

冷延工場タンデムミルセットアップ計算への機械学習の応用

Application of Machine Learning to Tandem Cold Mill Setup

山崎 達矢 YAMAZAKI Tatsuya JFE スチール 西日本製鉄所（福山地区）制御部 冷延制御室 主任部員（係長）
向山 瑛彦 MUKAIYAMA Akihiko JFE スチール 西日本製鉄所（福山地区）冷延部 冷延技術室 主任部員（係長）
矢島 昌英 YAJIMA Masahide JFE スチール 西日本製鉄所（福山地区）冷延部 冷延工場 副工場長（係長）

要旨

近年、自動車用ハイテンに代表される難圧延材の需要増加にともない、タンデムミル（Tandem Cold Mill）セットアップの精度向上が求められていることから、JFE スチールでは西日本製鉄所（福山地区）冷延工場に機械学習を用いたセットアップシステムを導入した。本システムでは、圧下率、スタンド間張力、圧延荷重、圧延トルクおよび先進率を、大量の実績データをもとに学習させた機械学習モデルによって予測計算する。本システムの導入により、種々のモデル予測精度は大幅に改善し、操業安定化ならびに生産性向上に寄与している。

Abstract:

In recent years, as demand for steel sheets that are difficult to roll (e.g., high-tensile steel sheets for automobiles) has been increased, improvement of the accuracy of mill setup systems has been required in tandem cold mills. Thus, a newly developed setup system using machine learning was applied to a tandem cold mill at JFE Steel West Japan Works. This system includes multiple predictive models, such as draft setting, tension setting, rolling force, rolling torque, and forward slip model, and trains them based on large amounts of operational data. The improvement of the accuracy of each predictive model contributes to increased productivity.

1. はじめに

薄板の板厚を作り込むタンデムミルは、母材の板厚と製品寸法としての目標板厚は指定されるが、各スタンドでの板厚に自由度があるという特徴がある。また、各スタンドの圧延荷重や圧延トルク、潤滑状況は、板厚・形状・表面外観といった鋼板品質に影響する。

これらの特徴を背景として、タンデムミルのセットアッププロセスにおいて、各スタンドの圧下率やスタンド間張力を設定するさまざまな方法が提案されている^{1,3)}。

さらに、今日主流となっている連続式タンデムミルでは、生産性を高めるために、コイル同士の溶接部を圧延停止することなく低速で通板させる走間板厚変更技術が一般に用いられる。走間板厚変更では、各スタンドのロールギャップとロール速度を、溶接部が各スタンドを通過するタイミングに合わせてフィードフォワード的に変更することで圧延通板を可能にしている。なお、通板完了後、ロールギャップやロール速度は、自動板厚制御または自動張力制御の操作端としてフィードバック制御される。このような高度な通板技術の実用化は圧延理論の進歩によるところが大きい。具体的には、各スタンドを通過するタイミングのロールギャップ変更量は、圧延荷重のモデル予測値とゲージメータ式から計算

され、ロール速度変更量は、各スタンドの圧下率設定値と先進率のモデル予測値から計算される。

一方、圧延機の実産性を左右する要因として、圧延機の最大圧延速度がある。圧延時、材料を塑性加工するための圧延動力は圧延ロール駆動電動機により供与される。このため、圧延ロールの速度は圧延トルクに応じて圧延動力が電動機の定格出力を超えない範囲に制限される。タンデムミルのセットアッププロセスでは、圧延トルクのモデル予測値から最大ロール速度を計算し、全てのスタンドで電動機の予測出力が定格出力を超えない速度を最大圧延速度とする。

上記のとおり、タンデムミルセットアップでは、圧下率等の設定に加え圧延理論に基づく種々のモデル計算を行っており、それらの良否が鋼板品質や生産能率に大きな影響を与える。

近年の自動車用ハイテンや電磁鋼板といった難圧延材の需要増加により、タンデムミルの製造品種は多様化し、新しい品種に対応した圧下率セットアップの高度化やモデルのレベルアップが求められていた。

そこで本稿では、当社西日本製鉄所（福山地区）冷延工場に導入した機械学習（ニューラルネットワーク）を用いたタンデムミルセットアップシステムについて紹介する。本システムは、過去の操業実績データから圧延条件に応じた圧下率・スタンド間張力設定を計算するモデルと、圧延荷重・

圧延トルク・先進率を予測計算するモデルを持つ。また、本システムは、データベースに操業実績データを蓄積し、これらのモデルをオンラインで自動学習させることにより、メンテナンスフリーを実現している。

2. タンデムミルセットアップシステム

2.1 タンデムミルセットアップ

本節では、タンデムミルセットアッププロセスの概要について述べる。一般に、冷間圧延機のセットアップは、**図1**に示すフローによって行われる。

2.1.1 圧下率・スタンド間張力の設定

まず、種々のモデル計算に先立ち、与えられた製造諸元(板厚、板幅、鋼種、圧延ロール情報等)をもとに圧下率とスタンド間張力の設定を行う。圧下率やスタンド間張力の設定については、従来から多くの方法が提案されており、生産性を向上させる目的の方法としては、テーブルで設定値を与える方法や圧延ロール駆動用電動機の出力を最大化する方法¹⁾等がある。一方、操業安定化・品質向上を目的とする方法としては、圧延荷重や電動機出力の予測値からなる評価関数を最小化する方法²⁾、ニューラルネットワークを用いた方法³⁾等が提案されている。

2.1.2 圧延荷重・先進率・圧延トルクの予測⁴⁾

前項の手順により圧下率とスタンド間張力が決定すると、これらをもとにした圧延荷重・圧延トルク・先進率の予測計算が可能となる。予測計算は、板幅、板厚、板硬度、圧延ロール径などをもとにした重回帰計算や、以下で述べる圧延理論に基づくモデル(以下、物理モデルという)を用いた方法で行う。物理モデルは、ロールバイト内での力のつり合いと、圧延荷重を受ける圧延ロールの弾性変形の関係式を連立させて得られる(近似)解である。

以下、冷間圧延で広く用いられている Bland and Ford の式と Hitchcock のロール偏平式について記す。

まず、Bland and Ford の理論では、ロールバイト内での力のつり合い方程式を近似的に解くことで、次式で表されるロールバイト内での圧延荷重の(接触弧方向の)分布を得る。

$$p = \begin{cases} \frac{kh}{h_0} \left(1 - \frac{\sigma_0}{k_0}\right) e^{\mu H} & (\text{先進域}) \\ \frac{kh}{h_1} \left(1 - \frac{\sigma_1}{k_1}\right) e^{\mu(H_1-H)} & (\text{後進域}) \end{cases} \dots\dots\dots (1)$$

$$H = 2 \sqrt{\frac{R'}{h_0}} \tan^{-1} \left(\sqrt{\frac{R'}{h_0}} \phi \right)$$

ここで、 k は変形抵抗、 h は板厚、 σ は張力、 μ は摩擦係数、 R' は偏平ロール半径、 ϕ は偏平ロール中心から見た極座標系の(ロールバイト出口側を0とした)角度、添え字0はロールバイト出口での値、添え字1はロールバイト入口での値を意味している。

冷間圧延における変形抵抗 k は、引張法や圧延・引張法などからオフラインで作成した次式のような非線形回帰式を用いる方法が一般的である。

$$k = C(\varepsilon + d)^n \dots\dots\dots (2)$$

ここで、 ε は相当歪み、 C, d, n は回帰パラメータである。

また、摩擦係数については、テーブルで与える方法、実績データをもとに上記モデル式から逆算する方法および製造条件をもとにした重回帰計算による方法が一般的に用いられる。

一方、Hitchcock のロール偏平理論では、ロール変形後もロール形状は円弧であり、圧延荷重の接触弧内での分布が楕円状であるという仮定のもとで、その半径 R' は次式で与えられるとしている。

$$R' = R \left[1 + \frac{16(1-\nu^2)}{\pi E} \frac{P}{h_1 - h_0} \right] \dots\dots\dots (3)$$

ここで、 R は変形前のロール半径、 E, ν はロールのヤング率とポワソン比、 P は単位幅あたりの圧延荷重である。

式(1)、(2)を見ると、単位幅あたりの圧延荷重 P (接触弧内での圧延荷重和 $\int p dx$ に相当)は偏平ロール半径 R' から決まり、偏平ロール半径 R' は圧延荷重 P から決まることわかる。したがって、適当な初期値(例えば $P=0, R'=R$)のもとで2式を交互に用いて収束計算することで、圧延荷重および偏平ロール半径を計算することができる。

同様に、先進率 f および(圧延ロール1本あたりの)圧延トルク G についても以下の物理モデルが知られている。

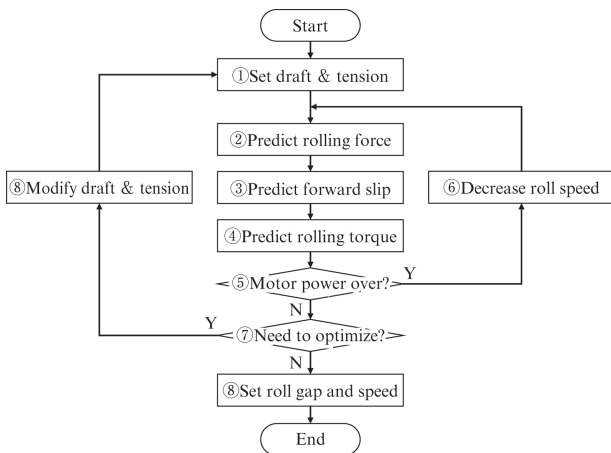


図1 タンデムミルセットアップ計算フローチャート

Fig. 1 Tandem cold mill setup flow chart

$$f = \tan^2 \left(\tan^{-1} \left(\sqrt{\frac{h_1 - h_0}{h_0}} \right) - \frac{1}{4\mu} \log \left(\frac{h_1 (1 - \sigma_0 / k_0)}{h_0 (1 - \sigma_1 / k_1)} \sqrt{\frac{h_0}{R'}} \right) \right) \dots\dots\dots (4)$$

$$G = \frac{R}{R'} \int p dx + \frac{R}{2} (h_1 \sigma_1 - h_0 \sigma_0) \dots\dots\dots (5)$$

2.1.3 電動機パワーチェック⁴⁾

前項で得た圧延トルクならびに先進率の予測値を用いて、次式で圧延動力を予測することができる。

$$W = 2G \frac{v_R}{R} + v_0 h_0 \sigma_0 - v_1 h_1 \sigma_1 \dots\dots\dots (6)$$

$$= 2G \frac{v_0}{(1+f)R} + v_0 h_0 \sigma_0 - v_1 h_1 \sigma_1$$

ここで、 v_R, v_0, v_1 はそれぞれロール速度、ロールバイト出口での板速度、ロールバイト入口での板速度（すなわち、前段スタンド出口での板速度）を意味する。

上式において電動機トップ回転数となるように各ロール速度を決定したとき、定格出力 W_{rated} に対して $W > W_{rated}$ となるスタンドが存在する場合、その超過率分だけロール速度を減じて再度モデル計算を行う。

2.1.4 圧下率・スタンド間張力の最適化

前項までの議論で、圧下率・スタンド間張力が決定し、圧延荷重等の予測値が得られたため、次項に示す方法でロールギャップとロール速度の設定値を決定することができる。しかしながら、従来提案されている圧下率・スタンド間張力の設定方法の中には、例えば各スタンドの圧延動力の和が最大になるよう圧下率を決定する方法のように、数値最適化を含むものがある。その場合、2.1.1 項から前項までの手順をさらに反復して実行する。

2.1.5 ロールギャップとロール速度の設定

最後にロールギャップ S を、ゲージメータ式とよばれる、圧延荷重によるミルの弾性変形とロールギャップ、板厚の関係から次式により求める。

$$S = h_0 - \frac{Pb}{M} \dots\dots\dots (7)$$

ここで、 b は板幅、 M はミルの剛性を表す定数である。

以上のフローで計算したロールギャップとロール速度を、それぞれ油圧圧下制御装置や電動機ドライブ制御装置に通板時の値として設定する。

2.2 開発システム概要

今回開発したシステムの構成を図2に示す。本システムでは、機械学習専用サーバーを新設し、Level-2 計算機（プロセス計算機）と汎用伝送（Ethernet）でインターフェイス

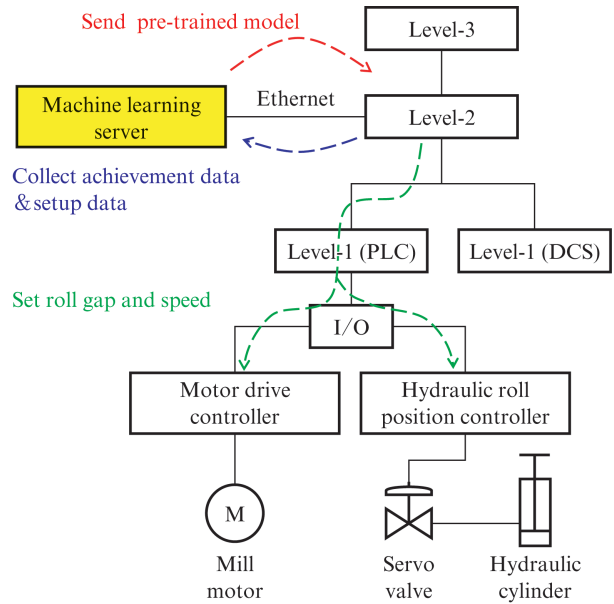


図2 システム構成図

Fig. 2 System configuration diagram

する。なお、機械学習専用サーバーのハードウェアは汎用の計算機とした。

機械学習専用サーバーは、Level-1（PLC: Programmable Logic Controller や DCS: Distributed Control system）から得られる圧延荷重をはじめとする操業実績データ、Level-2 計算機のセットアップデータ、さらに、Level-3 計算機（ビジネス計算機）から送信されるコイル諸元や圧延ロールデータ等のデータを、Level-2 計算機経由で収集し、コイル単位でデータベースに保存する。

Level-2 計算機は各スタンドの圧下率、スタンド間張力設定、圧延荷重、圧延トルク、および先進率を機械学習モデルで予測計算する。具体的には、各予測モデルに応じた説明変数から次章で述べる予測計算ロジックを用いて計算を行い、従来のモデルによる予測値を置き換える。さらに、計算結果に基づくロールギャップ、ロール速度を Level-1 計算機経由で油圧圧下制御装置ならびに電動機ドライブ制御装置に、走間板厚変更時の変更量データとして設定し、予測計算結果をミル制御に反映する。

また、機械学習専用サーバーでは、学習対象モデルに応じてデータベースから学習に必要なデータを抽出し、次章で述べるモデルの教師あり学習を行う。モデル学習は圧延ロール組替に合わせてバッチ処理で実行し、学習完了時に学習済みパラメータを Level-2 計算機に送信する。Level-2 計算機は、適宜パラメータを再読込することで、オンラインでのパラメータ更新（自動学習）を実現する。

上記機能分担を採用したのは、以下の利点による。

- (1) モデル学習機能の改良を Level-2 計算機を変更することなく行える。
- (2) 負荷の高い学習計算を Level-2 計算機から分離するこ




図3 多層パーセプトロンネットワーク
Fig. 3 Multi-layer perceptron network

とができる。

- (3) 予測計算を Level-2 計算機で実施することで高速化できる。

3. 機械学習によるモデル構築

本章では、今回開発したタンデムミルのセットアップシステムで用いる、ニューラルネットワークによる予測モデル構築の概要について説明する。

なお、本章で説明するモデル学習方法は、誤差逆伝搬法⁵⁾とよばれる手法を、図3に示すニューラルネットワークの一種である多層パーセプトロンで構成された回帰モデルに対して適用したものである。

3.1 予測計算 (推論)

本節では、図3に示す多層パーセプトロンによる予測計算について述べる。なお、本稿で構築しているモデルでは、目的変数はいずれも多次元である(例えば圧延荷重予測ではタンデムミルのスタンド数と同数)。すなわち、以下で説明するモデルはいずれも MIMO (Multi Input Multi Output) であることに注意が必要である。

まず、モデルの説明変数 x は材料条件(母材板厚, 目標板厚, 板幅, 板硬度等)やロール条件(ロール半径, ロール粗度, ロール使用長等)から適切に選択され, n 次のベクトルとして次式で与えられるものとする。

$$x = [x_1 \ x_2 \ \dots \ x_n] \dots\dots\dots (8)$$

一方、モデルの目的変数 y は圧延荷重や圧延トルク, 圧下率設定値などモデルごとに異なる変数であり, m 次のベクトルとして次式で与えられるものとする。

$$y = [y_1 \ y_2 \ \dots \ y_m] \dots\dots\dots (9)$$

重みパラメータ(行列, ベクトル)の次数については表記を省略するが, 入出力に応じた適切なサイズと仮定する。

説明変数 x に対して, 重みパラメータを W_1, b_1 , 第1中間層のニューロン個数を n_1 として, 次式で第1中間層の n_1 次出力ベクトル h_1 を得る。

$$h_1 = f_1(x \cdot W_1 + b_1) \dots\dots\dots (10)$$

ここで, f_1 は活性化関数である。本稿では, ReLU (Rectified Linear Unit) とよばれる関数を用いる。

さらに, 中間層について同様に繰り返すことで, 次式で第 i 中間層の n_i 次出力ベクトル h_i を得る。

$$h_i = f_i(h_{i-1} \cdot W_i + b_{i-1}) \dots\dots\dots (11)$$

ここでも, 活性化関数 f_i は同様に ReLU を用いる。

最後に, 中間層の総数を N としてモデル予測値であるニューラルネットワークの出力 y を次式で得る。

$$y = h_N \cdot W_{N+1} + b_{N+1} \dots\dots\dots (12)$$

上記の各計算は, 簡単な行列・ベクトル計算と活性化関数の組合せであるため容易に実装が可能であり, かつ, 高速で計算可能である。今回導入したシステムでは, 本節で説明した予測計算ロジックを Level-2 計算機に実装しており, 予測計算に要する時間は1ミリ秒程度となっている。

なお, 例えば製造実績の少ない品種・寸法を製造する場合, 機械学習によるモデルは(実績データが少ないために)大きく外れた予測値を計算する可能性がある。そこで本システムでは, 既存のモデル計算値を用いた閾値処理を行うことで, 大きく外れることを抑止している。

また, 本稿のモデル構築方法では, (説明変数を適切に選択するステップ以外では) 圧延理論に関する知見を用いていないことから, 本稿のモデル構築方法は, 圧延プロセスに限らず有効なものであると言える。

3.2 学習計算

続いて, 多層パーセプトロンの学習方法である誤差逆伝搬法について概要を述べる。

誤差逆伝搬法とは, 教師データ t とモデル予測値 y の誤差が小さくなるように, 出力層から入力層に向かって誤差を伝搬させ(逆伝搬), 各層の重みパラメータを更新する方法である。以下, その具体的な手順を説明する。ただし, 表記を簡単にするため中間層の総数 $N=1$ とする。このとき, 前節の計算手順は次式のように表される。

$$h = f(x \cdot W_1 + b_1), \quad y = h \cdot W_2 + b_2 \dots\dots\dots (13)$$

まず、教師データを t とし、本稿の問題設定（回帰）に合わせて損失関数 L を二乗和誤差と定義すれば、損失関数 L は次式で表される。

$$L = \frac{1}{2} \sum_{i=1}^m (y_i - t_i)^2 = \frac{1}{2} \|y - t\|^2 \quad \dots\dots\dots (14)$$

このとき、その導関数は次式のように簡単に表せる。

$$\frac{\partial L}{\partial y} = y - t \quad \dots\dots\dots (15)$$

次に、微分に関する連鎖率より、次式を得る。ここで、 T は行列およびベクトルの転置を表す。

$$\left. \begin{aligned} \frac{\partial L}{\partial h} &= \frac{\partial L}{\partial y} \cdot W_2^T, \\ \frac{\partial L}{\partial W_2} &= h^T \cdot \frac{\partial L}{\partial y}, \\ \frac{\partial L}{\partial b_2} &= \frac{\partial L}{\partial y} \end{aligned} \right\} \dots\dots\dots (16)$$

さらに、 $h_1 = f(v)$ 、 $v = xW_1 + b_1$ とすれば、同様にして次式を得る。

$$\left. \begin{aligned} \frac{\partial L}{\partial v} &= \begin{cases} \frac{\partial L}{\partial h} & (v_i \geq 0 \text{ の要素}) \\ 0 & (v_i < 0 \text{ の要素}) \end{cases}, \\ \frac{\partial L}{\partial W_1} &= x^T \cdot \frac{\partial L}{\partial v}, \\ \frac{\partial L}{\partial b_1} &= \frac{\partial L}{\partial v} \end{aligned} \right\} \dots\dots\dots (17)$$

以上の議論から、例えば確率的勾配降下法を用いて、次式のように重みパラメータ W_i 、 b_i を更新することで、損失関数 L を減少させることができる。

$$W_i \leftarrow W_i - \alpha \frac{\partial L}{\partial W_i}, \quad b_i \leftarrow b_i - \alpha \frac{\partial L}{\partial b_i} \quad \dots\dots\dots (18)$$

ただし、 α は確率的勾配降下法の学習率であり、通常 0.01 程度の小さい値が選ばれる。

上記の学習手順を大量のデータに対して繰り返し実行することで、損失関数 L を減少させることが期待できる。言い換えれば、上記手順を繰り返すことで、多層パーセプトロンの出力 y は教師データ t に近づくことが期待できる。

今回導入したシステムでは、上記の学習手順を機械学習専用サーバーに実装し、データベースに蓄積したコイル単位の操業実績データを用いて各モデルの学習を行う。各モデルの重みパラメータ W_i 、 b_i は、学習完了時に Level-2 計算機に自動的に伝送され、Level-2 計算機がそれを適宜再読込することによりオンラインでの自動学習機能を構築している。

表 1 各モデルの目的変数

Table 1 Objective variables of the models

Name	Number of objective variables
Draft setting	Equals to the number of mill stands.
Tension setting	Equals to the number of mill stands plus one.
Rolling force	Equals to the number of mill stands.
Rolling torque	Equals to the number of mill stands.
Forward slip	Equals to the number of mill stands.

4. 実機適用結果

4.1 セットアップシステムの運用状況

前章で述べた機械学習を用いたセットアップシステムは、当社西日本製鉄所（福山地区）冷延工場で実機適用されており、現在、表 1 に示した 5 種類のモデルを実用化している。

4.2 実機での予測モデル精度検証

本システムによる予測モデルを実機適用した前後での各モデルの予測誤差を表 2 に示す。表 2 における予測誤差の評価は、実機適用の前後それぞれに対して予測値と実績値の RMSE (Root Mean Squared Error) を計算し、Conventional system (実機適用を行ったタンデムミルにおいて従来運用されていた、第 2 章で述べた圧延理論に基づく物理モデル) での RMSE を 1 として相対評価した。また、先進率については、その実績を得ることは困難であるため、各スタンドの圧延ロール速度の比に関する予測値と実績値との比較を行った。なお、評価期間はそれぞれ約 3 ヶ月であり、各モデルについて代表的な 2 種類の鋼種での予測誤差を比較した。また、圧下率とスタンド間張力については、設定値であるため予測誤差を定義することができないことから、ここでは評価を省略した。

表 2 に示すとおり、いずれのモデルについても本システムを導入したことで Conventional system より予測誤差が改善していることが確かめられた。鋼種によって改善率が大きく異なっているのは、従来のモデルによる予測誤差が鋼種によって大きく異なっていたためである。

表 2 モデル予測誤差評価 (既存システムを 1 とした)

Table 2 Evaluation of predictive errors of the models (Conventional system = 1)

Steel grade	Model name	Conventional system	Proposed system
A	Rolling force	1	0.41
	Rolling torque	1	0.45
	Forward slip (roll speed)	1	0.82
B	Rolling force	1	0.26
	Rolling torque	1	0.93
	Forward slip (roll speed)	1	0.81

表3 モデル応用結果の評価
Table 3 Evaluation of application of models

Expected effects of application	Main result
Less welded point breaks during flying gauge control	26.4% decrease
Increased productivity	2.4% increase in a typical grade

4.3 実機適用による効果

表3は、本システム導入による操業安定化および生産性向上の効果を定量的に評価したものである。

まず、圧延荷重予測精度の向上により、溶接部通板時の板破断の発生頻度は26.4%減少した。

また、圧延トルク・先進率の予測精度向上および圧下率・スタンド間張力の自動設定により、圧延動力がボトルネックとなる特定の材料において2.4%の生産性向上を確認した。

5. おわりに

JFE スチール西日本製鉄所（福山地区）冷延工場において実機運用している機械学習を用いたタンデムミルのセットアップシステムについて述べた。


- (1) 本システムによる種々の圧延モデル精度向上は、冷間圧延機の操業安定化・生産性向上に寄与している。
- (2) 本システムは、モデルのオンライン学習により、メンテナンスフリーも実現できた。

参考文献

- 1) 蒲田正誠. 薄板連続圧延. 地人書館, 1997, 308p.
- 2) 村上晃, 中山万希志, 岡本充央, 佐野研一. 冷間タンデム圧延機のパススケジュール最適化. 鉄と鋼. 2004, vol. 90, no. 11, p. 953-957.
- 3) 豊福達生, 竹腰篤尚, 山本正治, 田中一. ニューラルネットを用いたタンデムミルにおけるドラフトスケジュールの決定方法. 鉄鋼協会第122回講演大会. 1991.
- 4) (社) 日本鉄鋼協会精算技術部門圧延理論部会 (第2章: 松本紘美). 板圧延の理論と実際 (改訂版) (第2章). 日本鉄鋼協会, 2000, 350p.
- 5) Rumelhart, D. E.; Hinton, G. E.; Williams, R. J. Learning internal representations by error propagation. Parallel Distributed Processing: Exploration in the Microstructure of Cognition. 1986, vol. 1, p. 318-362.



山崎 達矢



向山 瑛彦



矢島 昌英