

技術論文

プロセス制御・品質管理におけるデータモデリング技術

Data Modeling Technologies for Process Control and Quality Control

森 田 彰*
Akira MORITA岩 村 健
Ken IWAMURA岸 真 友
Masatomo KISHI北 田 宏
Hiroshi KITADA中 川 義 明
Yoshiaki NAKAGAWA中 川 繁 政
Shigemasa NAKAGAWA

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，蓄積された大量データの解析に基づくプロセス改善が，大いに期待されている。しかしながら，実際のプロセス改善を達成するには，原理原則に基づき開発してきた物理モデルや，現場の操業知見との親和性の高い手法が求められる。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と適用事例を紹介した。

Abstract

Due to progress in information technology and artificial intelligence, improvements of processes based on the analysis of accumulated big data are highly expected in steel industry as well as in other fields. However, attainments of improvement in real processes require methodologies compatible with physical models based on fundamental principles and operational knowledge in factories. This article introduces data modeling technologies and their applications deploying strength of developments in physical models and statistical models.

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おり，これらの実操業に関わるデータを有効に活用して，品質向上や高生産性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，新日鐵住金(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。新日鐵住金の計測・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の研究開発を継続してきており，本論文ではその技術と事例を紹介する。

鉄鋼製造における品質には，製品寸法(厚みや幅)のほか，金属組織を決定する温度など，定量的に数値で表現される指標と，製品表面疵や内部欠陥の合否判定のように定性的に評価される指標がある。まず2章では数値で表現される指標に対する取組みを紹介し，次に3章で定性的な指標に対する品質改善の取組みを紹介する。

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、統計モデル（機械学習モデルを含む）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、プロセスとの対応は必ずしも明確ではない（説明性が低い）。また、新たな作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、




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

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、作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。

図1(c)は、実際に用いられるのは統計モデルのみであるが、プロセスの物理的特性との対応をとることで統計モデルの説明性を向上させたり、統計モデルを構築する際に、あらかじめ物理的知見を反映できるようにしたりする方法である。

上記3つの形態の事例を次節以降で紹介する。

2.1 理論モデルの統計モデルによる補正技術

まず、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目的で、新日鐵住金と歌山製鉄所の中径シームレスミルにおいて鋼管の収縮率予測を対象として精度向上を試みた事例を紹介する⁹⁾。

中径シームレスミルは、シンプル&コンパクトミルをコンセプトとして、1997年に新設した当時世界最新鋭のミルである。図2に示すように、従来のミル構成では必須であった再加熱炉を省略し、マンドレルミルの直後にエキストラクタ機能を兼ね備えた3ロールサイザーを配置することで、非常にコンパクトなミルを実現したが、従来なかった課題も生じた。一番影響が大きいものが、サイザー仕上げ温度の変動であり、対応として新たな制御技術の開発に取り組んだ。

図3に開発した外径制御システムの構成を示す。鋼管の熱収縮率は、サイザー出側での鋼管の平均温度に依存するが、鋼管の内部温度を測定することは不可能なので、温度シミュレータを用いて予測計算することになる。温度シミュ




図2 和歌山製鉄所中径シームレスミルの設備構成
Plant configuration of Wakayama Works seamless pipe mill




図3 外径制御システム構成図
System configuration of diameter control




図4 事例ベースモデリング
Case-based modeling

レータでは、加熱炉抽出からサイザー圧延までの加工実績や搬送時間実績を入力として、鋼管内部の温度分布を予測計算するが、当然ながらモデル誤差が存在する。また、鋼管の内部温度は測定できないため、実際の収縮率を正として、温度シミュレータ予測値に対する補正を付加している。その際には、誤差要因の解析結果に基づいて層別補正テーブルのメンテナンスで対応している。

過去の経験値、実績値、入出力関係に基づいてプラントなどをモデル化する事例ベースモデリングの概念を図4に示す。データベースに蓄積された過去事例の中から、本操業条件の近傍に含まれる類似事例のみを抽出し、近傍内データの予測誤差を最小化する局所モデリングによりモデル出力を生成する。この対象では従来の制御モデル（温度シミュレータ）の出力を活用した上で、残ったモデル誤差のみを事例ベースモデリング技術で予測することを考える。

近傍設定の予測精度への影響を調べるため、シミュレーション検証した結果を図5に示す。図5(a)は、補正を付加していない理論モデル単体の予測精度を表している。図5(b)に示しているのは、理論モデルの誤差を事例ベースモデリングの考え方をを用いて予測し、補正テーブル値を自動生成した場合を想定した精度である。従来精度に対して、自動補正を付加することで予測精度が向上していることがわかる。また、近傍を広く設定することで、ヒストグラムの山がなだらかに(図5(c))、近傍を狭くすると急峻になる(図5(d))。近傍を狭くすると予測精度は向上するが、蓄積データに異常値が含まれている場合などには、悪影響を受けやすくなるので注意が必要である。

2.2 統計モデルによる理論モデルのパラメータ設定

グレイボックスモデリングの2つめの形態(図1(b))の例として転炉吹錬制御モデルの開発内容^{2,3)}を紹介する。

転炉吹錬制御モデルはサブランス測定による吹錬中の溶鋼温度、炭素濃度実測値を始点として、吹止め(処理終了)時の溶鋼温度・炭素濃度を所定の目標値にするために必要な吹込み酸素量および冷材投入量を指示するとともに、サブランス測定以降の溶鋼炭素濃度・温度を逐次推定する。通常、酸素収支式(炭素濃度推定用)と熱収支式(温度推定用)から構成される。ここでは酸素収支式を検討対象と




図5 近傍設定と予測精度の関係
Relationship between setting of neighborhood and prediction errors




図6 溶鋼中炭素濃度と脱炭酸素効率(η)の関係
Relation between O_2 efficiency for decarburization and carbon content

する。

酸素収支式は、脱炭酸素効率(η)と溶鋼炭素濃度([C])の関係を吹込み酸素量(O_2)と[C]に関して積分することによって得られる。本モデルが制御対象とする吹錬末期には、図6に示すように吹錬の進行に伴い[C]が小さくなると η が低下する。脱炭反応($[C] + 1/2O_2 \rightarrow CO \uparrow$)が酸素供給律速から炭素供給律速に移ることによる。

η が低下しはじめる際の[C]は臨界炭素濃度(C_{cr})と呼ばれ、吹錬中の最大脱炭酸素効率(k_2)とともに、吹錬末期の

脱炭挙動を特徴づける値である。 C_{cr} と k_2 は上底吹ガス条件やスラグ量等の作業条件の影響を受けて変動することが知られている。従って正確な酸素収支式を得るためには、 C_{cr} と k_2 を精度良く把握することが重要である。

次に、具体的に酸素収支式を導出する。 η と $[C]$ との関係を C_{cr} と k_2 を用いて式(1)で表現する。

$$f(C) = k_2 \times \left(1 - \exp \left(-\frac{(C - C_L)}{C_{cr}} \right) \right) \quad (1)$$

式(1)を積分することにより、式(2)の酸素収支式が得られる。

$$\Delta O_2 = \frac{C_{cr}}{k_2} \left(\frac{1}{C_{cr}} (C_{SL} - C) + \ln \left(\frac{1 - \exp(-(C_{SL} - C_L)/C_{cr})}{1 - \exp(-(C - C_L)/C_{cr})} \right) \right) \quad (2)$$

グレイボックスモデリングの枠組みでは、この酸素収支式が物理モデルに対応し、パラメータである C_{cr} と k_2 を統計モデルで予測する。

統計モデルを構築する際に、 C_{cr} と k_2 の実績値が必要となるが、そのためには、吹錬中の $[C]$ を短い周期で測定する必要がある。実験室レベルでは可能かもしれないが、この方法で統計モデルを構築するために必要なサンプル数を得ることは非現実的である。そこで、実機の作業実績データ(吹込み酸素量、吹錬中・吹止め炭素濃度)を用いて後述の数値計画問題を活用して C_{cr} と k_2 を推定(同定)し、これを実績値とみなして統計モデルを構築する。この数値計画問題は、酸素収支式を制約条件、従来の知見等から得られた標準的な C_{cr} からの逸脱度と k_2 の理論値とのずれを最小化する評価関数から構成される非線形最適化問題である。この問題を逐次二次計画法で解くことにより、酸素収支を満足しつつ妥当と考えられる C_{cr} と k_2 が得られる。

実機におけるオンラインの計算では、あらかじめ求めておいた予測式をつかって C_{cr} と k_2 を予測し、この予測値を酸素収支式に適用することにより、必要な吹込み酸素量や溶鋼炭素濃度を逐次算出する。

C_{cr} と k_2 の予測式は、過去の実機の作業実績データと数値計画法で同定した C_{cr} と k_2 を目的変数、種々の作業条件

を説明変数とする重回帰モデルで構築した。表1には C_{cr} 予測式のモデルパラメータと分散分析から求めた各作業要因のF値を示す(F値が大きいほど、その作業要因が C_{cr} に及ぼす影響が大きいことを意味)。表1より生石灰の投入量のF値が他の作業要因より大きく、パラメータの符号は正で、生石灰の投入量(≡スラグ量)が大の場合に C_{cr} は増加することを表しており、従来研究の知見(スラグ量が増えると吹錬末期の脱炭酸素効率は低下)と一致する結果となった。

図7には吹止め炭素濃度実績値と C_{cr} と k_2 の予測値を適用した酸素収支式から求めた吹止め炭素濃度推定値の関係を示す。低炭素から中炭素の比較的広範囲の吹止め炭素濃度を良好に推定できた。

本論文で紹介した転炉吹錬制御モデルは各所に横展開中であるが、説明変数に排ガス情報から得られる炉内残留酸素を活用すると精度が改善することを確認済である。また、近年発展が著しい機械学習を統計モデル(C_{cr} と k_2 の予測式)の構築に活用することによりさらなる精度改善が期待できる。




図7 吹止め炭素濃度の推定精度
Accuracy of carbon content estimation

表1 C_{cr} の回帰結果
Results of regression of C_{cr}

No	Operational conditions	Parameters	t value	Pr(> t)	Df	Sum Sq	Mean Sq	F value	Pr(>F)
1	(Intercept)	-0.1638	-1.3	1.88E-01	—	—	—	—	—
2	Hot metal [Si]	-0.1250	-2.6	0.010338	1	0.2777	0.2777	53.7	3.09E-13 ***
3	Hot metal [Ti]	0.1521	2.9	3.90E-03	1	0.033	0.033	6.4	1.16E-02 *
4	Hot metal temp	0.0002	4.0	6.58E-05	1	0.0371	0.0371	7.2	7.42E-03 **
5	Hot metal weight	-0.0007	-4.0	5.85E-05	1	0.2002	0.2002	38.7	5.66E-10 ***
6	Lime	0.0067	9.5	2.00E-16	1	1.6034	1.6034	310.0	2.00E-16 ***
7	Scale	0.0004	2.4	0.016748	1	0.0639	0.0639	12.4	4.46E-04 ***
8	Sub material 1	-0.0004	-2.6	0.008235	1	0.1118	0.1118	21.6	3.49E-06 ***
9	Sub material 2	-0.0038	-2.2	2.46E-02	1	0.0311	0.0311	6.0	1.43E-02 *
10	Oxygen gas flow rate	0.0000	10.8	2.00E-16	1	0.6456	0.6456	124.8	2.00E-16 ***
11	Bottom gas flow rate	-0.0018	-2.8	5.11E-03	1	0.0325	0.0325	6.3	1.23E-02 *
Residuals					2710	14.0163	0.0052		

*: Pr < 0.05, **: Pr < 0.01, ***: Pr < 0.001

2.3 物理的知見を反映した統計モデル

適切な物理モデルがない、もしくは物理モデルがあっても実プロセスへのパラメータ調整が難しいため、実データから回帰式等で制御モデルを作成しているプロセスも多い。そのようなプロセスを対象に、精度改善とメンテナンス負荷低減を狙って、制御モデルの自動構築手法を開発した⁴⁾。

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て、適切な層別を自動的に作成し、回帰モデルを構築する手法の開発に取り組んだ。

開発した手法のモデル式を以下に示す。

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

操業因子 $\vec{u} = (u_1, \dots, u_p)$ で構成される入力変数空間は、 M 個の局所領域に分割され、各局所領域では品質 y と操業 $\vec{u}$ の関連を線形式でモデル化する。全体モデルは非線形の活性度関数 $\Phi_i(\vec{u})$ を重みとした各線形モデル $\hat{y}_i$ の和で表される。 $\Phi_i(\vec{u})$ は線形モデル $\hat{y}_i$ の寄与を表現し、 $\hat{y}_i$ が支配的な領域では1、ほとんど影響の無い領域では0に近い値を取り、任意の $\vec{u}$ に対し $\sum_{i=1}^M \Phi_i(\vec{u}) = 1$ とする。図8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。入力変数空間の局所領域への分割は、図9に示すように、全体領域から始めて任意の領域を2分割する方法の中から精度が良くなる分割を順次選択しながら、必要なモデル精度が得られるまで実施する。

この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




図8 活性度関数の例
Example of weight function




図9 入力変数空間の分割
Partitioning of input variable space




図10 熱間圧延プロセス
Hot rolling process

表2 モデル予測誤差の比較
Comparison of model errors

Estimation error	Std. dev.
Conventional model	1.000
Proposed model	0.920

Values are rescaled

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。

提案した手法を、熱間圧延プロセスの仕上圧延時における幅変動予測モデルに適用した(図10)。幅変動予測値は粗圧延出側の目標幅に反映されるが、粗圧延条件が決定される加熱炉抽出時点では、仕上圧延条件が不確定なため、物理モデルの適用が難しく、従来から重回帰モデル(材料により3区分)を使用していた。開発した手法を適用した結果、6つの局所領域からなるモデル($M=6$)を自動構築し、幅変動予測精度を8%向上させることができた(表2)。

本手法は報告したプロセスにおいて実機適用されており、制御精度向上とメンテナンス負荷低減を実現することができた。さらに他のプロセスにも広く適用可能な技術であり、適用検討、実機適用を進めている。

3. 統計的アプローチによる製造条件最適化

製品品質が“良品”、“不良品”のように定性的な情報で表現される場合には、まず品質と膨大な数の操業条件との関係を表現するモデルを構築した上で、品質条件を最適化

するような操業条件を決定する必要がある。

さらに、品質には確率的な事象の寄与が大きく、物理法則では十分に表現できない場合が多く、統計的なアプローチが要求される。

3.1 PCA-LDA と DDQI による品質改善

棒鋼特殊鋼の内部欠陥の品質改善の取組みとして、PCA-LDA (Principal Component Analysis-Linear Discriminant Analysis) を用いて定性的品質情報と操業条件との関係をモデル化し、DDQI (Data-Driven Quality Improvement) により操業条件を最適化した例^{5,6)}がある。

PCA-LDA では、まず操業条件データ $X \in \mathbf{R}^{N \times P}$ を主成分分析 PCA により R 個の主成分得点 $T_R = XV_R$ ($\in \mathbf{R}^{N \times R}$) に圧縮する (N はデータ数, P は操業条件の数)。 $V_R \in \mathbf{R}^{P \times R}$ はローディング行列と呼ばれ、 X の特異値分解によって得られる。次に、主成分得点の空間において線形判別分析 LDA を用いて、良品と不良品の 2 クラスをもっともよく分離する判別軸 $J \in \mathbf{R}^{N \times 1}$ を求める。

$$J = T_R K_{PCA} = XV_R K_{PCA} = XK_{LDA}$$

ここで、 $K_{PCA} \in \mathbf{R}^{R \times 1}$ は主成分得点 T_R に対する判別軸を表すベクトルであり、これを元の操業条件データ X の空間に変換したものが判別係数 $K_{LDA} = V_R K_{PCA}$ ($\in \mathbf{R}^{P \times 1}$) である。

解析対象とした操業条件変数は、二次精錬から分塊圧延までの 40 変数で、良品 532 サンプル、不良品 208 サンプルのデータから、主成分数 6 の PCA-LDA による品質判別モデルを作成した。図 11 に示すように、良品と不良品が概ね分離できており、LDA の判別係数 K_{LDA} から、各操業条件が品質に及ぼす影響を算出することができる (図 12)。ただし、操業条件の中には、互いに独立ではなかったり、品質とは擬相関であったりするものも存在し得るので、影響係数の比較的大きいものに着目しつつ、物理的知見や操業知見と矛盾しないものに絞り込む等の判断を行い、最終的には実験室や実機での試験による検証が必要である。

さらに、この判別モデルと本質的に同一な主成分回帰 PCR (Principal Component Regression) による、品質モデル (定性的品質を定量化した品質のモデル) $Y = T_R K_{PCR}$ ($Y \in \mathbf{R}^{N \times Q}$) を構築し (Q は品質変数の数)、DDQI により歩留りを改善させる操業条件を求めることができる。目標良品率に相当する品質を希望品質として、それを実現する操業条件を求めるが、品質変数の数 Q は主成分の数 R よりも少ない場合が大多数であり、操業条件は一意には決定できない。このため、操業条件に関する二次形式の評価関数を設けて最適化問題により操業条件を決定する。この際、実現可能な操業条件範囲を制約条件とするとともに、各操業条件の変更しやすさを評価関数の重みに反映する。

表 3 は先の解析例に対して、操業条件変更の容易性、コスト等を考慮して DDQI を用いた運転条件推定結果の一部である。ベース条件に対して良品率を 10% および 20% 改




図 11 線形判別分析の結果
A result of linear discriminant analysis




図 12 品質への影響係数の一部
Examples of influence coefficients for quality

表 3 運転条件推定結果
Recommended points to improve the quality

Factors	Yield		
	Base	10% up	20% up
S-1	3.6	5.0	6.6
S-5	2.9	4.2	5.5
B-1	87	89	92

善する場合の操業条件 (S-1, S-5, B-1) の推定値を示している。実機確認試験においても、表 3 の推定結果に概ね一致する改善結果が得られ、本手法の妥当性と有効性が確認できた。

3.2 一般化線形モデルによる品質改善

前節の事例は、合否判定の二値を線形判別モデルで表現するものであるが、より一般的な品質指標をモデル化する方法として一般化線形モデル (GLM; Generalized Linear Model) を用いた事例^{7,8)}がある。GLM では説明変数 x_i の線形式である線形予測子 S に可逆かつ微分可能な連結関数 ℓ を用いて、目的変数 y の予測値 $\hat{y}$ をモデル化し、実際の品質データの確率分布に適合した解析を可能とする。

$$S = c_0 + \sum_{i=1}^I c_i x_i, \quad \hat{y} = \ell(S)$$

連結関数 ℓ は対象とする品質データに応じて設定するが、表 4 に鉄鋼製品の典型的な品質解析に有効な GLM の例を示す。板厚のような連続値に対しては ℓ を恒等関数とした重回帰を用いればよいし、欠陥個数のような係数値には ℓ を指数関数としてポアソン回帰、合格率のような比率には ℓ をロジスティック関数として、ロジスティック回帰を用い

表 4 鉄鋼製品の品質解析に有効な GLM
Effective GLMs in analysis of qualities of steel products

Quality	Accuracy of sheet gauge	Number of defects	Acceptance ratio
Sort of data	Continuous	Count	Ratio
Regression	Normal	Poisson	Logistic
Distribution of the objective	Normal	Poisson	Binary
Link function ℓ	S	$\exp(S)$	$[1 + \exp(-S)]^{-1}$

ればよい。

GLMを用いて、製品品質に対する最適操作条件を決定するには、線形予測子 S を、操作可能な変数で構成する S_1 と制御できない外生変数で構成する S_2 の和に分解する。

$$S_1 = c_0 + \sum_{i=1}^J c_i x_i, \quad S_2 = \sum_{i=J+1}^I c_i x_i \quad (3)$$

欠陥個数や不合格率をできるだけ小さくする操作条件を求めるためには、操作可能な変数の実績データの変動範囲内で S_1 が最小となる点における操作条件を最適値とする。最適操作条件に対する品質 ($=S$) は、 S_2 を実績データの平均でおきかえて推定する。

鉄鋼製品を対象に、連続鋳造から分塊圧延までの操作条件を用いて、製品ロット毎に、ある疵発生率のロジスティック回帰を実施した。

図 13 に線形予測子の値と疵発生率の関係を表す。回帰に用いたデータ (●) のプロットと連結関数 (ロジスティック関数) の一致は良好であることが確認できた。図 14 は、式 (3) における S_1 と S_2 の関係のプロットである。操作可能な変数の実績データの変動範囲内での S_1 の最小値 (-2.0) と、 S_2 の実績データの平均値 (-1.3) から、最適操作条件に対する品質は $S=-3.3$ と推定できた。本手法で推定した最適操作条件をもとに、回帰精度に対して特に影響の大きい条件を品質が改善する方向に変更した結果、図 13 および図 14 の白丸 (○) で示すように疵発生率の改善が確認できた。

4. 結 言

鉄鋼プロセスにおける、データを活用したプロセス制御、品質改善の取組みを紹介した。これらは新日鐵住金の取組みの一部であり、各プロセスの特性、物理モデルの精度や現場の操業知見に応じて、さまざまな技術開発、改良を行っている。

生産管理システム、プロセス制御システムからのデータ




図 13 GLM による解析結果
Result of analysis using GLM




図 14 最適操作条件の導出
Derivation of the optimal operational point


収集・蓄積システムは拡充され続けており、さらなるデータ活用が求められている。機械学習をはじめとする人工知能技術も発展を続けており、それらの最新技術を取り込み、プロセス、操業の知見と組み合わせて操業改善に引き続き取り組んでいる。

参考文献

- 1) 岸真友 ほか：計測と制御. 44 (2), 116 (2005)
- 2) 岩村健 ほか：材料とプロセス. 20, 954 (2007)
- 3) 岩村健 ほか：材料とプロセス. 27, 790 (2014)
- 4) 森田彰 ほか：材料とプロセス. 26, 854 (2013)
- 5) 中川義明 ほか：日本設備管理学会誌. 19 (4), 220 (2008)
- 6) 中川繁政 ほか：計測と制御. 48 (2), 206 (2009)
- 7) 北田宏 ほか：材料とプロセス. 23, 199 (2010)
- 8) 中川義明 ほか：オペレーションズ・リサーチ. 56, 654 (2011)



森田 彰 Akira MORITA
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
主幹研究員
千葉県富津市新富20-1 〒293-8511



岩村 健 Ken IWAMURA
プロセス研究所
計測・制御研究部 主幹研究員



岸 真友 Masatomo KISHI
プロセス研究所
鋼管プロセス研究部 主幹研究員



北田 宏 Hiroshi KITADA
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
上席主幹研究員 博士(情報学)



中川義明 Yoshiaki NAKAGAWA
業務プロセス改革推進部 部長



中川繁政 Shigemasa NAKAGAWA
プロセス研究所
計測・制御研究部長 博士(工学)