

データ駆動モデルのプロセス制御・操業支援への活用

Application of Data-driven Models for Process Control and Operational Action Recommendations

角谷 泰則*
Yasunori KADOYA

森田 彰
Akira MORITA

小杉 聡史
Satoshi KOSUGI

竹島 将太
Shota TAKESHIMA

抄 録

情報システム技術、人工知能技術の進歩を背景に、鉄鋼業においても、蓄積された大量の操業実績データを活用する取り組みが進展している。鉄鋼製造プロセスでは、高品質な製品の造り込みのために、原理原則に基づき開発してきた物理モデルを適用してプロセス制御を実施してきた。プロセス制御では、実用的な計算時間でモデル計算を行う必要があるものの、厳密な物理モデル計算に時間を要する場合や、原理原則に基づくモデル化が困難な対象が存在することから、操業実績データを活用して、さらなる高精度化、操業安定化を実現することが期待されている。本稿では、操業実績データに基づくデータ駆動モデルをプロセス制御や高度な操業支援に適用する技術とその適用事例を詳述する。

Abstract

Due to progress in information technology and artificial intelligence, initiatives to utilize the large amount of accumulated operational data are progressing in the steel industry. In the steel manufacturing process, process control has been implemented by applying physical models developed based on principles to produce high-quality products. In process control, it is necessary to perform model calculations within a practical calculation time. However, there are problems such as the long computation time required to calculate the exact physical model and some control objects are difficult to build models based on principles. Therefore, improvement of the control accuracy and stabilization of operations by utilizing operational data are highly anticipated. This article introduces technologies and application examples of data-driven models based on operational data developed to realize high accuracy process control and advanced operational action recommendations.

1. 緒 言

近年の情報システム技術、ならびに機械学習をはじめとする人工知能技術の劇的な進歩に伴い、高速ネットワークを通じてデータを収集する大容量データベースシステムを安価に構築し、大量データの解析から付加価値を生み出すことが可能になってきた。鉄鋼業においても、制御システムや生産管理システムからのデータ収集・蓄積は従来から行われてきたが、そのデータ容量・保存期間が飛躍的に増大し、システム間にまたがる多種多様な情報を集約、解析する環境を構築してきている。また近年、鉄鋼業のような過酷な環境下においても、安定した計測を可能とする技術が開発されて、実操業に関わるデータの質も高くなり、これらのデータを有効に活用して、品質向上や生産性向上につなげることが期待されている。

しかしながら、鉄鋼業は多様なプロセスによる多品種高生産であり、操業制約も厳しい上、すでにこれまでの技術開発や操業知見の積み重ねによる改善が行われており、単に統計解析や機械学習を適用するだけでは、さらなる歩留り改善や高生産の実現には不十分な結果に留まる場合が多い。

一方で、日本製鉄(株)は原理原則に基づき長年にわたって開発してきた物理モデルや、現場の経験に基づく操業知見を保有しており、さらなるプロセス改善を実現するには、物理・化学的知見に基づく物理モデルと統計解析や機械学習との組合せや、現場の操業知見との親和性の高い手法が求められる。日本製鉄の計測・制御分野の研究・開発部門では、物理モデル開発と統計モデル開発の強みを生かすデータモデリング技術や、操業実績データを活用した統計解析・機械学習による高度操業支援の研究開発を継続して

* プロセス研究所 インテリジェントアルゴリズム研究センター オートメーション研究室長 千葉県富津市新富 20-1 〒293-8511

きている。本稿では、操業実績データに基づくデータ駆動モデルの技術と、本技術をプロセス制御や、高度操業支援に活用した事例を紹介する。

まず2章では、物理モデルと統計モデルのそれぞれの強みを生かしたデータモデリング技術によるプロセス制御の取り組みを紹介し、次に3章でビッグデータに基づく高度操業支援に関する取り組みを紹介する。

2. データモデリング技術によるプロセス制御

鉄鋼製品の寸法（厚みや幅）、温度など数値で表現される定量的品質指標については、物理・化学法則に基づく物理モデルによる予測やプロセスの制御が広く行われている。しかしながら、理論や実験に基づく物理モデルの実プロセス適用には、現実の設備やプロセスに合わせたモデル調整が必要であり、物理モデルの誤差調整や物理モデルの代替として回帰式による制御モデルが広く適用されている。

物理モデルはその構成や数式と実プロセスとの対応が明らかであり、納得感が高い一方、現実の現象のすべてを表現するのは難しく、精度が不十分な場合がある。一方、機械学習モデルを含む統計モデルは実プロセスデータに基づくため高い精度を得やすいが、プロセスとの対応が必ずしも明確ではない場合が多い（説明性が低い）。また、新たな操業条件や材料に対しては、精度の信頼性がないという課題がある。

そこで、物理モデルと統計モデルを組み合わせ、プロセスへの説明性を確保しつつ精度を高める手法であるグレイボックスモデリングの技術開発を行っている。なお、この名称は、統計モデルを説明性が低いブラックボックス、物理モデルを説明性の高いホワイトボックスとして、両者を混合したグレイボックスと呼んでいるものである。

グレイボックスモデリングの方法としてはさまざまな形態が考えられるが、主なものとして、次のようなものが実機適用されている。

まずは、図1(a)のように、物理モデルの誤差を統計モデルで補正し、モデルの予測精度を向上させるものである。この手法は、物理モデルの予測誤差の実績データを用いて、それを予測する統計モデルを作成して構築される。

次に、図1(b)は、物理モデルのパラメータを統計モデルで設定するものである。この手法は、プロセスの定性的な特性は物理モデルで表現できているが、実プロセスにおけるパラメータの設定が難しい場合に適しており、操業実績から何らかの方法で物理モデルのパラメータを推定し、それを予測する統計モデルを作成して、構築される。

上記2つの形態の事例を次節以降で紹介する。

2.1 物理モデルの統計モデルによる補正技術

グレイボックスモデリングの1つめの形態（図1(a)）で





図1 グレイボックスモデリングの形態
Various configurations of gray box modeling

ある、物理モデルの誤差を統計モデルで補正して、モデルの予測精度を向上させる技術を2つ紹介する。

1つめは、自動層別制御モデル構築手法¹³⁾を適用して、統計モデルを構築する技術である。本手法は、操業因子空間をいくつかに分けた局所領域内の線形関係式の重ね合わせ（重み付き平均）として非線形モデルを構築する方法であり、領域分割の構造で、ある程度モデルの全体像が把握できるという特徴があるが、モデル構築にはある程度のデータ数が必要であるというデメリットもある。

もう1つは、過去の経験値、実績値、入出力関係に基づいてモデル化する事例ベースモデリング技術を適用して統計モデルを構築する技術である。本手法は、説明変数を含む大量のデータをデータベースに蓄積しておき、必要ときにデータベースから条件の類似するデータを抽出して、局所モデルを構築する方法であり、メッシュフリー（領域分割不要）で、データ数が少ない状態でもモデル構築できるという特徴があるが、モデルの全体像の把握が難しいというデメリットもある。

物理モデルの誤差を統計モデルで補正する技術を適用する場合には、上述の特徴を勘案して、適切な手法が用いられる。

2.1.1 データモデリング技術を用いた熱延クラウン形状設定技術

実操業で用いられる統計モデルの多くは、プロセスの非線形性に対応するため、製造条件などで層別した複数のモデルを用いている。しかしながら、その層別条件などのモデル構築は、人の経験や試行錯誤に頼っているため、モデル調整の作業負荷が高く、製造品種の多様化等に伴う精度劣化が課題となっている。このため、過去の操業データを用いた自動層別制御モデル構築手法を開発した。本手法は操業因子空間をいくつかに分けた局所領域内の線形関係

式 \hat{y}_i の重ね合わせ (重み付き平均) として非線形モデル \hat{y} を構築する方法である。この重みを決める活性度関数 Φ_i は、なるべく少ない層別数で精度の高い制御モデルになるよう実績データから自動的に生成される。

$$\hat{y} = \sum_{i=1}^M \underbrace{(w_{i0} + w_{i1}u_1 + w_{i2}u_2 + \dots + w_{ip}u_p)}_{\hat{y}_i} \Phi_i(u) \quad (1)$$

$u = (u_1, \dots, u_p)$: 説明変数, M : 領域分割数, w_{ij} : 回帰係数

図2は、2変数の空間を3つの領域に分割する活性度関数の例であるが、このように領域の境界が滑らかな活性度関数を用いることで、全体モデルも連続かつ滑らかな特性を表現することが可能である。領域を分割する点は、領域を等分割する点や領域内のデータ数を等分割する点を分割候補点として、その中から選択する方法もあるが、事前の物理的知識や操業上の基準から分割候補点を与えることも可能である。こうすることにより、事前の知見を取込んだモデルが構築され、モデルの説明性を向上させることができる。

本手法の特徴として、領域分割の探索には時間がかかるものの、領域分割が決定した後のモデル式による予測計算は軽く、活性度関数と回帰係数のみ計算できればよいので、実績データを保持する必要がない点があげられる。また、回帰係数を逐次学習することにより、操業の変動にも追従することができる。

以下では、本手法の適用例として、熱延クラウン形状設定技術³⁾を紹介する。

熱延仕上圧延では、各圧延機出側の板形状を安定通板範囲に収めつつ、最終圧延機出側の板クラウンを製品の許容範囲内にすることが求められ、各圧延機のクラウン・形状制御端 (ベアクロス角度、ワークロールベンディング力など) を適切に設定すること (クラウン形状スケジュールの決定) が重要である。クラウン・形状変化の上流から下流への影響を考慮し、制御能力範囲内の設定を行うには、数理最適化が有効である。さらに、板クラウンの予測精度向上のため、過去実績を用いたデータモデリング技術による物理モデルの補正を組合せたクラウン形状設定技術を開発した。




図2 活性度関数の例
Example of weight function

仕上入側から出側までのクラウン形状スケジュールは、各圧延機前後の板クラウンと板形状 (伸差率) に関する物理モデル⁴⁾から各圧延機の板クラウン制御量 (ε_i) に関する線形式表現を導き、二次計画法などの数理最適化により、適切に決定することができる (図3)。この際、制御能力範囲内で制約条件を満足できない場合には、制約緩和量を導入し実現可能な緩和解を求めたり、板厚スケジュールも決定変数に加えた問題に拡張して解を求めたりすることが可能である。

板クラウン、形状の予測は物理モデルに従って行われるが、実機環境においては、ロールの熱膨張量や摩擦量などの把握が難しく、十分な精度を得るのは難しい。そこで、過去実績データを用いた自動層別制御モデル構築手法による物理モデルの補正を行った。しかし、これをそのまま適用した場合、クラウン形状スケジュールの決定に非線形最適化もしくは線形近似が必要となる。

今回、補正モデルの説明変数 $u = (u_1, \dots, u_p)$ を、板クラウン制御量に依存しない変数 $u_1 = (u_1, \dots, u_{p_1})$ と依存する制御変数 $u_2 = (u_{p_1+1}, \dots, u_p)$ に分け、操業因子空間の分割は u_1 のみで行っても、補正モデルの精度は変わらないことを確認した (図4)。この補正モデルを用いれば、クラウン形状スケジュールを決定する際のクラウン補正量は、 u_1 を固定して u_2 に関する線形式で表され、二次計画法でも予測精度の劣化なく高速に最適解を得ることができる (図5)。

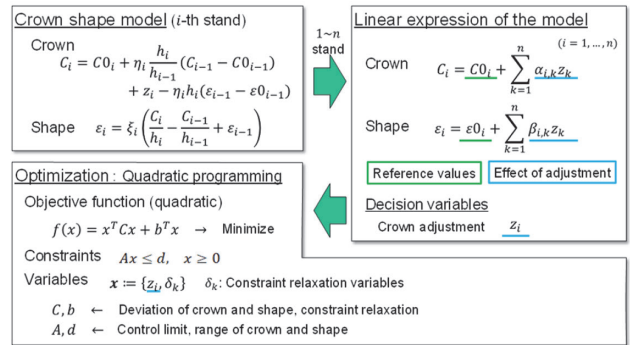


図3 クラウン・形状スケジュール設定
Crown and shape schedule set-up

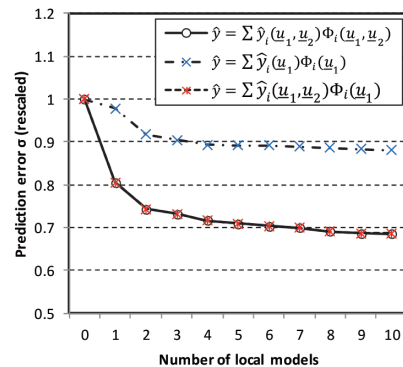


図4 モデルの違いによる予測精度比較
Comparison of model variations

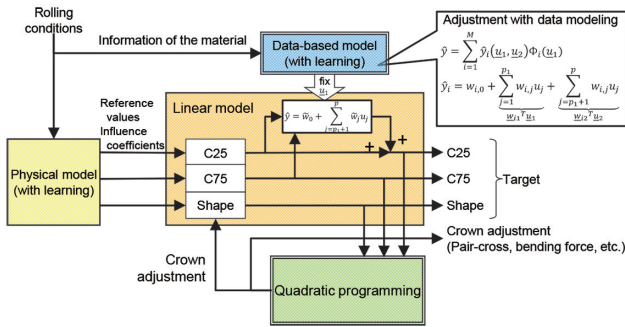


図5 データモデリング技術と数理最適化(二次計画法)の組合せ
Combination of data modeling and quadratic programming




図6 オンラインでのモデル予測精度比較
Comparison of model variations

実機においては、パラメータ誤差やプロセス変動があるため、予測誤差を逐次学習して、クラウン補正モデルを更新している。活性化関数 Φ_i (モデル空間分割) は固定とし、局所領域内の線形関係式の係数 w_{ij} を逐次修正する。実機適用の結果、クラウン予測精度を物理モデルに比べて約30%改善した(図6)。

2.1.2 データモデリング技術を用いた厚鋼板冷却温度制御技術

物理モデルの統計モデルによる補正のもう一つの手法を紹介する。本手法は、前述の自動層別制御モデル構築手法のように、操業因子空間をいくつかの領域に分割することは行わず、過去の製造条件を含む操業実績データを大量に蓄積した保存したデータベースから、今回の製造条件等に類似するデータを抽出し、類似データを用いて、モデル予測誤差を推定する局所モデルを構築する手法である。今回の条件に類似するデータを抽出する際には、データベースに保存された操業データ No. i の条件と今回の条件との距離 d_i を式(2)の重み付きユークリッド距離にて類似度を評価する。

$$d_i = \sqrt{\sum_{j=1}^m w_j \cdot (x_{i,j} - x_{n,j})^2} \quad (2)$$

ここで、 m は説明変数の数、 j は説明変数を表す添字、 $x_{i,j}$ は操業データ No. i の条件の説明変数、 $x_{n,j}$ は今回条件の説明変数、 w_j は重みである。

この距離 d の値が小さいほうから一定個数のデータを類似データとして抽出し、抽出したデータセットを用いて、目的変数であるモデル誤差 e と説明変数 x_j との関係式(3)の回帰係数を求めることで局所モデルを構築する。

$$e = a_0 + \sum_{j=1}^m a_j \cdot x_j \quad (3)$$

ここで、 a_1, a_2, \dots, a_m は回帰係数である。

なお、条件の類似するデータセットを用いて回帰係数を求めると、説明変数となる条件に偏りがあるため、説明変数の中に相関の高い組合せがある多重共線性が問題となる可能性があり、オンライン制御への適用の観点では好ましくない。このため、多重共線性の悪影響を排除できるPLS回帰(Partial Least Squares regression)の手法を適用して、局所モデルを構築する。

このようにして、モデル誤差を推定する局所モデルを構築できるが、産業応用上は、局所モデルの推定値が異常値となる確率を排除し、信頼性を高める必要がある。ここで、物理モデルの誤差を局所モデルで推定する場合には、各説明変数に対する回帰係数の正確性は求められず、推定値を高精度に求められればよいため、アンサンブル学習の考え方^{5,6)}を適用する。アンサンブル学習は、複数のモデルの出力を用いて最終的な出力を求める方法であり、今回条件に類似するデータを抽出する際の距離関数式(2)の重み w_j を種々変更することで、異なるデータを含んだデータセットを複数抽出できる。このように、重み w_j を変更することは、説明変数の内、重視する因子を変更して類似データを抽出することを意味する。

次に、図7に示すように、それぞれのデータセット G_1, G_2, \dots, G_M を用いて、 M 個の局所モデルを構築し、それぞれの局所モデルから今回条件でのモデル誤差の推定値 $\hat{e}_1, \hat{e}_2, \dots, \hat{e}_M$ を求め、 M 個のモデル誤差推定値の内、最大値と最小値を除く $M-2$ 個の平均値を最終的なモデル誤差推定値 \hat{e} とする。

以下では、本手法の適用例として、厚鋼板の加速冷却における温度制御技術を紹介する。

冷却温度制御では、水冷熱伝達モデルを含む鋼板温度予測モデルを用いて、冷却後の鋼板温度を予測し、この予測温度が目標温度と一致するように冷却装置を操作する。鋼板温度予測モデルは、伝熱現象に基づいてモデリングしているものの、鋼板の表面性状などモデル化困難な因子があるため、温度予測誤差が生じてしまう。このため、データベースに蓄積されたデータから温度予測誤差を推定する局所モデルを構築し、温度予測モデル(物理モデル)の計算結果を補正することで、冷却温度制御を高精度に行うことができる。本技術では、図8に示すように、鋼板の冷却終了時に鋼板温度予測モデルの予測誤差を計算し、製造条件や操業実績データとともにデータベースに保存する。そして、次材の冷却開始前に、製造条件や加速冷却の前工程

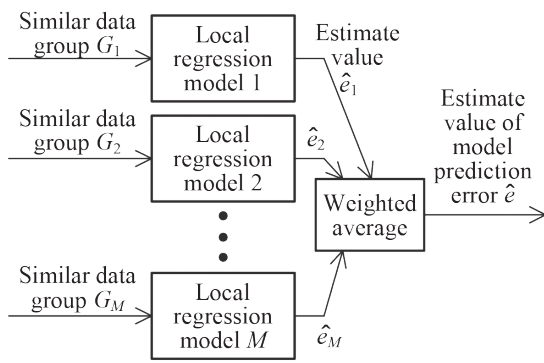


図7 複数の局所モデルを用いたアンサンブル学習
Outline of ensemble learning using multiple local regression models

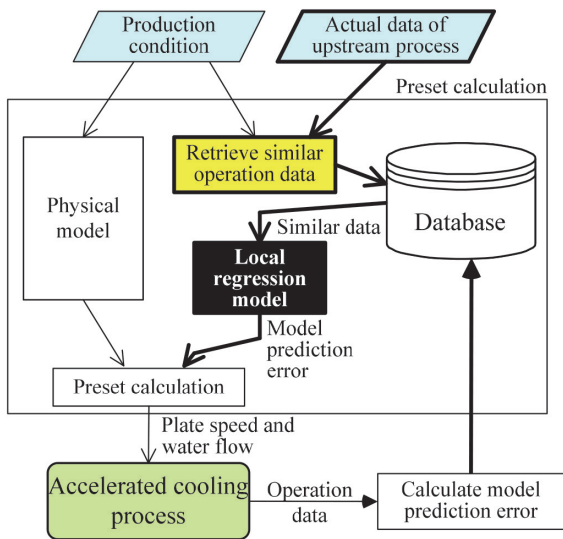


図8 厚鋼板冷却制御における局所モデルを用いた鋼板温度予測モデル誤差の補正
Correction of model prediction error using local regression model in plate cooling temperature control

である圧延工程での製造実績が、今回の条件に類似するデータをデータベースから抽出し、類似データを用いて局所モデルを構築し、モデル予測誤差を推定する。次材の冷却制御では、制御モデルが狙う目標値を前記推定したモデル予測誤差分だけバイアス補正して、冷却装置の操作量である鋼板搬送速度、冷却水量を決定する。

前述の通り、鋼板温度予測モデルは、伝熱現象に基づいてモデリングしているものの、鋼板の表面性状などモデル化困難な因子がある。そこで、厚鋼板加速冷却での鋼板温度予測誤差要因と考えられる因子を局所モデルの説明変数として用いた。具体的には、冷却水と鋼板との境界条件となる熱流束の誤差要因になると考えられる因子 (HF) および鋼板内部の熱伝導や変態発熱現象の誤差要因になると考えられる因子 (PP) を説明変数とした。これらの因子に対して、表1に示すように、距離関数式(2)の重み w_j を7条件変更して、 $M=7$ 個のデータセットを抽出した。条件 W-1 を基準に、一部の因子の重みを2倍または4倍とし、それ

表1 アンサンブル学習における説明変数の重み
Weight coefficient of explanation variable for ensemble learning simulation

Item No.	W-1	W-2	W-3	W-4	W-5	W-6	W-7
1 (HF)	1	2	1	1	1	2	2
2, 3 (HF)	1	1	1	1	1	1	1
4-6 (HF)	1	1	2	1	4	2	1
7-10 (HF)	1	1	1	1	1	1	1
11-24 (PP)	1	1	1	2	1	1	2

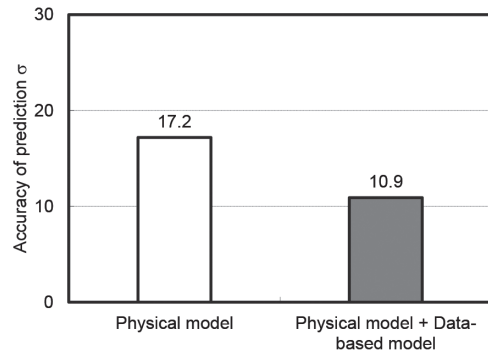


図9 厚鋼板冷却後の鋼板温度予測精度比較
Comparison of model prediction accuracy of plate finish cooling temperature

ぞれのデータセットを用いて局所モデルを構築した。

本手法を用いることで、冷却終了時の鋼板温度予測精度は、図9に示すように、鋼板温度予測モデル(物理モデル)の17.2℃に対して、10.9℃に向上し、冷却制御を高精度に行うことができる。

2.2 統計モデルによる物理モデルのパラメータ設定

次に、グレイボックスモデリングの2つめの形態(図1(b))である、物理モデルのパラメータを統計モデルで設定する事例として、転炉りん濃度推定において階層ベイズモデルを用いた例を紹介する。

転炉吹錬制御では、吹錬終了時の溶鋼温度と溶鋼成分を二次精錬で要求される目標値になるよう、送酸量と副原料投入量を指示するとともに、吹錬末期に炭素濃度と溶鋼温度がサブランス測定でサンプル測定されたのちには、ダイナミック制御の目的で、溶鋼成分と溶鋼温度を逐次推定し、吹錬の進行状況を推定している。

吹錬終了時の溶鋼りん濃度の制御も鋼の品質管理上重要になることから、推定する溶鋼成分は炭素濃度だけでなく、りん濃度も対象になる。吹錬終了時のりん濃度は吹錬開始時の溶銹りん濃度よりも低位なため、脱りん速度が溶鋼りん濃度に比例すると仮定する一次反応式

$$\frac{d[P]}{dt} = -k_p \times [P] \quad (4)$$

で溶鋼りん濃度 $[P]$ の推移を近似でき、その比例定数 k_p を脱りん速度係数と呼ぶ。吹錬開始時の溶銹りん濃度 $[P]_{ini}$ と脱りん速度係数 k_p があれば、一次反応式から任意吹錬




図 10 脱りんモデル
Dephosphorization model

時間の溶鋼りん濃度は $[P]=[P]_{ini} \times \exp(-k_p \times t)$ で推定できることになる (図 10)。

また、吹錬終了後に、実測の終点りん濃度 $[P]_{end}$ と吹錬時間 t_{end} が得られれば、脱りん速度係数は

$$k_p = \frac{1}{t_{end}} \ln \frac{[P]_{ini}}{[P]_{end}} \quad (5)$$

で計算できる。この脱りん速度係数 k_p は脱りん挙動を特徴づける値となる。ダイナミック制御の目的で、溶鋼りん濃度を推定するには、吹錬中に精度よく脱りん速度係数を予測する必要がある。そこで、過去吹錬データにおいて、サブランス測定までに判明している操業要因 X_i を説明変数にし、吹錬終了後に式 (5) で算出できる脱りん速度係数 k_p を目的変数として重回帰モデル

$$k_p = a_0 + \sum_{i=1}^I a_i \times X_i \quad (6)$$

を構成する。ここで $a_i (i=0, \dots, I)$ は重回帰パラメータであり、 I は説明変数の数である。この重回帰モデルを用いることで、サブランス測定以降、吹錬終了まで溶鋼りん濃度の推定が可能になった。

しかし、吹錬終了時の実績りん濃度と推定りん濃度を比較すると、実績りん濃度が高濃度側で推定値が実績値より低位になり、脱りに不利な条件が重回帰パラメータに十分に反映されていないことが懸念された。

そこで、定性的に脱りに影響を及ぼすことが知られている溶鋼温度をより重要視して重回帰モデルに反映することを検討した。吹錬末期の温度は、目標温度に十分近いと仮定して、重回帰パラメータには、目標温度との交互作用があるとし、加えて、1つの重回帰パラメータは目標温度のレンジ内であれば同符号であり、目標温度が異なっても1つの操業要因の脱りんへの寄与は定性的に同じになることを改良の要件とした。

このような要件を満たすモデルとして、階層バイズモデルが好適なため、下記のようにモデル化した。

$$k_{p,n} \sim N\left(a_0 + \sum_{i=1}^I a_i \times X_{i,n}, \sigma_Y^2\right) \quad (n=1, \dots, N) \quad (7)$$

$$a_i = \bar{a}_i + b_i \times Z_n \quad (i=0, \dots, I)$$

$$b_i \sim N(0, \sigma_i^2)$$

$$\sigma_i \sim N_+(0, v_i^2)$$




図 11 吹錬終了時りん濃度予測精度比較
Comparison of model prediction accuracy of phosphorus concentration

ここで、 $N(\mu, \sigma^2)$ は平均 μ 分散 σ^2 の正規分布を表し、 N_+ は半正規分布、 N はデータ数、 Z_n は目標温度である。 σ_Y と \bar{a}_i にはそれぞれ無情報事前分布と弱情報事前分布を設定し、 v_i には予め定めた正定数を設定した。さらに、ダイナミック制御時の溶鋼りん濃度推定には、交互作用パラメータの事後確率最大値を用いた。

この変更により、吹錬終了時りん濃度の予測精度は、RMSE (二乗平均平方根誤差) で 26% 向上することを確認した (図 11)。

3. データに基づく高度操業支援

操業異常や設備異常などの事象を判定するモデルを物理モデルに基づいて構築することは困難である。さらに、これらのモデル化においては、多数の正常操業・設備稼働データに対して比較的少数の操業異常・設備異常データが混在したデータとなっているため、このような正常・異常データ数が不均衡なデータ (不均衡データ) に対して異常データを精度よく検出できるモデリング手法が求められる。異常発生時には様々な要因が複雑に交絡していると考えられるため単純な線形回帰のようなモデルでは精度を得ることが難しい。一方で表現力の高い複雑なモデルを利用し操業異常や設備異常の発生を学習・検知できたととしても、なぜモデルがそのような判断に至ったかブラックボックス化されており解釈性が乏しく、要因の特定、改善アクションの策定につなげられないという問題がある。

上記の問題点を考慮し、発生頻度の低い操業変動・設備異常を精度良くモデリングする手法、モデル判定結果から異常の要因を抽出する解釈手法および主要因群に対して適切な変更アクション量を推薦する高度操業支援の枠組みを開発した。コークス押し詰まり懸念解析の事例をもとに開発した枠組みを紹介する。

3.1 コークス押し詰まり懸念解析支援枠組み

コークス炉操業において、窯単位にて日々、石炭の乾留および乾留後のコークス押し出しが行われる。ある押し出し操業 i について、石炭性状、炉温や乾留時間といったプロセス実績および窯状態などの操業変数 $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$

が、押し出し機の負荷に影響を及ぼすと考える。この時、押し出し負荷が閾値を超える場合に懸念状態 $y_i=1$ 、そうでない正常な場合に $y_i=0$ とラベリングする。押し詰まりに至ると操業コストおよび設備保全の観点から損失が大きく、懸念状態に至った時点で適切な操業アクション改善が求められる。

開発した枠組みを図 12 に示す。まず過去操業変数データ $\mathbf{X}=[x_1, x_2, \dots, x_n]^T$ と対応する過去懸念状態 $\mathbf{y}=[y_1, y_2, \dots, y_n]$ より、懸念確率を出力するモデル m を学習する。次に、解析対象の押し出し操業 j の操業変数 x_j をモデル m の入力として、懸念確率 $\Pr[y_j=1|x_j]$ を求める。次に、懸念確率に対する各操業変数 x_{j_1}, \dots, x_{j_p} の寄与度を求め、寄与度の高い操業変数を主要因群として抽出する。最後に、各主要因について押し出し負荷低となるようなアクション量を視覚化・推薦する。次節以降で、詳細を説明する。

3.2 不均衡データを考慮した機械学習による押し詰まり懸念モデル

機械学習において、学習時に全データを用いて損失関数を最小化しよう学習パラメータを最適化する。本稿事例においては、懸念データが少数の不均衡データであり、大多数の正常データ ($y=0$) が正しく検出できれば損失関数は小さくなるため懸念データが検出できない可能性がある。

提案手法では、図 12 に示すように、不均衡データの内、多数を占める正常データをアンダーサンプリングし、正常データに占める懸念データの割合を増加させサブデータセットを作成し、学習に用いる。これにより、懸念データの検出精度の向上が期待できるが、一方でアンダーサンプリングによるデータ数減によりモデルが過学習する可能性がある。そこで、図 13 に示すように、モデルのハイパーパラメータチューニングにより、よりシンプルなモデルとし、これらモデルを複数作成・多数決をとるアンサンブルモデルとすることで、過学習を回避する。

3.3 機械学習説明手法による押し詰まり懸念要因抽出

解析対象の押し出し操業 j の操業変数 x_j を、前節にて学習済みモデル m の入力として、懸念確率 $\Pr[y_j=1|x_j]$ を求める。ある操業変数 x_{jk} に対する寄与度は、 x_{jk} を正常操業データの平均値に置き換え推論した際に懸念確率がどの程度低下するかによって算出する。 x_{j_1}, \dots, x_{j_p} の寄与度を算出することで、単一の操業変数による懸念確率への影響を評価できる。

また、複数の操業変数値の組合せにより懸念確率が上昇する場合に SHAP[®] による寄与度分解を適用する。これにより、式 (8) に示すように解釈の難しい機械学習モデルの予測値を各操業変数の寄与度 ϕ の和に分解することで寄与度の相対的な大きさに応じて主要因群を抽出できる。

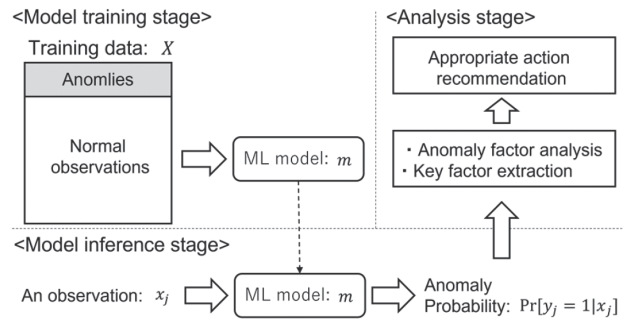


図 12 高度操業支援フレームワーク
Proposed framework of data-driven operation analysis

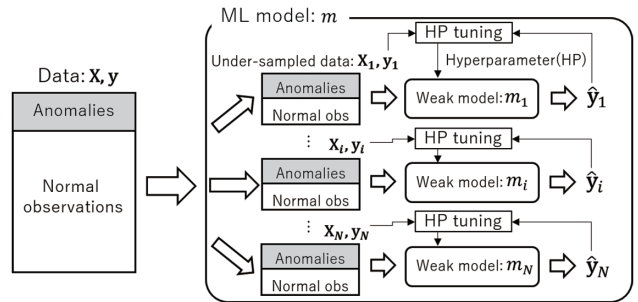


図 13 不均衡データを考慮した機械学習モデル
Training of ensemble ML model considering imbalanced data

$$\Pr[y_j = 1|x_j] = m(x_{j_1}, x_{j_2}, \dots, x_{j_p}) = \phi_0 + \phi_{j_1} + \dots + \phi_{j_p} \quad (8)$$

3.4 適正アクション量の視覚化・推薦

解析対象の操業 j の操業変数 x_j に対する寄与度 $\phi_{j_1}, \dots, \phi_{j_p}$ に対して、例えば寄与度の大きい順に l 個を主要因群とする。これら l 個の主要因群変数を改善アクション対象として、それぞれに対するアクション量を求める。まず、アクション対象外の $p-l$ 個の変数を用いて、過去正常操業の内、解析対象操業 j との類似操業を求める。類似性の判定においては、各操業変数で単位・次元が異なる可能性があるため変数毎に正規化した上で、例えば L2 ノルムを算出し閾値未満のものを類似操業とみなす。図 14(a) は、 $l=2$ の場合の解析対象操業と正常類似操業のプロット例である。次に図 14(b) のように、主要因平面で正常類似操業点群を各矩形領域でグループ分けし、グループ内の押し出し負荷平均値をカラースケールで表示する。

適正アクション量の推薦においては、これらグループに含まれる正常類似操業のデータ数とばらつきから押し出し負荷平均値の標準誤差を求める。標準誤差が閾値以下となるグループの内最も押し出し負荷平均値が低いものを次の操業に適用すべきアクション量 (図 14(b) 星印) とする。

4. 結 言

鉄鋼プロセス制御において、操業実績データに基づくデータ駆動モデルをプロセス制御や高度な操業支援に適用

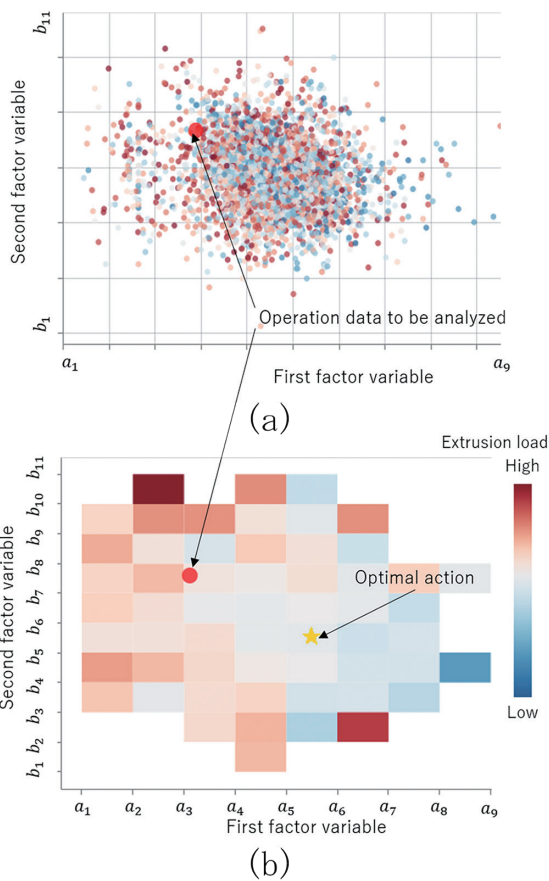


図 14 適正アクションの視覚化および推薦
Visualization and recommendation of optimal action

した代表的な事例を紹介した。それぞれのプロセスの特性や操業知見、さらには物理モデルとの組合せに応じた、操業実績データ活用技術の開発を推進してきており、製造歩留まり改善や生産性向上に寄与している。機械学習をはじめとする人工知能技術の発展は目覚ましく、今後もこのような最新技術を取り込んで、操業の高度化に貢献していく。

参考文献

- 1) 森田 彰 ほか：新日鉄住金技報. (411), 96 (2018)
- 2) 森田 彰 ほか：材料とプロセス. 26, 854 (2013)
- 3) 森田 彰 ほか：材料とプロセス. 35, 379 (2022)
- 4) 圧延理論部会編：板圧延の理論と実際
- 5) Schapire, R.E.: The Strength of Weak Learnability, Machine Learning, 5-2, 197 (1990)
- 6) 上田 ほか：アンサンブル学習における汎化誤差解析. 電子情報通信学会論文誌 D-2. J80-D-2-9, 2512 (1997)
- 7) 太田宣子 ほか：材料とプロセス. 36, 146 (2023)
- 8) Lundberg, S. M. et al.: A Unified Approach to Interpreting Model Predictions, Advances in Neural Information Processing Systems, 4765 (2017)



角谷泰則 Yasunori KADOYA
プロセス研究所
インテリジェントアルゴリズム研究センター
オートメーション研究室長
千葉県富津市新富20-1 〒293-8511



小杉聡史 Satoshi KOSUGI
プロセス研究所
インテリジェントアルゴリズム研究センター
オートメーション研究室 主幹研究員
博士(理学)



森田 彰 Akira MORITA
設備・保全技術センター
システム制御技術部 プロコン技術室
制御システム第二課 首席主幹



竹島将太 Shota TAKESHIMA
デジタル改革推進部 主幹