

(解説)

# 鋼板製造工場の冷却工程への深層ニューラルネットワークを用いた巻取温度制御技術の適用

佃 岳洋\*<sup>1</sup>・原田 駿\*<sup>1</sup>・樋口真之\*<sup>2</sup>・長谷川裕之\*<sup>2</sup>・逢坂武次\*<sup>3</sup>・森居数広\*<sup>3</sup>

## Application of Coiling Temperature Control Technology Using Deep Neural Network to Cooling Process in Steel-plate Manufacturing Plant

Takehiro TSUKUDA・Shun HARADA・Masayuki HIGUCHI・Hiroyuki HASEGAWA・Taketsugu OSAKA・Kazuhiro MORII

### 要旨

熱間圧延の冷却工程における巻取温度は鋼板の機械的特性を決定する重要な要素であるため、非常に高い制御精度が要求されている。これを実現するためには、鋼板に注水する冷却水量を決定するための鋼板の温度予測モデルを高精度化することが不可欠であり、今回、AI手法の一つである深層ニューラルネットワークを用いた温度予測モデルを開発・導入した。その結果、ハイテン系の鋼板を中心に巻取温度の制御精度が大幅に向上した。さらには、操業部門において新しい予測モデルの効率的かつ柔軟な運用が定着化しており、スタッフや製造現場のオペレータの業務において大きな変革が起きている。

### Abstract

In the cooling process of a hot strip mill, the coiling temperature is a crucial factor that determines the mechanical properties of steel plates and therefore requires extremely high control accuracy. To achieve this, it is essential to improve the accuracy of the temperature prediction model for the steel plates, which determines the amount of cooling water to be injected. In this study, a temperature prediction model using a deep neural network, one of the AI methods, has been developed and introduced. As a result, the control accuracy of the coiling temperature, especially for high-tensile steel plates, has significantly improved. Furthermore, in the operational department, an efficient and flexible operation of the new prediction model has been established, leading to significant changes in the tasks of staff and operators at manufacturing sites.

### 検索用キーワード

熱間圧延, 巻取温度, CT, AI, 深層ニューラルネットワーク, 技術継承

まえがき = 熱間圧延の冷却工程は当社ビジネスの主力の一つである薄板製品<sup>1), 2)</sup>の品質・機械的特性に多大な影響をおよぼす。中でも、巻取機前の巻取温度 (Coiling Temperature ; CT) は、最も重要な要素であり、高精度に制御することが強く求められている。CTを制御するために、冷却工程専用のプロセスコンピューター (以下プロコンと呼ぶ) において、鋼板の温度予測モデルに基づき、冷却設備から鋼板に注水する冷却水量を決定している。しかし従来、鋼板温度の高精度な予測、かつその維持が難しく、CTの制御精度低下が問題となっていた。そこで今回、この課題を解決するために、深層ニューラルネットワーク<sup>3)</sup>を用いた温度予測モデルを開発・導入した。

本稿では、深層ニューラルネットワークを用いた巻取温度制御開発の経緯・概要や運用方法、さらには開発・導入による操業部門での業務の変革について述べる。

## 1. 深層ニューラルネットワークを用いた巻取温度制御開発の経緯

### 1.1 巻取温度制御の概要

熱間圧延工程での仕上圧延機と巻取機の間にある冷却

設備の概要を図1に示す。本冷却設備では、鋼板の上下から注水する複数の冷却ヘッダーが設けられており、各ヘッダーには開閉の動作を行うシリンダーバルブが取り付けられている。プロコンは、仕上圧延機出側での鋼板温度や板厚、搬送時間の情報を用いて仕上圧延機出側から巻取機間での鋼板の温度降下量 (以下: 温度降下量) を予測する機能を有している。この温度降下量の予測値を基に鋼板全長にわたって目標CTと一致するように開閉するバルブ本数および位置 (以下: 開閉バルブパターン) を周期的に繰り返し計算している。

### 1.2 従来制御の問題点

従来制御では、温度降下量の予測に、鋼板の熱伝導方程式に基づく物理モデルを用いていた<sup>4)</sup>。しかしながら、繰り返し計算の時間制約の観点から、差分法を用いて熱伝導方程式を厳密に計算することができず、その計算結果を基にした近似モデルを用いていた。近似モデルでは、鋼板の板厚方向の復熱現象を表現しきれないなどの問題があり、精度向上を図るには限界があった。また、従来の熱伝導方程式に基づくモデルでは、精度維持のためのパラメータ調整だけでなく、予測モデル構造の改良を必要とする場合もあった。さらには、本改良を行う

\*<sup>1</sup> 鉄鋼アルミ事業部門加古川製鉄所薄板部 \*<sup>2</sup> 鉄鋼アルミ事業部門加古川製鉄所プラントシステム部 \*<sup>3</sup> 技術開発本部デジタルイノベーション技術センター

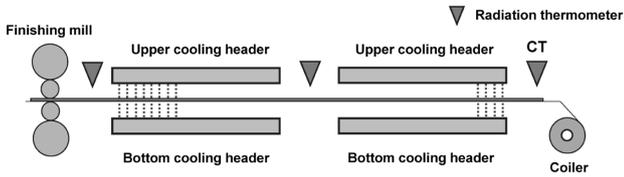


図1 冷却設備の概要  
Fig. 1 Overview of cooling equipment

には専門的な知識や技術を要するため、対応不十分により、CTの制御精度確保が困難な製品もあった。この問題に対応するため、製造現場のオペレータは、特定の製品に対し、プロコンで計算され開閉バルブ本数への増減方法を記した作業指示書をもとに作業を行っていた。それでもなお、異なる作業指示書の製品が連続圧延される場合、オペレータによる増減対応が間に合わない、作業指示書がない一般の製品に対してバルブの増減を戻し忘れるなどといった事例も発生し、オペレータの作業負荷が高くなっていた。さらに、予測モデルのパラメータ調整が、スタッフの属人的なノウハウに依存しており、新商品の高強度ハイテン材や冷却条件変更時など従来とは異なる条件で通板する場合、柔軟かつ迅速な対応が困難であった。

### 1.3 巻取温度制御におけるAI手法適用によるメリット

上記で述べた問題を解決するためには、以下三つのメリットから温度降下量予測にAI手法の一つである深層ニューラルネットワークを適用することが有効であると考えた<sup>5)</sup>。

- (1) シンプルなネットワーク構造で単純な計算処理を行うため、差分法より計算負荷が小さく、繰り返し計算の時間制約を受けない。
- (2) 入力されたデータに対し、正しい出力結果を得るようにネットワーク内の重みなどのパラメータを適正化する。(以下、学習という。) そのため、物理現象が非常に複雑である鋼板先端・後端などの非定常部に対し、定式化する必要がなく、適正化したパラメータを用いたネットワークによって予測を行うため、精度良く予測することができる。
- (3) モデルの調整において、調整パラメータを内包した物理モデルとは異なり、重みなどのパラメータを変更するだけで予測できるため、メンテナンス性が良い。

いっぽう、デメリットとしては、予測モデルがブラックボックスであるため、温度予測の挙動が分かりづらいことが挙げられるが、シミュレーションによる評価環境を構築することで克服できると考えた。

これらのメリット・デメリットを踏まえて、深層ニューラルネットワークを活用した温度予測モデルを開発することとした。

## 2. 深層ニューラルネットワークを用いた巻取温度制御の概要および運用方法

### 2.1 深層ニューラルネットワークを用いた温度予測モデルの概要

今回開発した深層ニューラルネットワークのモデル構造を図2に示す。板厚や製品の成分濃度などの材料要

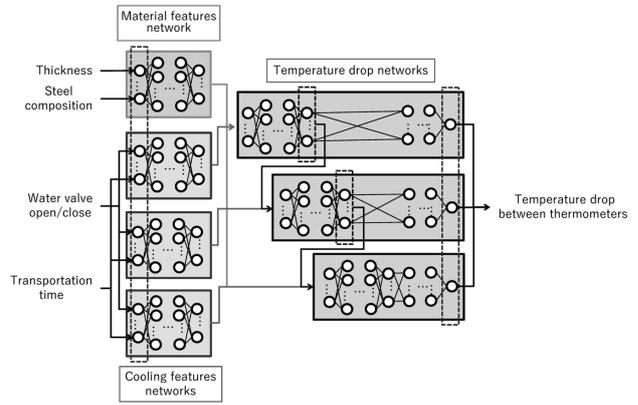


図2 深層ニューラルネットワークの構造  
Fig. 2 Deep neural network architecture

表1 モデルの分割条件  
Table 1 Conditions of dividing models

Model No	Coiling temperature (°C)	Thickness of steel sheets (mm)	Concentration of steel components (%)
1	$X_1 \sim X_2$	$Y_1 \sim Y_2$	$Z_1 \sim Z_2$
2	$X_3 \sim X_4$	$Y_3 \sim Y_4$	$Z_3 \sim Z_4$
...	...	...	...
N	$X_i \sim X_j$	$Y_i \sim Y_j$	$Z_i \sim Z_j$

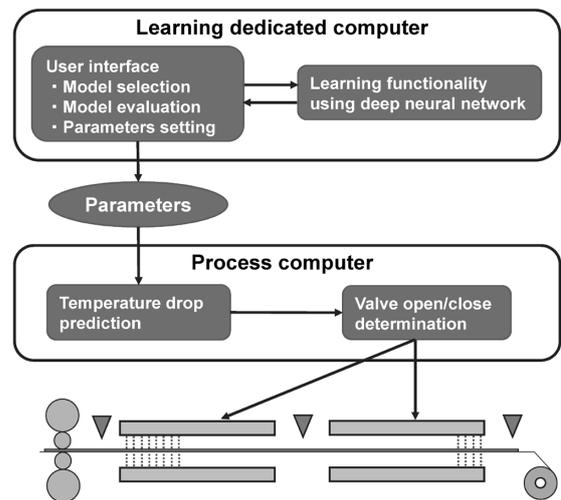


図3 機能構成の概要  
Fig. 3 Overview of functional configuration

因と、開閉バルブパターンや搬送時間などの作業要因を入力値として、温度降下量を予測している<sup>6)</sup>。

また、表1に示すように、CTや板厚、および炭素やシリコンなどの製品の成分濃度に対して、範囲を与える形式でモデルを分割し、それぞれモデルNo.で管理している。本方式を採用することで、CTや板厚、成分濃度を広範囲に網羅したモデルと特定の範囲に絞り込んだ詳細なモデルを混在させることが可能となる。これにより、モデルの汎用性確保と精度向上を図っている。

### 2.2 新制御の機能構成の概要

図3に示すのは、今回開発した新制御の機能構成の概要であり、プロコンとそれに付帯するモデル学習計算機で構成されている。プロコンでは、深層ニューラルネットワークモデルを用いた温度降下量の予測を行い、開閉バルブパターンを決定している。いっぽう、モデル学習計算機は深層ニューラルネットワークモデルを学習す

る専用計算機であり、スタッフが計算機を操作し、学習を実行する。本計算機はAIに関する知識やプログラミング技術を有していなくても学習を実施できるユーザインタフェースを備えており、スタッフは任意のタイミングでニューラルネットワークの学習を実行し、適正化したパラメータをプロコンに転送して登録することができる。

### 2.3 新制御への切替方針

従来制御での過去実績データを用いて、全モデルNo.のパラメータを決定した。そして、従来制御と比較して開閉バルブパターンがおおむね同じで、かつ制御精度が悪かった部分が改善方向に変化することを確認し、2021年9月に新制御方式に切り替えた。

従来制御ではモデルの分割数が非常に多く、まれにしか通板されない製品は制御精度が悪くなる傾向にあった。これを改善するため、可能な限りCTや板厚などの条件を広範囲にカバーするモデルを作成することを基本方針とした。ただし、この方針の場合、汎用性は高いが制御精度は劣る傾向にあるため、より高い制御精度が要求されているハイテン系鋼種に対しては、個別にモデルを作成することにした。

### 2.4 新制御におけるモデル調整方法

操業部門では、今回開発したモデル構造や機能構成の特性を考慮して、下記に示す手順をもとに調整を行っており、全ての製品に対し、対応できている。

#### Step 1：[調整対象モデルの選択]

最初に調整を実施する対象のモデルNo.を選択する。選択方法として、主に以下の三つのCaseがある。

#### Case 1：[条件を変更せず、既存モデルNo.を選択]

既に条件の範囲を絞りこんでおり、かつ、データ数が豊富にあるモデルNo.に対しては、範囲を変更せず対応する。

#### Case 2：[条件を変更し、既存モデルNo.を選択]

条件の範囲が広く、モデル精度が確保できない場合やCTなどが変更となった既存モデルNo.に対しては、範囲を変更して対応する。

#### Case 3：[新しいモデルNo.を作成]

過去に数本程度しか生産されることがない試作材や生産本数が非常に少ない量産製品の場合、既存のモデルNo.が存在しない場合が多い。この場合、CTなどの各条件の範囲を規定して、新規にモデルNo.を作成する。

#### Step 2：[学習に使用するデータの選定]

Step 1で選択したモデルNo.に対し、CTや成分濃度などの条件に合致する指定した期間内の全データを抽出する。つぎに、抽出したデータの中から、条件範囲内で極力バリエーションに富むよう自動でデータを選定する。

#### Step 3：[学習したモデルの評価]

Step 2で選定したデータを用いて学習を実行し、モ

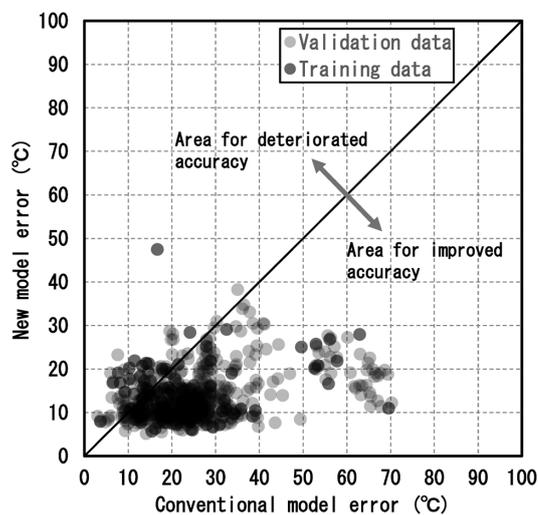


図4 モデル評価画面例

Fig.4 Example screen for Model evaluation

デルのパラメータを決定する。つぎに、自動選定により学習に使用したデータも含め、対象モデルNo.の全データに対し、パラメータを用いて鋼板全長のCT予測計算を行い、下記二つの誤差を計算する。

- a 適正化したパラメータによるCT予測値と実績値の誤差
- b プロコン実装中のパラメータによるCT予測値と実績値の誤差

aとbの誤差の評価を図4に示す画面で実施する。誤差が小さくなっていないければ、Step 1あるいはStep 2に戻って調整を行い、再度Step 3を実施する。誤差が小さくなるまで、Step 1～Step 3の作業を繰り返す。

#### Step 4：[新パラメータのプロコンへの登録]

Step 3で決定した新パラメータをモデル学習計算機からプロコンに転送し、新パラメータの登録を行う。これにより、プロコンでは新パラメータを用いて温度降下量を予測する。

## 3. AI手法導入による操業に与えた効果

操業部門では、CTの制御精度改善は尽きることのない命題である。そのような状況の中、今回開発・導入したAI手法により、操業部門にて業務内容を中心に以下の変革が進んだ。

- (1) スピーディーなモデル調整作業
  - (2) オペレータによるバルブ開閉負荷の大幅軽減
  - (3) モデル調整作業の属人性排除と円滑な技術継承
- 以下におおのの詳細について記す。

### 3.1 スピーディーなモデル調整作業の実現

スタッフがAI手法の専門知識や技術を有していなくても、つぎに示すように、スピーディーにモデル調整作業を実施できるようになった。表2に示すのは、CTの制御精度を改善する必要があると判断してから、モデル調整が完了するまでの作業時間を従来制御と比較したものである。今回、操業実績データを確認するためのユーザインタフェースを整備したことにより、実態調査の時間を大幅に削減できた。さらに、モデル調整において、

最低限の実績データを確認して、深層ニューラルネットワークモデルを学習するだけとなり、1日未満で全ての作業を完了している。また、図4に示すように、調整によるモデル誤差の改善状況も可視化しており、調整したモデルの評価やプロコンへの登録の判断を迅速に行うことができています。

### 3.2 オペレータによるバルブ開閉負荷の大幅軽減

前節で記したように、CTの制御精度が悪化した場合に都度、モデル調整作業を適正かつスピーディーに実施して制御精度を改善している。それにより、特定の製品に対するバルブ本数への増減方法を記した作業指示書を全て撤廃することができており、オペレータの作業負荷が大幅に軽減した。また、作業ミスなどのリスクも大幅に減少した。

### 3.3 モデル調整作業の属人性排除と技術継承の実現

従来制御で実施していた予測モデルの改良作業や属人的ノウハウとなっていたパラメータ調整作業が無くなり、深層ニューラルネットワークモデルの学習によってモデルの調整を行うようになった。それにより、モデル調整作業において、経験や勘から脱却することができ、従来制御と比較して、属人性を大幅に排除することができた。また、スタッフ間の技術継承も円滑かつ確実にを行うことができるようになったことで、スタッフがモデル調整作業を行う持続的体制を構築できた。

表2 モデル調整期間の比較  
Table 2 Comparison of model adjustment periods

Working item	Expected number of working days [day(s)]	
	Conventional method	New method
Actual condition survey	2	0.1
Model tuning	1	0.6
Model evaluation	-	0.1
Parameter implementation to process computer	0.1	0.1
Total number of days	3.1	0.9

## 4. AI手法導入による製品品質に与えた効果

今回開発・導入した技術により、定常状態である鋼板中間部のみならず、従来制御では精度低下が多発していた鋼板先端・後端部、とくに目標温度を定常部と変更した場合でも、CTを高精度に制御することができるようになった。それにより、当社の代表的な熱延ハイテン材と冷延ハイテン材において、CT公差外れによる廃却量が従来制御と比較して、それぞれ21%、71%削減し、歩留まりが向上した。

**むすび**=ここでは鋼板製造工程における巻取温度制御の温度予測モデルに深層ニューラルネットワークを実機適用した経緯や運用方法、および生み出すことができた操業部門の業務の変革について述べた。

近年、当社では熱間圧延工程全体の多種多様なデータを収集するインフラを再構築し、従来よりも格段に大量のデータを活用できる環境が整った。今後、その環境を利用することで加熱炉や圧延設備などの熱間圧延工程内の他工程に対しても、本稿のAI手法の技術を横展開し、さらなる品質の安定化や製造現場のオペレータの作業負荷の軽減などを実現していく。

### 参考文献

- 1) 池田宗朗ほか. R&D神戸製鋼技報. 2017, Vol.66, No.2, p.8-11.
- 2) 村田忠夫ほか. R&D神戸製鋼技報. 2017, Vol.66, No.2, p.17-20.
- 3) 岡谷貴之. 深層学習 改訂第2版. 講談社. 2022.
- 4) 佃 岳洋ほか. R&D神戸製鋼技報. 2011, Vol.61, No.2, p.75-79.
- 5) 前田知幸ほか. R&D神戸製鋼技報. 2024, Vol.72, No.2, p.79-83.
- 6) 逢坂武次. 材料とプロセス. 35 (2022) 2, 387.