変数として圧延工程後に得られた温度センサの時系列データも含まれる。しかし, 各センサにおける時系列データには測定誤差などの問題があり, そのままの形で用いることができない。そこで本研究では, 以下の三つの前処理を施した。

一つ目の前処理として, 各センサにおける時系列データの長さを統一する。圧延材の長さは各センサ毎に異なるため, 時系列データの長さも異なっているが, 分類モデルに多変量時系列データを入力する際には, 時系列長を統一する必要がある。圧延工程では, 圧延材は均一に伸ばされるため, 時系列長を統一することで圧延材の同一位置における温度変化を正確に捉えることができる。この統一により, 各センサ間での特徴を一貫して解析できると考えられる。本研究では, 各センサの時系列データを線形補間により統一し, すべてのセンサでの時系列長を 1000 に揃えた ($L = 1000$)。

二つ目の前処理として, 温度が自然に低下する特定のセンサデータに対して対数差分変換を行う。この現象は, 特に FET センサにおいて観察される。FET センサのみがこのような温度低下を示すと, 他のセンサデータとの条件が異なり, 一貫性が失われる問題が生じる。この問題を解決するために, 対数差分変換を用いる。対数差分変換により, 温度低下の影響を軽減し, 各センサ間の条件を統一することができる。対数差分変換前の時系列データを $\{a_n\}_{n=1}^N$, 対数差分変換後の時系列データを $\{z_n\}_{n=1}^N$ とし, この変換は次のように表される。

$$z_{n-1} = \log a_n - \log a_{n-1}, n = 2, 3, \dots, N$$




図 3 提案手法の流れ

この対数差分変換を適用することで、温度低下の影響を減らし、各センサ間のデータ条件を整えることができると考えられる。

三つ目の前処理として、線形補間を行う前に各センサの時系列データにおいて温度が 20 °C 以上低下した時点で、それ以降の時系列データを削除する処理を施した。これは、圧延材がセンサを通過した後も温度測定が続けられ、その後の測定値が一定となるデータが存在するためである。

これら三つの前処理を行うことで、圧延における各センサの時系列データを整え、時系列長が統一された多変量時系列データを作成することができる。

5 提案手法

本研究において、LSTM モデルをそのまま用いると高精度な分類が困難であると考えられる。これは、圧延材全長の温度分布が異なり、温度時系列データが非定常である点と、異常検知タスクであるために正常ラベルと異常ラベルの数に大きな偏りがあることが問題となるためである。これらの課題に対処するため、本研究では二つの工夫を施した上で LSTM モデルを用いることで分類精度を向上させることを目指す。

5.1 時系列データの分割

提案手法を三つのステップに分けて説明する。まず、データの前処理に加えて、時系列データの分割を行う。前処理により時系列長を 1000 に統一した後、ウィンドウサイズ W を設定し、データを分割する。時系列の後半部分では、前処理の一環としてセンサ抜けへの対処が行われるが、さらに尾端のデータ削除も実施する。これは、センサ抜けの傾向が残るデータが含まれているためである。このようにして、1 本の圧延材は時系列長が W のデータ 1000 - W 個に分割される。分割された時系列データに対しては、正常データにはラベル 0、温度が下降する異常データにはラベル 1、温度が上昇する異常データにはラベル 2 を付与する。

次に、LSTM モデルを用いて学習を行う。入力として 4 変量で時系列長 W のデータを用い、出力としてラベルを予測する。最適化アルゴリズムには Adam を使用し、誤差関数には交差エントロピー誤差を採用する。これにより、モデルが各ウィンドウ内のデータから適切にラベルを予測することが可能となる。

最後に、全結合層を用いて最終的な予測ラベルを出力する。1 本のコイルに対して 1000 - W 個のラベルが得られるため、それぞれのラベルの予測確率を集計し、最終的な予測ラベルを決定する。このプロセスにより、時系列データの各部分に基づいた予測を統合し、全体としての予測精度を向上させることができる。これらの工程を図 3 に示す。

時系列データを分割することにより、非定常なデータ

の分類が容易になる。特に温度が低下する異常については、時系列データの前半から中盤にかけて温度が大きく低下し、後半では温度が上昇するパターンが多く含まれている。このため、時系列データ全体で温度変化を予測するよりも、データを分割して圧延の前半、中盤、終盤での温度変化を個別に予測し、それらの予測を統合することで、より高精度な分類が可能となる。

5.2 損失関数への重み付け

データが不均衡である問題に対処するために、損失関数に対して重み付けを行う。三値分類問題であるため、それぞれのラベルに対する重みを $w = [w_0, w_1, w_2]$ と設定する。本研究では、交差エントロピー誤差を使用しており、損失関数 E は真のラベル $y = [c_0, c_1, c_2]$ 、予測ラベルの確率分布 $p = [p_0, p_1, p_2]$ として以下のように表すことができる。

$$E = - \sum_{i=0}^2 w_i y_i \log(p_i)$$

ここで、真のラベルが c_0 の場合 $y = [1, 0, 0]$ 、真のラベルが c_1 の場合 $y = [0, 1, 0]$ 、真のラベルが c_2 の場合 $y = [0, 0, 1]$ とする。この重み付けにより、ラベルの不均衡を考慮した損失関数を実現され、異常データに対する予測精度の向上が期待できる。

6 評価実験

6.1 比較手法の設定

本研究では、温度センサから得られた時系列データを用いて異常検知を行うため、時系列データを用いたベースラインモデルを三つ、静的特徴量を用いたベースラインモデルの一つ用意した。

時系列データの分析における代表的な手法として、距離ベースの分類、特徴量ベースの分類、深層学習ベースの LSTM モデルの三つをベースラインモデルとして採用した。これらのベースラインモデルでは、5 節で行った時系列データの分割は行わずに、4 変量で時系列長 1000 のデータを入力し、ラベルを出力する設定とした。距離ベースのモデルでは、機械学習ライブラリ `sktime` を用いて、距離尺度としてユークリッド距離を採用し、 $k = 5$ の k 近傍法を用いて分類を行った。特徴量ベースのモデルでは、`sktime` の `Summary Classifier` を使用して時系列データから特徴量を抽出し、その特徴量を用いてランダムフォレストで分類を行った。最後に、深層学習ベースの LSTM モデルでは、提案手法と同じ設定を用いながらも、時系列データの分割は行わない形で実装した。

静的特徴量を用いた分類では、圧延工程前に設定された特徴量を使用した。先行研究でも用いられていた決定木ベースの分類モデル `lightgbm` を採用し、分類を行っ

表 1 モデルの性能比較

手法	mPre	mRec	mF1
距離ベース	0.498	0.427	0.453
特徴量ベース	0.498	0.381	0.406
LSTM	0.516 ± 0.072	0.472 ± 0.039	0.448 ± 0.035
決定木ベース	0.553	0.428	0.465
提案手法	0.514 ± 0.064	0.543 ± 0.079	0.524 ± 0.067
アンサンブル	0.674 ± 0.050	0.490 ± 0.080	0.530 ± 0.088

た。ハイパーパラメータの選択は、ランダムに選択したデータセットを用いて最も高い精度を示したものを使用した。本研究での設定は、学習率を 0.01、ブースティングの反復回数を 150、葉ノード数を 6 とした。

このように、異なるアプローチを用いたベースラインモデルを設定することで、提案手法の有効性を多角的に検証することができる。

6.2 提案手法の設定

評価実験における提案手法の設定について説明する。ウィンドウサイズは $W = 20$ 、損失関数の重みは $w_0 = 1.0$ 、 $w_1 = 50.0$ 、 $w_2 = 80.0$ に設定した。これらの重みは、ランダムに抽出した 1000 本のコイルデータに基づいて設定している。データのラベル分布は、ラベル 0 が 969 本、ラベル 1 が 18 本、ラベル 2 が 13 本であり、このラベルの発生頻度に基づいて重み付けを行った。

さらに、分類精度を向上させるために、静的特徴量を用いた決定木ベースの分類モデルと、時系列特徴量を用いた LSTM モデルをアンサンブルした。アンサンブルは、各モデルが出力する分類ラベルに対する確信度に基づいて行う。確信度とは、モデルが出力に対してどれだけ自信を持っているかを示す指標である。LSTM モデルの確信度は、全結合層での予測確率によって表される。アンサンブルの方法としては、各モデルの確信度の重み付き平均を取る。決定木モデルと LSTM モデルの重みをそれぞれ w_l 、 w_p 、確信度を c_l 、 c_p 、アンサンブル結果の確信度を c_e とすると、次の式で表される。

$$c_e = \frac{w_l c_l + w_p c_p}{w_l + w_p}$$

この重み w_l と w_p は、検証データに対して最も性能が良くなるように調整した。

6.3 実験結果

本論文では、過去のデータから未来の異常を検知するために、以下のデータセットを使用した。6349 本分の圧延データを、得られた期間の古い順から最初の 4000 本を訓練データ、次の 1000 本を検証データとして最後の 1349 本をテストデータとした。訓練データを用いてモデルを作成し、テストデータでの分類結果をもとに精度の比較を行った。

評価指標としては、不均衡な三値分類問題に対応するため、平均適合率 (mPre)、平均再現率 (mRec)、およびそれらの調和平均であるマクロ F1 (mF1) を使用した。時系列データのベースラインモデルとして、距離ベースのモデル、特徴量ベースのモデル、深層学習ベースのモデルを用いた。また、静的特徴量のベースラインモデルとして決定木ベースのモデルを用い、提案モデルおよびアンサンブルモデルとの性能を比較した。LSTM モデル

に関しては、6 回のモデル学習を行い、学習結果に基づく評価値の平均と標準偏差を求めた。そして提案モデルに関しては、LSTM での学習を 3 回、それぞれの学習結果に対して全結合層の学習を 2 回行うことで、計 6 回のモデル学習を行った。そして、それぞれの学習結果に基づく評価値の平均と標準偏差を求めた。そのためアンサンブルモデルは、1 つの決定木ベースのモデルと 6 つの提案モデルをそれぞれアンサンブルを行い、評価値の平均と標準偏差を求めた。各モデルの分類結果の性能比較を表 1 に示す。

まず時系列データを用いた分類モデルについてみていく。提案手法のモデルは他の距離ベース、特徴量ベースそして LSTM の分類モデルと比較すると、すべての指標において精度が高くなっていることが分かる。時系列データの分割を行っていない LSTM モデルより良い分類精度となっていることから、時系列データを分割することが LSTM が時系列データの特徴を捉える上で良い影響を与えたといえる。

次に、時系列データを用いた分類モデルと静的特徴量を用いた分類モデルの比較を行う。静的特徴量を用いた決定木ベースのモデルは提案手法以外の分類モデルと比較すると良い精度で分類できていた。提案手法と決定木ベースの分類モデルの精度を比較すると、提案手法のモデルの精度が良くなっている。ここから、提案手法の分類モデルは従来の研究で提案されてきたモデルと比較しても良い精度で分類できていることが分かる。

そして最後に、アンサンブルモデルについてみていく。提案手法と決定木ベースの分類モデルをアンサンブルすると、mRec と mF1 の指標において良い性能となった。これは、それぞれ別の特徴量を用いており、それぞれの特徴量の良い部分を抽出できたと考えられる。一方で、mRec に関して提案手法と比較して劣っている。これは決定木ベースでの分類モデルの mRec の値が低く、これに影響を受けたためだと考えられる。

7 結論

本論文では、金属の加工方法の一つである圧延における温度の品質異常に着目し、正常ラベルと二つの異常ラベルを含む三値分類問題に取り組んだ。従来の研究では、圧延工程における静的特徴量を用いた分類が主流であったが、本研究では、圧延過程に設置された温度センサから得られる 4 本の時系列データを用いた分類に焦点を当てた。

まず、ベースラインモデルとして距離ベースの分類モデル、特徴量ベースの分類モデル、そして LSTM モデルを用いて分類を行った。しかし、いずれのベースラインモデルも高い精度で三値分類を達成することはできなかった。そこで、近年時系列データの分析で高い精度を示している LSTM モデルに改良を加えることで、精度の

向上を図った。

提案手法では、圧延終了後の時系列データを分類モデルに入力する前に分割し、それぞれの分割されたデータを予測した後、最終的に全結合層を用いて統合する方法を採用した。この方法により、LSTM モデルの分類精度が向上することを示した。提案手法と従来の LSTM モデルの性能を比較した結果、提案手法の方が優れていることが確認された。これは、時系列データの前半部分、中盤部分、後半部分における温度変動の傾向の違いを考慮できたためであると考えられる。

また、提案手法のモデルの性能は、静的特徴量を用いた決定木ベースの分類モデルと比較しても高いことが示された。その上で、静的特徴量を用いた分類モデルと提案モデルを確信度に基づいてアンサンブルすることで、さらに精度が向上することも確認された。これは、それぞれの分類モデルが異なる特徴を捉えているためであると考えられる。

以上の結果から、本研究で提案した時系列データの分割および統合手法は、圧延工程における温度の品質異常検知において有用であることが示された。

参考文献

- [1] Rakhoon Hwang, Hyeontae Jo, Kyung Seok Kim, and Hyung Ju Hwang. Hybrid model of mathematical and neural network formulations for rolling force and temperature prediction in hot rolling processes. *IEEE Access*, 8:153123–153133, 2020.
- [2] Unsupervised deep anomaly detection for multi-sensor time-series signals. *IEEE Transactions on Knowledge and Data Engineering*, 35:2118–2132, 2 2023.
- [3] C. Orsenigo and C. Vercellis. Combining discrete svm and fixed cardinality warping distances for multivariate time series classification. *Pattern Recognition*, 43:3787–3794, 2010.
- [4] Ben D. Fulcher and Nick S. Jones. Highly comparative feature-based time-series classification. 1 2014.
- [5] Donald J Bemdt and James Clifford. Using dynamic time warping to find patterns in time series, 1994.
- [6] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 1997.
- [7] Felix A. Gers, Jürgen Schmidhuber, and Fred Cummins. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10):2451–2471, October 2000.
- [8] Yuxin Zhang, Yiqiang Chen, and Zhiwen Pan. A deep temporal model for mental fatigue detection. pages 1879–1884. Institute of Electrical and Electronics Engineers Inc., 7 2018.
- [9] Xiaolei Ma, Zhimin Tao, Yinhai Wang, Haiyang Yu, and Yunpeng Wang. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54:187–197, 5 2015.
- [10] Thomas Fischer and Christopher Krauss. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270:654–669, 10 2018.
- [11] Zhuolun Zhang, Bailin Wang, Shuaipeng Yuan, Yiren Li, Jiahui Yu, Tieke Li, and Xiqing Wang. Deep learning-based prediction framework of temperature control time for wide-thick slab hot rolling production. *Expert Systems with Applications*, 227, 10 2023.