
論 文

溶融亜鉛めっき付着量制御の AI 技術適用

～機械学習による誤差要因の探索手法の提案及びその活用～

Application of AI technology to zinc coating weight control
～Approaches to identify error factors of the non-linear model
using the machine learning～

筒本 直樹 Naoki TSUTSUMOTO
北九州技術センター 制御システム技術部
技術企画室

中尾 泰三 Taizo NAKAO
日鉄プラント設計
制御システムエンジニアリング部
製鉄電計第二チーム マネジャー

宮崎 聡志 Satoshi MIYAZAKI
北九州技術センター 制御システム技術部
製鉄制御室

角野 初輝 Hatsuki KAKUNO
製鉄プラントセクター
製鉄プラントエンジニアリング第二部
鋼板処理商品技術室 マネジャー

抄 録

溶融亜鉛めっきラインでは、ガスワイピング装置を用いてめっき付着量の調整を行っている。めっき付着量を継続して安定させるためにめっき付着量制御が用いられ、めっき付着量の推定モデルに基づき所定のめっき付着量となるようなガスワイピング装置の操作量を計算する。より精緻なめっき付着量制御を実現するためには、推定モデルの高精度化、すなわち、モデル化誤差の低減を図る必要がある。モデル化誤差低減に必須となる誤差要因の特定において、ガスワイピング理論が非線形であることから、万能な解析方法は存在せず、試行錯誤を要する。本論文では、当社のガスワイピング装置 NSblade® の特性に基づき構築した推定モデルの誤差低減の取り組みにおいて有効であった機械学習による誤差要因の探索手法について述べる。

Abstract

In this paper, we describe approaches to identify error factors of the non-linear model using the machine learning effectively. In the hot-dip galvanizing line, a gas-wiping device adjust the amount of zinc coating weight. In order to stabilize coating weight to achieve a predetermined coating weight continuously, coating weight control calculates optical action of gas-wiping device based on the coating estimation model. It is necessary to improve the accuracy of the estimation model, i.e., reduce the modeling error, in order to achieve a more precise control. The identification of error factors is essential to reduce modeling errors. However, there is no convenient approach because of the non-linearity of the gas wiping process. We describe one of the approaches using machine learning to identify error factors on non-linear coating estimation model for our wiping system NSblade®.

1 緒言

溶融亜鉛めっき鋼板は図1で示す連続溶融亜鉛めっきライン(Hot Dip Continuous Galvanizing Line, 以下 CGL)で製造されている。CGLにおけるめっきプロセスでは、図2のように鋼板を溶融金属浴中に浸漬させて、鋼板表面に溶融金属を付着させた後、鋼板の表裏に配置されるガスワイピング装置によって所定の規格となるようにめっき付着量を制御することで溶融亜鉛めっき鋼板を製造している。

このめっき付着量制御は鋼種やライン速度といった操業条件に応じてガスワイピング装置のノズル噴射圧力(以下、ノズル圧力)や鋼板に対するガスワイピング装置のノズル位置といったガスワイピング条件を適切に調整することで実現される。

上述の操業条件やガスワイピング条件とめっき付着量の関係は複雑な非線形であり、一般的な制御手法であるフィードバック制御だけでは制御が難しいため、めっき付着量の推定モデルを用いたフィードフォワード制御が行われている。

ガスワイピング装置の操作量はめっき付着量の推定モデルによって決定されるため、推定モデルの精度がめっき付着量制御精度に直結することとなり、高精度なめっき付着量の推定モデルが望まれる。

このめっき付着量の推定モデルには主に統計的手法が用いられており、実操業データを基にしためっき付着量におよぼす操業条件やガスワイピング条件の影響に関する重回帰による近似式を用いた推定モデルが提案されている^{1), 2), 3)}。この統計的手法による近似式を用いた推定モデルでは、回帰分析が行われたラインおよびその操業範囲内では信頼性があり、かつ近似式を用いているため計算量が小さく自動制御への組み込みが容易といった特徴がある。

一方、めっき付着量制御のガスワイピングプロセスを物理式により表現した推定モデルも提案されている^{4), 5), 6), 7), 8)}。この物理式を用いた推定モデルでは、新ライン建設または既設ライン改造など、操業条件やガスワイピング条件が異なるような場合においても、それに合わせて推定モデルを構築できることから、新ラインの設計への活用や、設備立ち上げ後の操業データ収集期間短縮によるめっき付着量制御の運用開始までの時間短縮が可能といった利点がある。

しかし、物理モデル構築時の理論上の想定と実機構成との差異を完全に解消することは難しく、その差異に起因するモデル化誤差の発生は避けられない。そのため、如何にして差異を見つけ出し、モデル化誤差を減らすかの取り組みが重要となる。だが、物理モデルは複雑かつ非線形な関数であり、さらに、モデル化誤差は単独の誤差要因ではなく、複数の誤差要因が互いに影響しあうことで生み出されることが多いため、モデル化誤差の解析には複数の誤差要因が絡み合う関数について取り扱う必要がある。従来手法では、これらの誤差要因を見いだすためには、操業条件を意図的に変化させた様々な操業条件の組み合わせからなる操業データを用意する必要があった。しかし、実操業において意図的に操業条件を変更することは難しい。そのため、実操業を行った結果として得られる限られた操業条件の組み合わせの中から必要な情報を抽出し、解析を行う必要がある。このとき、モデル化誤差とその誤差要因の関係が線形であれば容易に解析できるが、非線形な場合には万能な解析方法は存在せず、試行錯誤を重ねながらの解析が求められる。

そこで、機械学習をはじめとする AI(Artificial Intelligence)技術が複数の要因が絡みあう非線形な




図1 連続溶融亜鉛めっきライン
Fig. 1 Hot Dip Continuous Galvanizing Line




図2 めっき付着量調整
Fig. 2 Coating Weight Control

関係を効率的かつ柔軟に表現することに長けているという特徴に着目し、人間の代わりにこの非線形な関係を表現させることを考えた。ただし、機械学習モデルはブラックボックスであるため、非線形な関係を表現するモデルを構築しただけでは、人間がこの関係を読み解くことは難しい。

しかし、近年、機械学習モデル内部で行われる推論過程を人間にも理解できるようにした説明可能なAI(Explainable AI)⁹⁾が注目されている。その手法の一つとしてSHAP(SHapley Additive exPlanations)¹⁰⁾があり、この手法を用いることでブラックボックスである機械学習モデルの説明性を向上させることができる。そのため、上記の非線形な関係を表現する機械学習モデルの構築後、SHAPを利用することで、機械学習モデル内部の非線形な関係を読み解く、つまり、複数の誤差要因がどのようにモデル化誤差に影響するかということを読み解くことができれば、そこから誤差の低減、すなわち、物理モデルの改善につなげることが可能となる。

本論文では、当社のめっき付着量制御で用いているめっき付着量推定のための物理モデルに対し、機械学習を活用し、物理モデルの誤差要因の特定及びその誤差要因を物理モデルに反映することで、物理モデルの効率的な改善に成功した事例について紹介する。



図3 NSblade®(写真)
Fig. 3 Overview of NSblade® (Photo)

2 ガスワイピング理論によるめっき付着量推定

ガスワイピングプロセスを物理式により表現しためっき付着量推定モデルは、ガスワイピング理論を用いることで、式1～3のような物理モデルで定式化されることが知られている。

$$u \frac{\partial u}{\partial x} = -\frac{1}{\rho_l} \frac{\partial P}{\partial x} - g + \frac{\mu_l}{\rho_l} \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) \quad (1)$$

$$\frac{\partial u}{\partial x} = 0 \quad (2)$$

$$\delta_m = \delta(x) + \frac{\tau_w(x)}{2\mu_l V_s} \delta^2(x) - \frac{1}{3\mu_l V_s} \left(\frac{dP_w(x)}{dx} + \rho_l g \right) \delta^3(x) \quad (3)$$

x は鋼板の長手方向の位置、 y はめっき膜厚方向の位置、 u と P は熔融金属の流速と圧力、 g は重力加速度、 V_s はライン速度、 μ_l と ρ_l は熔融金属の粘度と密度、 P_w と τ_w はワイピングジェットによる衝突圧力とせん断応力、 δ はめっき膜厚、 δ_m は平均めっき膜厚である。式1～3に諸条件を与えた後、数値計算を用いてめっき膜厚 δ を求めることで、めっき付着量を推定することができる。

上記の物理モデルをめっき付着量制御ロジックへ実装するために、当社のガスワイピング装置NSblade®の特性を考慮しつつ、ブロワからガスワイピング装置までの配管系統及びガスワイピング装置の駆動系といった周辺環境(図4)も含めた物理モデルを構築した。以降、本論文ではこれらの周辺環




図4 ガスワイピング装置及び周辺機器
Fig. 4 Equipment Configuration of Gas Wiping Device




図5 物理モデルの推定精度
Fig. 5 Estimation Accuracy of Physical Model

境も含めた物理モデルについて述べる。

物理モデルの精度を検証するため、操業データを用いてめっき付着量実績値と物理モデルによるめっき付着量推定値を比較すると図5のような結果が得られた。図5の横軸は相対誤差、縦軸は確率密度であり、相対誤差の分布を示したものである。

$$(\text{相対誤差}) = \frac{(\text{推定値}) - (\text{実績値})}{(\text{実績値})} \times 100(\%) \quad (4)$$

分布は全体的にプラス側(推定値が実績値より大きい)に偏っており、また、相対誤差の絶対値に対する平均値である平均絶対誤差率(MAPE; Mean Absolute Percentage Error)は約7%であった。このMAPEは分布のばらつきの大きさを示すことができるため、本論文では後述のモデルも含め、モデルの精度を表す指標として用いる。

めっき付着量制御では物理モデルによるめっき付着量推定モデルを用いたフィードフォワード制御が行われており、この推定モデルを用いて付着量の変化量を計算し、所定のめっき付着量となるように操作量を決定している。したがって、推定モデルを改善することは、めっき付着量制御の制御性能の改善につながる。

本論文では物理モデルを効率的に改善するために、モデル化誤差の要因の特定に加え、その要因を用いて物理モデルの改善を実現するために機械学習を活用したアプローチを行った。

3 機械学習による物理モデルの誤差要因の探索手法

物理モデルを効率的に改善するにあたり、物理モデル改善までの過程を次の項目

- ① 誤差要因の特定

- ② 物理モデルの改善見込みの試算
- ③ 誤差要因の影響度合いの算出

に分け、機械学習モデルを活用して、これらの項目を実現する手法を考えた。

項目①では誤差を生み出す可能性のある多数のプロセスデータの中から組み合わせを変えながら物理モデルの誤差を推論する機械学習モデルを構築し、最も誤差を上手く表現できたときの機械学習モデルの入力変数に着目する。これは、物理モデルの誤差はその入力変数のみを用いた表現で十分に近似できるためである。

項目②では項目①で求めたプロセス値を入力変数とした機械学習モデルを用いてめっき付着量の推定精度がどの程度まで改善するかに着目する。もし、機械学習モデル内部の非線形性を物理モデルに完全に織り込むことができれば、機械学習モデルと同じ推定精度まで物理モデルを改善できることになる。完全に非線形性を表現することは難しいとしても、物理モデルの改善の可能性としての指標となり得る。そもそも機械学習モデルを用いても推定精度の向上が見込めないようであれば、根本的なアプローチの見直しが必要であり、このことを物理モデルの改善に着手する前に判断することが可能となる。

項目③ではSHAPを活用し機械学習モデルが誤差を推論する過程を読み解く。項目①で求めたプロセス値と物理モデルの誤差との間に何らかの関係性を見出すことができれば、これをきっかけとし、現実の物理現象に紐づけを行い、物理モデルへ組み込む。現実の物理現象への紐づけには知見や経験を要するものの、やみくもに物理モデルの改善に取り組む場合と比較すると、きっかけがある分、効率的である。

3.1. ①誤差要因の特定

誤差要因を特定するために、設備全体で収集しているプロセスデータのうち、めっき付着量制御に関係する可能性のあるプロセスデータを経験、知見、設備知識、プロセス知識、及び相関係数と主成分分析の活用によって、プロセスデータを20個まで絞り込んだ。

次に、絞り込んだプロセスデータを説明変数、物理モデルのモデル化誤差を目的変数として機械学習

モデルを構築した。なお、機械学習モデルとしてはニューラルネットワーク、XGBoost、ランダムフォレスト、サポートベクターマシンなど様々な手法が存在するが、本論文では、複数モデルを適用した結果、最も高い推定精度が得られたニューラルネットワークを用いた。

さらに、ブラックボックスである機械学習モデルからモデル化誤差に対する各説明変数の影響度合いを調べるための指標として、SHAP 値を活用した。SHAP 値はゲーム理論において、複数のプレイヤー同士が連携した際に各プレイヤーの寄与度を表す Shapley 値の機械学習への応用であり、学習済みモデルにおいて、「それぞれの説明変数」が「そのモデルの予測値」に「どの程度寄与したか」を算出することができる。

機械学習モデルを用いた誤差要因特定のため、SHAP 値を用いて RFE(Recursive Feature Elimination；再帰的特徴量削減)を行い、最良のモデルの探索を行った。具体的な手順を以下に示す。

[RFE 手順]

1. 20種類のプロセスデータと誤差データを用意する。
2. プロセスデータを説明変数とし、誤差を教師データとする機械学習モデルを構築する。
3. 手順2.をハイパーパラメータ(ノード数、層数など)の調整を行いつつ複数回繰り返し、最良

のモデルを構築。

4. 手順3.にて得られた最良のモデルの SHAP 値より各変数の重要度を求める。
5. 最も重要度の低い変数を1つ削減し、残ったプロセスデータを説明変数とする。
6. 手順2.～5.を繰り返すことで、説明変数の数を一つずつ減らしながらモデルをそれぞれ構築する。

図6は、上記手順を500回行ったときの各 RFE の過程を集計したものである。横軸の Number of Features は機械学習の入力として用いた説明変数の数を示し、右に行くにつれ RFE により一つずつ変数が削除されていく過程を示す。図上段の Survival Rate は500回の試行の中で各変数が RFE の過程で削除されずに残った割合を示しており、20個の説明変数を色分けにて表現している。例えば、説明変数の数が19個のときの橙色で表現される説明変数の Survival Rate は約60%である(図6-A)。これは RFE により説明変数の数を20個から19個に削減する過程において、橙色で表現される説明変数が約40%の確率で重要ではないとみなされ削除されたことを示す。つまり、説明変数の数を繰り返し削減する過程で Survival Rate が減少しない説明変数は、目的変数である誤差を表現するのに重要であるとみなすことができる。また、図下段の Minimum Loss は RFE の過程により生成したモデルの損失関数の

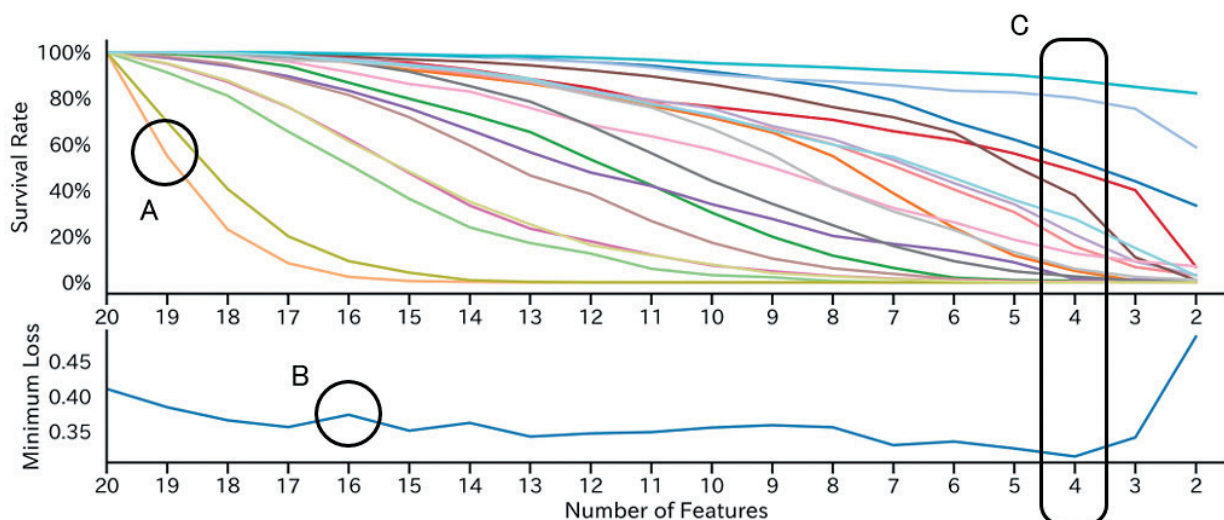


図6 説明変数の数と Survival Rate, Minimum Loss の関係
Fig. 6 Relation between Number of Features and Survival Rate(top), Minimum Loss(bottom)

値 (Loss) を集約し最小値を取ったものである。例えば、説明変数の数が16個のときの Minimum Loss は約0.4である (図6-B)。これは500回の試行の中で説明変数の数が16個のときの機械学習モデルの中で最も高精度であるモデルの Loss が約0.4であることを示す。

図下段の Minimum Loss の推移に着目すると、RFEにより説明変数を削減する過程において説明変数の数が4個になるまでは、徐々に Minimum Loss が小さくなり、さらに説明変数を削減すると、今度は逆に Minimum Loss が大きくなっている。そのため、4つのプロセスデータが誤差を生み出している主要因であると特定できた。

3.2. ②物理モデルの改善見込みの試算

特定された誤差要因を用いることで物理モデルをどこまで改善できる可能性があるのか、について試算するために、図6において説明変数の数が4個のとき (図6-C) の Survival Rate 上位の4つのプロセスデータから構築された機械学習モデルを用いてめっき付着量推定値を計算したところ、図7のような結果が得られた。図7の Target と Physical はそれぞれ機械学習モデルと物理モデルの分布を示している。機械学習モデル内部ではこれら4つのプロセスデータと物理モデルの誤差の関係を表現しており、物理モデルにおいてもこの関係を完全に表現することができれば、MAPE 約7%から約3%まで、つまり、5割以上の精度改善が見込めることになる。

したがって、これら4つのプロセスデータに着目した物理モデルの改善は取り組む価値があると判断し、MAPE 3%を改善指標として物理モデルの改善に取り組んだ。

3.3. ③誤差要因の影響度合いの算出

機械学習が獲得した非線形性を読み解くことについて考える。そこで、再び SHAP 値を用いて、機械学習モデルが導いた推定値に対して誤差要因として特定した4つのプロセスデータの寄与度をそれぞれ計算した。この計算結果を用いることで、機械学習モデルの内部において、これら4つのプロセスデータからどのように推定値が導かれたのかを読み




図7 モデル精度の改善目標
Fig. 7 Improvement Target of Physical Model Estimation Accuracy

解くことができる。

これら4つのプロセスデータとこれらの SHAP 値および物理モデルの誤差についての関係性を調べた結果、4つのプロセスデータのうち、3つのプロセスデータにおいて、プロセスデータ自体とその SHAP 値に関係性を見いだすことができた。

その3つのプロセスデータのうち、ノズル圧力を例とすると、図8のような関係性となる。

図8左図はノズル圧力と物理モデルの相対誤差を比較しており、左図からはノズル圧力とモデル化誤差の間には明確な関係を読み解くことはできない。これは、モデル化誤差は複数の誤差要因が互いに影響しあっているため、ノズル圧力以外の誤差要因の影響も物理モデルの相対誤差に反映されているためである。

一方、図8右図では、ノズル圧力とノズル圧力の SHAP 値を比較しており、ノズル圧力とノズル圧力の SHAP 値の間には、圧力が高い領域で若干のばらつきがあるものの、負の相関となっていることがわかる。このとき縦軸であるノズル圧力の SHAP 値の数値が意味することは、構築した機械学習モデルが物理モデルの誤差を推論した際に、推論された値のうち、ノズル圧力の影響分の値を示している。例えば、構築した機械学習モデルが物理モデルの誤差は0.15(15%)となると推論した際に、ノズル圧力の SHAP 値が0.05(5%)であれば、推論された誤差15%のうち、5%分がノズル圧力による影響、残りの10%がその他3つのプロセスデータによる影響によるものである。その他3つのプロセスデータの SHAP 値も計算できるため、それぞれの SHAP 値から推論された誤差の内訳を求めることができる。

したがって、図8の右図から、ノズル圧力が小さいとき、ノズル圧力は物理モデルの誤差がプラス(めっき付着量推定値が実績値より大きい)側となるように働き、逆に、ノズル圧力が大きいとき、ノズル圧力は物理モデルの誤差がマイナス(めっき付着量推定値が実績値より小さい)側となるように働いていることがわかる。

このようにノズル圧力とノズル圧力の SHAP 値を比較することで、その他の誤差要因の影響を除いて、ノズル圧力が誤差にどのような影響を与えているかを見いだすことができる。例えば図8のノズル圧力が35kPa付近において、左図では物理モデルの誤差はマイナス10%からプラス15%のばらつきが見られ、ノズル圧力と誤差の間には関係が無さそうに見られるが、右図ではノズル圧力が35kPa付近の SHAP 値は約5%に集まっており、ノズル圧力が35kPa付近ではノズル圧力は、その他の誤差要因に関わらず、常に物理モデルの誤差をプラス5%大きくするよう働くことがわかる。

上記のように、ノズル圧力を含め、そのプロセスデータ自体とその SHAP 値に関係性を見いだすことのできた3つのプロセスデータに対して、それぞれがどのように誤差に対して影響を与えているかを一つずつ読み解いた。

3.4. めっき付着量推定モデルの改善

前述に例として挙げたノズル圧力とノズル圧力の SHAP 値の関係から実際に物理モデルを改善した内容について紹介する。

ノズル圧力とノズル圧力の SHAP 値の関係から考察するに、ノズル圧力が小さいときに、物理モデルのめっき付着量推定値が今より小さい値を出力し、ノズル圧力が徐々に大きくなるにつれて、その推定値が徐々に大きい値を出力するように、物理モデルを修正すればよいことが分かる。

ガスワイピングプロセスにおいて、ノズル圧力が大きいときは、そぎ落とす溶融亜鉛の量が多くなることから、鋼板へのめっき付着量は小さくなり、逆に、ノズル圧力が小さいときは、めっき付着量は大きくなるという関係がある。

この関係と物理モデルに対して行いたい修正内容から、ノズル圧力が小さいときは、物理モデルで用いるノズル圧力の値を実際の値よりも大きくし、ノズル圧力が徐々に大きくなるにつれて、物理モデルで用いるノズル圧力の値をより小さくすれば良いと考えられる。

上述のようなノズル圧力の振る舞いは、圧力損失の振る舞いと似ていることから、ノズル圧力に起因する誤差を物理現象として圧力損失に紐づけることができると考えた。そして、物理モデルの計算過程において圧力損失を表現する部分に対し重点的に見




図8 ノズル圧力と物理モデルの誤差(左図)、ノズル圧力の SHAP 値(右図)の関係

Fig. 8 Relation between Nozzle Pressure and Relative Error(left), SHAP value of Nozzle Pressure(right)




図9 改善後物理モデルの推定精度
Fig. 9 Estimation Accuracy of Improved Physical Model

直しを行った結果、実際の圧力損失と物理モデルの計算過程における圧力損失に差異があることが判明し、そこを改善することで物理モデルの精度が向上した。

同様に、プロセスデータ自体とその SHAP 値に関係性を見いだすことができた残りの2つのプロセスデータに対しても検討を行うことで、最終的に図9のような結果が得られた。図9の Improved Physical, Target, Physical はそれぞれ改善後の物理モデル、物理モデルの改善指標、改善前の物理モデルの分布を示しており、改善後の物理モデルの MAPE は約4%となった。

以上の結果を踏まえ、物理モデルの改善前後及び改善指標としての精度を比較すると図10となる。図10の Physical は改善前の物理モデルの精度(図5), Target は物理モデルの改善指標(図7), Improved Physical は改善後の物理モデルの精度(図9)を示す。図10より、物理モデル精度は改善前後でそれぞれ MAPE 約7%と約4%であり、4割近く改善することができた。さらに、改善後の物理モデルは改善指標とした約3%近くまで改善したことから、本論文での提案手法により、機械学習モデル内部で表現される誤差要因として特定した4つのプロセスデータと物理モデルの誤差のおおよその関係を物理モデルにて表現できたと考える。




図10 モデル精度の比較
Fig. 10 Comparison of Model Accuracy

4 結言

当社のめっき付着量制御で用いているめっき付着量推定のための物理モデルに対し、機械学習モデルを活用し、物理モデルの誤差要因の特定及びその誤差要因を物理モデルに反映することで、物理モデルの効率的な改善に成功した事例について紹介した。

本論文で述べた手法は、非線形性を有するモデル化誤差を解析し、物理モデルを改善するためのアプローチの一つであり、めっき付着量制御の物理モデルに限ったものではない。そのため、めっき付着量制御システムの更なる高度化に加え、他設備への適用についても検討し、プラント制御高度化に貢献していく所存である。

参考文献

- 1) 安谷屋武志, 阿部雅樹, 庄司政浩, 矢野秀勝. “連続式溶融亜鉛めっきの気体絞り制御機構に関する検討”. 鉄と鋼, 66(1980), pp. 835-844
- 2) 安藤成海, 岩崎清俊, 福田豊史, 前原一雄, 小野泰太郎, 笠井研治. “溶融亜鉛めっきラインの亜鉛付着量制御”. 実務表面技術, 29(1982), pp. 160-164
- 3) K.T.Shin and W.K.Chung. “A new model and control of coating process at Galvanizing line”. IFAC Proc, 41 (2008), pp. 9138-9143
- 4) J.A.Thornton and H.F.Graff. “An analytical description of the jet finishing process for hot-dip metallic coatings on strip”. Metall. Trans. B, 7B(1976), pp. 607-618
- 5) 武石芳明, 山内昭良, 宮内澄隆. “連続溶融めっきにおけるガスワイピング機構”. 鉄と鋼, 81(1995), pp. 643-648
- 6) P.Naphade, A.Mukhopadhyay, and S.Chakrabarti. “Mathematical modelling of jet finishing process for hot-dip zinc coatings on steel strip”. ISIJ Int, 45 (2005), pp. 209-213
- 7) E.A.Elsaadawy, G.S.Hanumanth, A.K.S.Balthazaar, J.R. McDermid, A.N.Hrymak, J.F.Forbes. “Coating weight model for the continuous hot-dip galvanizing process”. Metall. Mater. Trans. B, 38(2007), pp. 413-424
- 8) S.B.Kwon, Y.D.Kwon, S.J.Lee, S.Y.Shin, and G.Y.Kim. “Numerical analysis for the coating thickness prediction in continuous hot-dip galvanizing”. Journal of Mechanical Science and Technology, 23(2009), pp. 3471-3478
- 9) 永原正章. “スパースモデリング-基礎から動的システムへの応用-”. (2017), コロナ社
- 10) S.M.Lundberg and S.I.Lee. “A unified approach to interpreting model predictions”. Advances in Neural Information Processing Systems 30, (2017), pp. 4768-4777