

高炉操業データの可視化, 解析技術の開発

Development of Blast Furnace Operation Data Visualization and Analysis Technology

松崎 眞六* 伊藤 雅浩 森田 彰
Shinroku MATSUZAKI Masahiro ITO Akira MORITA

抄 録

高炉の操業データやセンサデータを活用するため、データの可視化、解析技術の開発を行った。データの可視化については、シャフト圧力やステーブ温度の多量データを2次元的に可視化画像化し、さらにデータの空間変化率、時間変化率なども合わせて可視化画像化した。その結果、高炉の操業状態の推定の精度向上と迅速化を図ることができた。また、CbLW-PLSを用いた高炉の操業状態の可視化技術の開発も行った。データの解析技術については、JITモデリングを応用した“大規模データベースオンラインモデリング”や、機械学習を用いて、溶銑温度等の予測モデルを開発し、その予測性を評価した。

Abstract

In order to utilize operation data and sensor data of blast furnace, we developed data visualization and analysis technology. For visualization of data, a large amount of data on shaft pressure and stove temperature was visualized in two-dimensionally, and then the spatial change rate and time change rate of the data were also visualized. As a result, the accuracy and speed of estimation of blast furnace operation was improved. In addition, the visualization technology of blast furnace operation state was developed using CbLW-PLS. As for data analysis technology, a prediction model such as hot metal temperature was developed using “large-scale database online modeling” applying JIT (Just-In-Time) modeling and machine learning, and its predictability was evaluated.

1. はじめに

高炉の操業を理解、推定、制御するうえで、高炉のデータを活用する取り組みは従来から行われている。まずは高炉の操業について、羽口からの送風量や微粉炭の吹込み量、炉頂からの原料の装入量、装入方法など種々の操業条件、また、原料の成分や粒度の原料条件、溶銑温度や溶銑成分スラグ成分などの種々のデータの時系列推移図やXYプロットを描画し、眺め、理解、解釈することが、高炉技術者の基本作業となっている。次にこれらのデータを用い、統計的な解析を行う、様々な方法で可視化する、あるいは数式モデル計算と比較する、模型実験結果と比較する、などの作業を行い、炉内を理解し、高炉の制御方法を検討する。

また、高炉操業に関するデータは、いわゆる、送風、装入のような基本的な操業データだけでなく、高炉に設置された種々のセンサ(図1¹⁾)からも多量に得られる。ただ、高炉は高温・高圧容器であり、原料として破碎物を用いているために炉内は多粉塵などの環境下になっており、さら

には固体、気体、液体の三相が混在した炉であるため、センサの設置なども難しく、実際には解析に本当に必要なデータを十分に得ることは困難である。したがって得られるデータを基に可視化あるいは統計解析など、さらに最近では、機械学習、人工知能などの手法を十分に活用して、高炉の炉内現象を理解し、さらには推定、予測することが必要である。

2. 高炉データによる可視化の取り組み

高炉炉内の可視化の観点からは、高炉は高さ方向だけでなく、炉周方向や炉半径方向に空間的な広がりを持った炉であり、その操業状態は、空間的かつ時系列的に時々刻々変化している。したがって、本来は2次元、あるいは3次元的に広がりを持って、かつ時間的に連続する情報を得て、その情報を基に可視化することが望まれる。

図1に示したように、高炉には様々なセンサが設置されており、炉の操業状況を把握することができるが、多くのセンサが1次元的な点情報であり、また炉内を測定できる

* プロセス研究所 製鉄研究部 主幹研究員 博士(工学) 千葉県富津市新富 20-1 〒293-8511

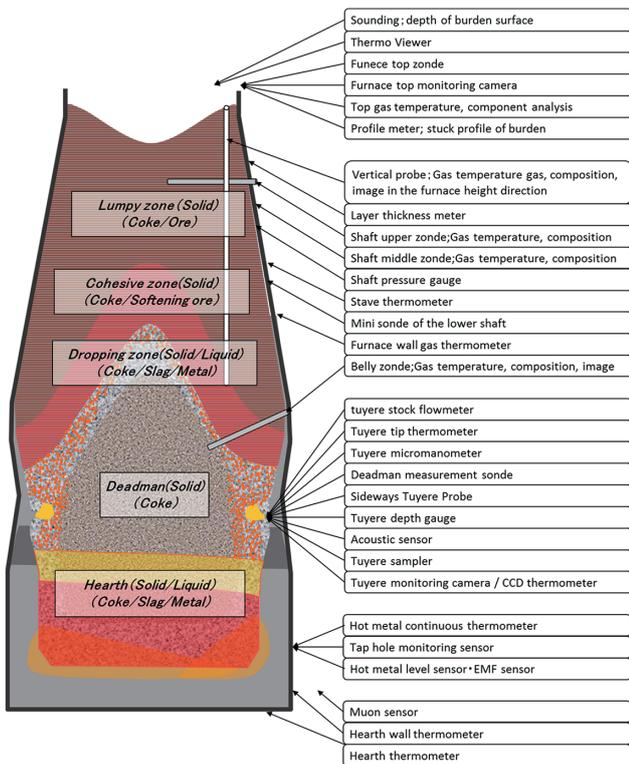


図1 高炉に設置されているセンサの概要図¹⁾
Outline of sensor installed in blast furnace¹⁾

シャフトゾンデ, 垂直ゾンデ, 炉腹ゾンデ, 炉芯ゾンデ²⁾については測定頻度が1日に数回からひと月に1回程度と月数, その測定頻度の少ないものも多い。そこで, 2次元的な設置状況ではあるものの, 空間的に広がりを持って設置され, かつ時間的に連続してデータを得ることができる, 炉体冷却水の温度(ステーブ温度)とシャフト圧力データを用いて, 高炉の炉体表面での状況を2次元に可視化する開発を行った。

2.1 2次元の可視化システム³⁻⁸⁾

高炉の炉体上に設置されたセンサデータ进行处理するうえで課題となるのは次の点である。高炉の炉体は単純な円筒ではなく, 円錐の組み合わせで構成されているため2次元平面化に工夫が必要となる。基本的には高炉の炉体形状を考慮しつつ, 炉の外表面, 及びセンサ設置位置を炉高方向, 炉周方向2次元平面に射影展開し, センサの計測データを描画した。さらにセンサデータのない部分は線形補完することによりデータを補い, それにより2次元の展開図を得た。

図2にステーブ温度, シャフト圧力情報の2次元可視化例を示す。図2中の左上図はステーブ温度, 右上図はシャフト圧力データの2次元可視化例である。図の横軸は炉周角度, 縦軸は羽口から炉頂までの炉の高さ方向で, *は測定センサの位置を示している。また, これらの2次元可視化画像を時間推移に伴い逐次更新することにより, リアルタイムに時間推移を監視することが可能である。オンラインシステムでは, 通常1秒周期で, データが更新, 蓄積される。

また, 高炉炉内の種々の現象は時間的な遅れ, あるいは空間的な動きを伴って変化すると考えられるため, ステーブ温度, シャフト圧力の現時点の値に加えて, 空間的な変化率や時間的な変化率も計算し, 2次元可視化した。図2中の左下図はステーブ温度の時間変化率の展開図である。時間変化率の画像を監視することにより, 温度の測定値を監視するより, より早期かつ精度良く, 炉内変動を把握することが可能となる。時間変化率はシャフト圧力に対しても定義可能である。

図2中の右下図はシャフト差圧である。圧力は炉内の充填構造やガス流れの変化を敏感に反映するが, 圧力情報を

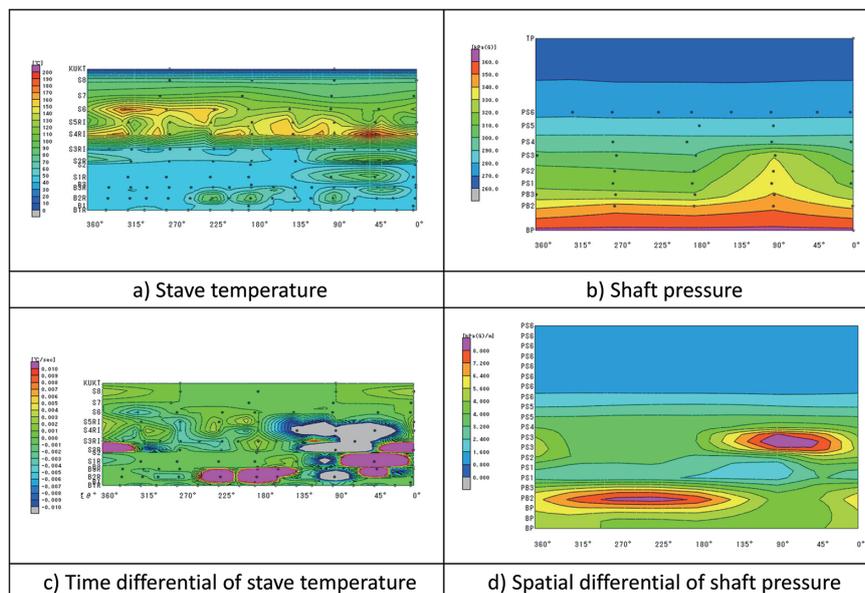


図2 ステーブ温度, シャフト圧力情報の2次元可視化例
Example of two-dimensional visualization of stave temperature and shaft pressure

細かく見るために従来から圧力の空間的な変化率、いわゆる差圧を監視してきた。本システムではこの差圧を一般化した空間変化率を計算し可視化した。なお、空間変化率はステープ温度に対しても定義可能である。

これらの可視化結果を時系列的に監視することにより、炉内の状況の変化を容易に把握することが可能となる。また、シャフト圧力データに対しては、実炉データの解析だけでなく、高炉のシャフトを模擬した模型実験や計算機シミュレーションによる解析も試みられている^{9,10)}。

2.2 3次元描画機能¹¹⁾

2次元に展開した可視化画像では、高炉特有の形状を特徴づけるシャフト部、ベリー部、ボッシュ部などとの位置関係が直感的に把握しにくくなる。また、高炉炉床部の温度情報については、炉床の側壁面だけでなく炉底も含めた3次元的な温度の動きを監視する必要がある。したがって、炉の表面情報ではあるが、炉全体を3次元的に可視化するための機能も開発した。

(1) 3次元描画方法

3次元の描画は、高炉の炉底面中心位置を原点として、炉高方向、炉半径方向、炉周角方向、の3次元座標系を設定し、透視投影法を用いて可視化を行った。またシャフト圧力に対しては、空間変化率ベクトルを炉高接線方向・炉周接線方向展開平面上で定義し、同時に描画可能とした。

(2) シャフト部の3次元可視化例

図3に、ステープ温度、及びシャフト圧力とその空間変化率ベクトルの3次元可視化例を示す。時間推移に伴って計測データを更新することにより高炉の動的挙動を3次元的な動画情報として監視でき、炉体上でのステープやシャフト圧力の変動の相互の関連性の把握がより容易となり、炉内現象の理解や操業監視力が高まる。

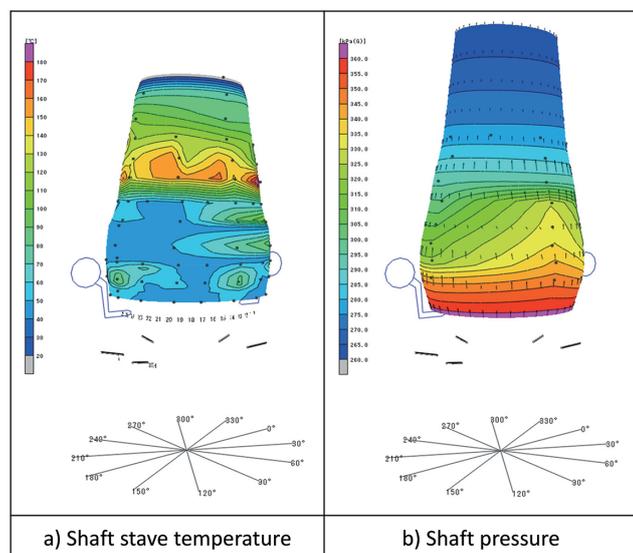


図3 シャフト部の3次元可視化例
Example of three-dimensional visualization of shaft region

(3) 炉床側壁・炉底部の温度の可視化例

図4に炉床側壁部と炉底部の温度データを用いて3次元的に可視化した例を示す。この図から炉床側壁部や炉底の温度の上昇降下などの温度の変化が、どの部位のどのような方向から、どのように進行したかを理解することが可能となる。たとえば、6月はすべての温度が沈静化しているが、8月には炉床側壁温度が上昇し、11月には炉床側壁温度が沈静化し、炉底部の温度が上昇しているなど3次元的な変化を読み取ることができる。

2.3 監視機能

シャフト圧力データ、温度データ及びその時間変化率、空間変化率等の2次加工データを用いて監視機能を付与することも可能である。

(1) シャフト圧力変動監視機能

シャフト圧力データについてはシャフト圧力の時間変化率を用いて、変動を監視することができる。たとえばシャフト圧力の時間変化率の最大値と最小値、すなわち最も変動した部位と最も変動しなかった部位の時間変化率の差を監視することにより、迅速なシャフト圧力の変動監視が可能となる。図5にシャフト圧変動の監視画面の例を示す。監視画面では、シャフト圧力の時間変化率の最大値と最小値の差がある閾値を超えると、画面の一部が青から赤の点滅となり、アラームを発するような機能を具備している。

(2) 付着物厚み監視機能

ステープ温度データについては、熱流束から付着物厚みを推定することが可能である。高炉の操業を健全に行うためには、炉壁のガス流量の監視が必要であり、熱負荷が必要以上に上昇しないよう、またステープ前面に付着物が生成しないように、炉壁のガス流れを制御することが要求される。ステープの深さ方向(水平方向)に2点設置された熱伝対の温度を用いて、1次元定常伝熱と付着物の物性値を仮定することにより、付着物の厚みを推定することができる。

ステープ温度、熱流束、付着物厚みの描画例を図6に示す。一定の仮定のもとではあるがステープ温度データを付着物厚みという実態的な数値に変換することにより、炉内の熱的な状態や、炉壁の状態がより具体的に可視化可能となる。

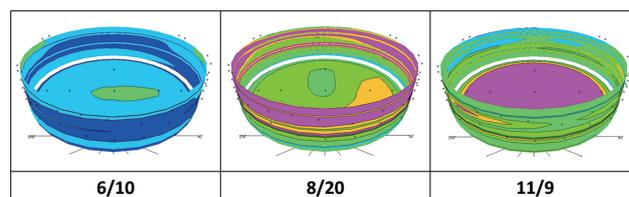


図4 炉床側壁・炉底部の温度の3次元可視化例
Three-dimensional visualization example of temperature of hearth and hearth wall

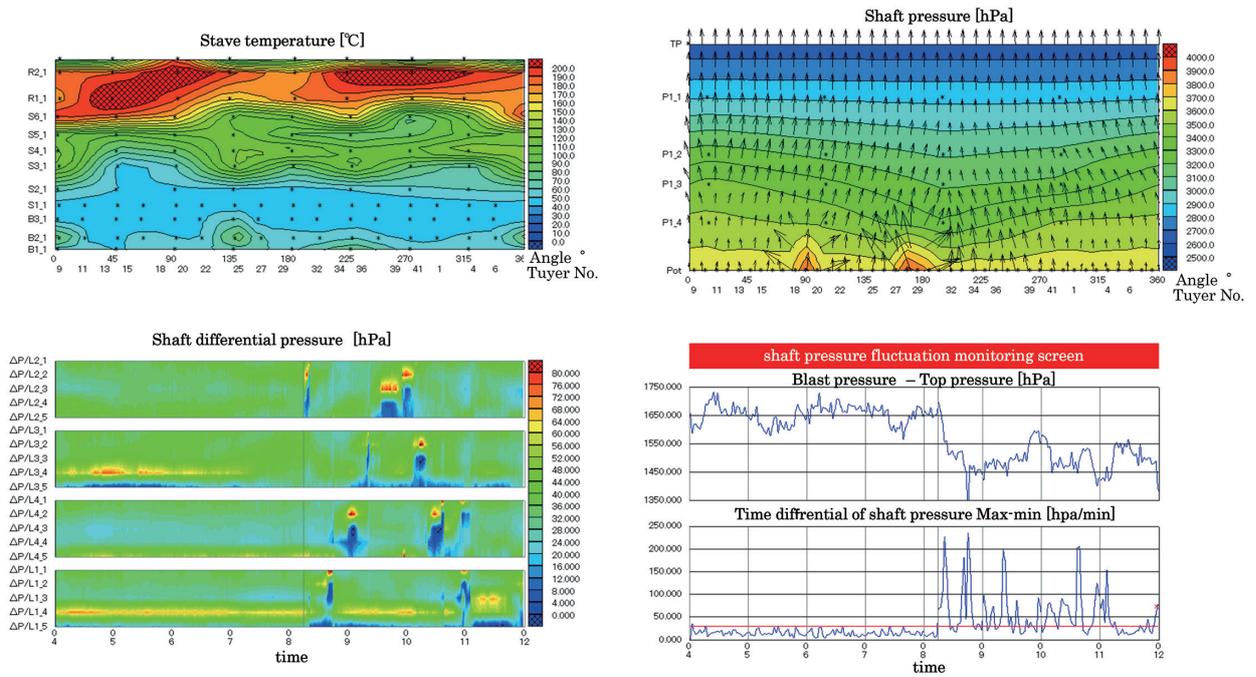


図5 シャフト圧力変動監視画面例
Example of shaft pressure fluctuation monitoring screen

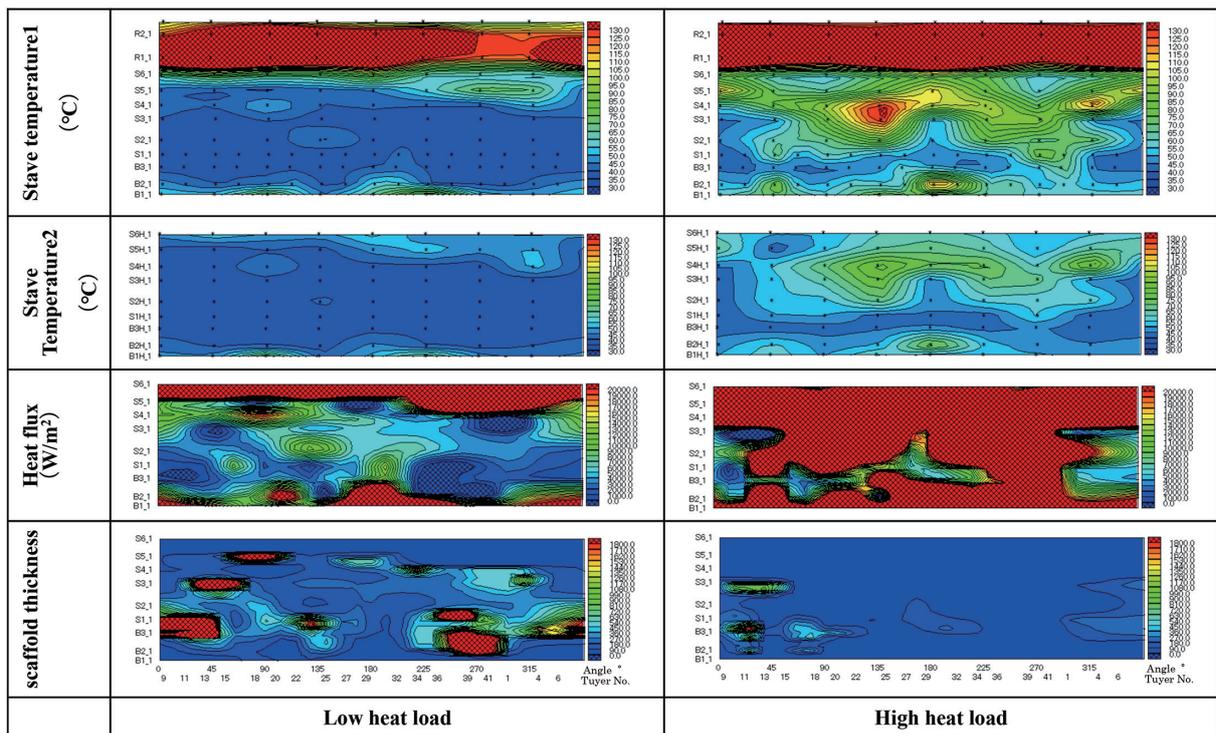


図6 ステープ温度、熱流束、付着物厚みの描画例
Drawing example of stave temperature, heat flux, and scaffold thickness

2.4 ステープ温度時間変化率の活用—融着帯推定

融着帯の推定方法は過去に様々な報告されているが^{12,13)}、本報ではステープ温度の時間変化率から融着帯根レベルの推定を試みた。融着帯の根位置は、シャフト圧力の空間変化率すなわち差圧からも推定可能であるが、たとえばボッシュ部など、融着帯の根が存在すると想定される領域では、根部に存在する半溶融のスラグ等によるシャフト圧力

計のガスの採取孔が詰まる等の問題で設置点数が少ないため、高炉下部にも測定点の多いステープ温度による推定方法を検討した。

(1) 融着帯推定方法

ステープ温度による融着帯根位置の推定は次のように行った。すなわち融着帯ではガスの通気抵抗が大きく、その充填構造も炉円周方向で変動していると考えられるた

め、融着帯を通過するガスは必ずしも安定的なプラグフローにならず、部分的にはガス流の方向や量が変動し、いわゆるガス抜けが頻繁に生じる可能性があると考えられる。この結果、融着帯の根部に相当する位置では根部の生成状況によって、局所的、短時間的にステープ温度が変化すると考えられ、実際にそのような現象が生じていることが確認できる。

したがって、ステープ温度の単位時間あたりの温度変化量が大きい領域を可視化画像上で選択してゆけば融着帯根部位置に相当する領域が推定できると仮定した(図7)¹⁴⁾。ただし本推定方法は、融着帯根部周辺での小規模なガス変動を仮定して融着帯根部の検知手段として用いており、実

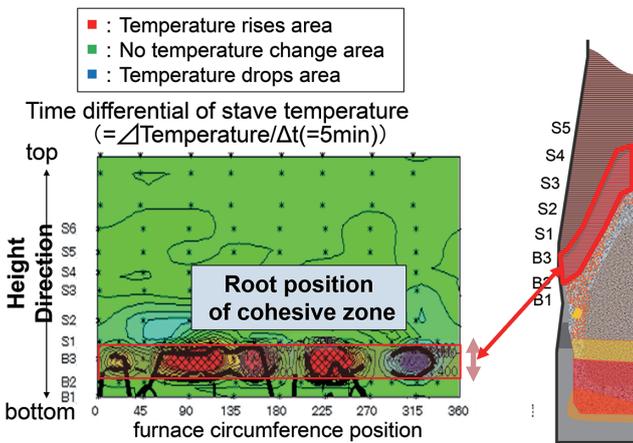


図7 融着帯根位置推定方法の概念図

Conceptual view of the estimation method of root position of cohesive zone

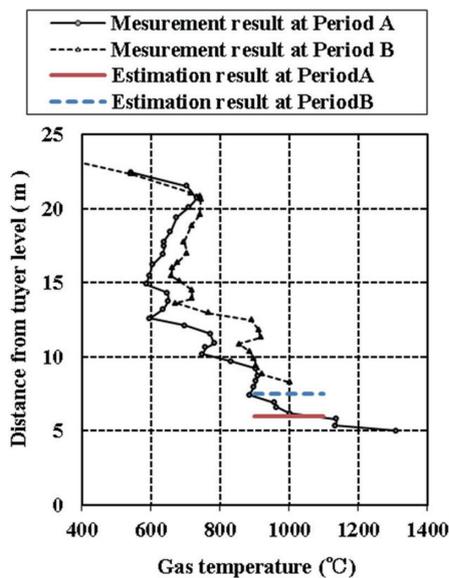


図8 炉壁部ガス温度の垂直ゾンデによる測定結果と、ステープ温度時間変化による融着帯根位置の推定結果の比較

Comparison of measurement results of furnace wall gas temperature by vertical sonde and estimation results of root position of cohesive zone by time differential of stove temperature

際にこのような現象が生じないときには推定ができない。また、融着帯根部の局所の変動の起因以外の大規模な吹き抜けが生じた場合にはそちらが検知されることになるため、この方法は適用できない。

(2) 推定値と垂直ゾンデによる実測値との比較

実高炉での炉壁部での垂直ゾンデの測定結果とステープ温度の変化率から求めた炉壁部での融着帯レベルの比較例を図8に示す¹⁵⁾。ステープ温度の変化率から求めた融着帯レベルは、期間Aで約7.5m、期間Bは約6mであった。ステープ温度からは炉内の温度レベルの推定はできないので高さレベルのみ示した。垂直ゾンデの測定結果と比較すると、期間A、期間B共に1000℃レベルの位置とほぼ一致しており、その変化と合わせて、融着帯上面レベルと対応していることが示唆される。

3. 操業データを用いた高炉操業推定モデル

将来の高炉の操業状態を推定し、取るべき操業アクションを決定する場合に、現在の操業状態と似た過去の操業状態を探して、その過去の時点で選択したアクションとその後の推移を参考にすることは日常的に行われている。この現在の操業状態と似た過去の操業状態の検索は、通常は経験や記憶に基づいて行われているが、経験の有無だけでなく、見落としや見間違いが生じる可能性がある。したがって、現在の操業状態と似た過去の操業状態の検索(過去類似例検索)を自動的に行い、過去のデータを有効に活用することを検討した。この過去類似例検索の自動化と過去類似例検索結果を用いた将来予測について“Just-In-Timeモデリング”¹⁶⁾と呼ばれるモデリング手法の適用を検討した¹⁷⁾。

3.1 過去類似例検索の自動化と将来予測の方法

過去類似例検索の自動化と将来予測モデリングの考え方は以下の通りである(図9)。①高炉操業のデータベースから予測したい変数に寄与する変数を選択し、②選択された変数を量子化し、③検索用データベースを作成する。④“要求点”の“近傍”データを量子化された検索用データベース上で量子単位での検索を行う。さらに、⑤検索した

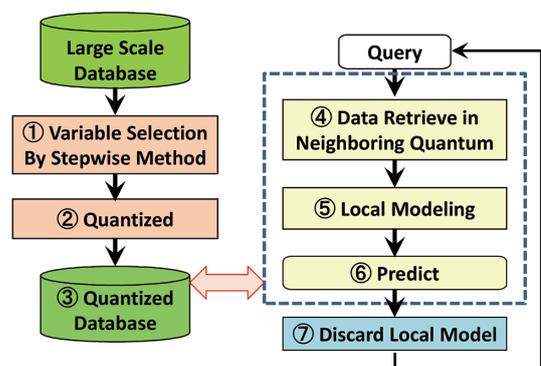


図9 LOMの考え方
Concept diagram of LOM

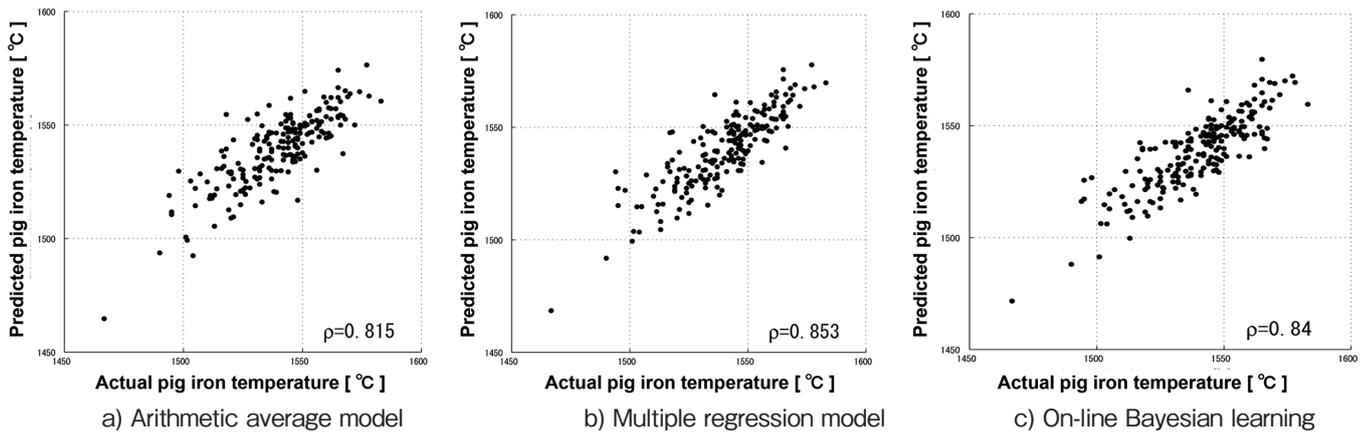


図 10 異なる局所モデルによる 1 時間後の溶銑温度推定結果の比較
Comparison of hot metal temperature estimation results after 1 hour by different local models

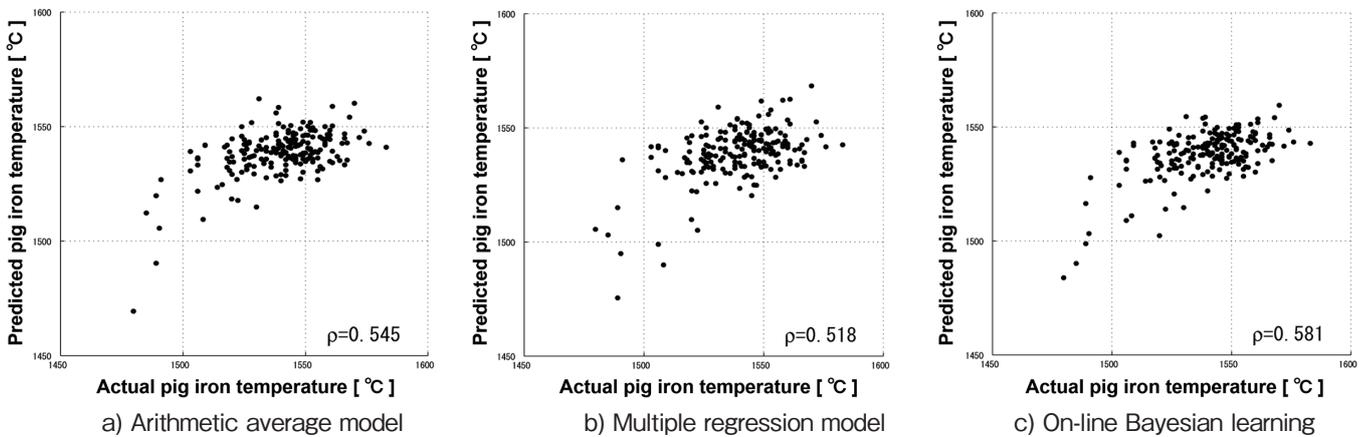


図 11 異なる局所モデルによる 6 時間後の溶銑温度推定結果の比較¹⁹⁾
Comparison of hot metal temperature estimation results after 6 hours by different local models¹⁹⁾

近傍データの出力を補間する局所モデルを作成し、⑥“要求点”の出力を推定する。このとき、⑦局所モデルは要求点が変わるたびに作り直すことにより、予測すべき変数や対象システムの経時的な特性変化に対応する。この手法を“大規模データベースオンラインモデリング (LOM: Large scale database Online Modeling)”と称する。

(1) 局所モデルによる予測精度の比較

LOM では、要求点を与えられたとき、要求点の近傍データセットを基に局所モデルを構築し、作成した局所モデルを用いて予測値を得る。局所モデルとして当初は近傍データの単純な平均値を用いる平均値モデルを用いていたが、モデルの予測精度を高めるため、局所重回帰モデルとオンラインベイズ学習モデルの開発を行い、その予測精度を比較検討した。局所重回帰モデルは要求点の近傍データセットに対して重回帰解析を行い、得られた回帰係数を基に線形予測モデルを構築するモデルである。オンラインベイズ学習モデルは、非線形関数を仮定しそのパラメータをベイズ統計で決定するモデルである^{18, 19)}。

図 10、図 11 に溶銑温度の実績値と、3 種類の局所モデル予測結果の比較を示す。これから、いずれのモデルも 1 時間後については予測精度が比較的高いが、6 時間後にな

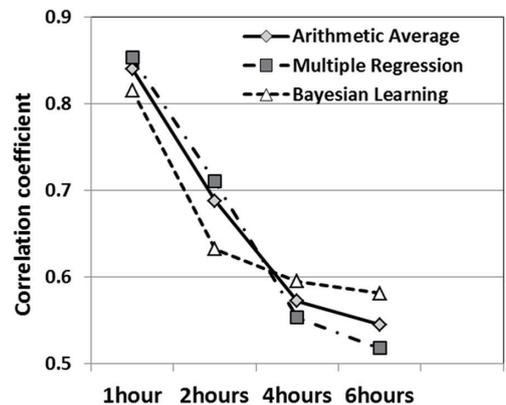


図 12 実績時と予測値の相関係数の比較
Comparison of correlation coefficient between actual data and predicted data

るとその予測精度は大幅に低下することがわかる。

図 12 に、1 時間後、2 時間後、4 時間後、6 時間後の局所モデルの予測値と実績値との相関係数の関係を示す。1 時間後、2 時間後では平均値モデル、局所重回帰モデル、オンラインベイズ学習モデルの相関係数はあまり変わらず非線形を考慮したオンラインベイズ学習モデルがむしろ最も低い値となっている。しかしながら、4 時間後、6 時間後

の予測結果では、平均値モデルの相関係数は大きく低下し、非線形性を考慮したオンラインバイズ学習モデルの方が低下の度合いが低く、相対的に予測精度の改善が見られた。これから、1時間や2時間程度の短期の予測の場合は単純な平均値モデルや線形性を仮定した局所重回帰モデルでもよいが、4時間以上の長期の予測を行う場合には非線形性を考慮したモデルが必要となることが示唆された。

(2) 独立成分分析結果の併用

高炉に設置されたセンサデータのうち、シャフト圧力センサやステープ温度センサは数十～数百点と比較的数多く設置されている。しかしながら、数は多いもののセンサの設置位置次第では、相互に強い関連を持って変動することが生じるため、すべてのセンサデータを独立な変数として扱うことは問題がある。したがって、各々のセンサデータから特徴となる変数を抽出しその変数を新たなパラメータとして与えてLOMを行うことを検討した。具体的には高炉2次元可視化システムの可視化画像から特徴量を抽出し、元のデータではなくその特徴量をあらためてLOMのデータとして用いることにより、データの次元を減らして計算負荷を軽減するだけでなく、予測精度の改善の可能性を行った。

2次元可視化画像の特徴量を抽出する手法としては、独立成分分析(ICA: Independent Component Analysis)を用いた^{20, 21)}。ICAは、多次元データから統計的に独立な成分を抽出し、抽出した独立成分を評価することで多次元データの特徴を定量的に評価する技術である。

ステープ温度の可視化画像に独立成分分析を適用して独立成分を抽出し、その独立成分をデータとしてLOMを適用し、高炉の熱負荷を予測した結果と、元のデータをそのまま用いた場合との予測結果を比較した例を示す。元のデータを用いて高炉の熱負荷の1時間後の実績値と予測値との比較をした場合の相関係数は0.699であったが、独立成分分析結果を適用した場合の相関係数は0.778となり、独立成分を適用し特徴的な成分を取り出しモデルのデータとして用いることにより、予測精度の向上が期待できることがわかる²²⁾。

3.2 機械学習を活用した推定モデル²³⁾

溶銑温度を予測するための方法として、前節では過去類似例を検出し、過去類似例の基で局所モデルを構築する方法を開発した。しかしながら、高炉操業の状況によってはモデルを構築するのに十分な類似例が存在しないこともある。本節では、選択されたすべての期間の操業データを用いて予測モデルを構築する手法について述べる。

モデル化の手法としては、Partial Least Squares (PLS)、決定木 (Decision Trees)、Random Forest、Ensemble Pattern Trees を用いて検討した。

PLSは重回帰分析と主成分分析の中間的な性質を持つ分

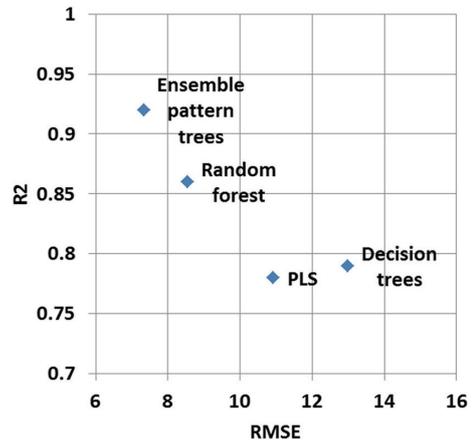


図13 予測結果のRMSEとR²の関係
Relationship between RMSE of predicted results and R²

析手法で、入力変数をそのまま用いるのではなく、出力変数と潜在変数との内積が最大となるように、入力変数の線形結合として決定した潜在変数を用いる分析手法である。

Ensemble Pattern Treesは、ロバストな非線形モデル構築手法であり、バギングを利用して多数のパターンツリー・モデルを1つの予測モデルに集約する手法である。データの変動やノイズに対して、1つのパターンツリーで高い精度を実現することは容易でないが、Ensemble Pattern Treesによってこの課題を解決することができる。

以上の解析方法を用いて高炉の溶銑温度を予測した結果を図13に示した。図13は予測結果の平均二乗誤差(RMSE: Root Mean Square Error)と決定係数R²の関係を示した図である。

これから、PLSとDecision Treesの予測精度があまり良くないことがわかる。Random Forestは比較的良く、Ensemble Pattern Treesはさらに高い予測精度を示した。

ただ、各モデルのパラメータの調整にまだ最適化の余地があり、また解析手法によっては、さらに大量のデータを用いて解析することにより、モデルの改善を図ることができる可能性がある。

3.3 高炉操業状態の可視化と予測²⁴⁾

高炉操業にとって、操業の安定維持は極めて重要な課題であるが、炉内反応の複雑さ、あるいは炉頂から装入された原料が出銑口から出銑されるまでに約8時間と時間がかかるため、操業状態とその変化を把握することは難しい。そのため、まず高炉の操業状態を直観的に把握するために、多次元の高炉操業データを低次元化することにより操業状態の可視化を試み、さらに可視化結果から進路予想法を用いて操業状態の予測を試みた。

可視化・低次元化手法は数多く提案されているが、ここではCbLW-PLS (Covariance-based Locally Weighted Partial Least Squares)を用いた。CbLW-PLSはJust-In-Time型モデリングの一種であるLW-PLSにおいて、入出力間の共分散

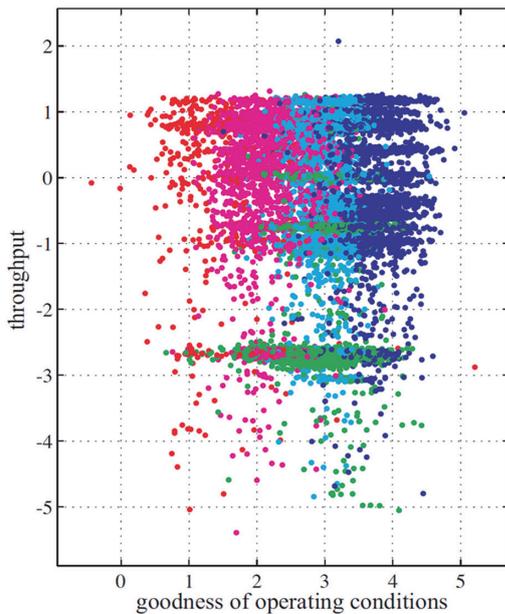


図 14 CbLW-PLS による高炉操業状態可視化結果²⁴⁾
Visualization of blast furnace operation status by CbLW-PLS²⁴⁾

に基づく重み付きユークリッド距離でサンプルの類似度を評価する手法である²⁵⁾。データの可視化は、多次元の操業データから派生して得られる高次元の状態を、“非常に良い”, “良い”, “悪い”, “非常に悪い”という4種類の操業状態に分類可視化することで実現した。

高炉操業状態を2次元平面に可視化した結果を図14に示す。横軸は操業状態の良し悪しを示し、縦軸は生産量を示す指標とした。各々のプロットの色は、操業者の判定結果を示し、濃青は非常に良い、薄青は良い、薄赤は悪い、濃赤は非常に悪い、を表している。緑は状態の良し悪しとは関係なく生産量の低い状態を表す。このように、多次元のデータに基づく操業状態の良し悪しが、CbLW-PLSを用いて多次元データを1次元に低次元化した結果として表現できることがわかる。

操業状態の予測と可視化は進路予想法(Track-forecast法)で行った。進路予想法は以下のとおりである。過去のデータに基づき、対象データの一定時間経過後の位置を円で表す。低次元化された2次元空間において現時点での近傍サンプルを抽出し、各サンプルの一定時間経過後のサンプルをデータベースより取得する。予想円の中心は、これらのサンプルデータの円の中心の座標を加重平均で計算し、円の半径は、経過時間ごとに先に得られた中心とサンプルデータのユークリッド距離を計算し、一定の割合を含むような距離から定義する。

データベース内の近傍サンプルの変化を利用して操業状態の変化を予測した結果を図15に示す。黄丸は現時刻の操業状態、橙丸と橙円は2, 4, 8時間後の操業状態予測結果と70%信頼区間、黄四角は実際の操業状態の変遷を表す。5963サンプルを用いて検証した結果、70%以上の精

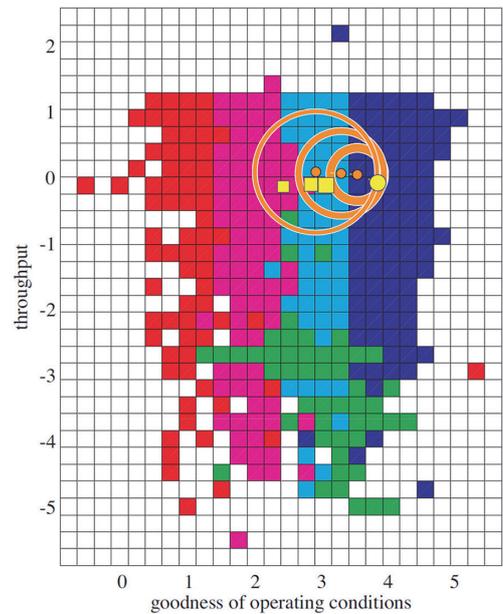


図 15 進路予想法による操業状態の予測結果²⁴⁾
Evaluation result operation status by track-forecast method²⁴⁾

度で操業状態の悪化または改善を正しく予測することができた。

4. まとめ

主として、ステープ温度やシャフト圧力のデータを用いて、高炉、特に炉壁部での操業状態の可視化を行った。ステープ温度やシャフト圧力など多数のセンサデータを2次元的に画像化することにより、シャフト圧力変動やスリップ発生に伴う炉内の空間的な変動を客観的に可視化することが可能になった。データの空間変化率、時間変化率などと操業データの推移を組み合わせることにより、シャフト圧力変動等の早期検出が可能となる。また、データの時間変化率、空間変化率などを用いて、融着帯根位置の推定やシャフト圧変動のアラームの発信なども行っている。ステープ温度データから熱流束や付着物分布なども求めることができる。さらに、可視化画像を3次元化することにより、炉内状況をイメージすることがより容易となり、シャフト・炉床部の温度及び圧力以外の監視データも単一画面で監視可能であり、異常現象の兆候見逃しによるアクション遅れなどを回避し、操業の最適化、迅速化を図ることができた。

高炉操業データの解析については、LOMや機械学習を用いて溶銑温度等の予測モデルの開発を行った。LOMについては、高炉データの過去類似例の検索と将来予測を試み、将来予測モデルとしても可能性の高いことを確認した。また局所モデルを改善することや、可視化画像から独立成分分析を用いて特徴量を抽出し、LOMに変数として取り込むことにより、さらに予測精度の向上が図れることを確認した。機械学習についても操業データ全体を用いた予測モデルを作成し、その予測精度を確認した。

また, 多次元の高炉操業データを CbLW-PLS を用いて低次元に可視化し, さらに進路予想法を用いて, 操業状態の予測が可能であることを示した。

参考文献

- 1) 日本鉄鋼協会編：鉄鋼便覧 第1巻製鉄・製鋼. 第5版. 東京, 日本鉄鋼協会, 2014, p.158
- 2) 芦村敏克 ほか：鉄と鋼. 80 (6), 457 (1994)
- 3) 伊藤雅浩 ほか：CAMP-ISIJ. 15, 927 (2002)
- 4) 松崎眞六 ほか：CAMP-ISIJ. 15, 928 (2002)
- 5) 伊藤雅浩 ほか：CAMP-ISIJ. 16, 300 (2003)
- 6) 伊藤雅浩 ほか：新日鉄技報. (379), 33 (2003)
- 7) 松崎眞六 ほか：新日鉄技報. (384), 89 (2006)
- 8) 伊藤雅浩 ほか：CAMP-ISIJ. 19 (2), 302 (2006)
- 9) Matsuzaki, S. et al.: ISIJ Int. 45 (10), 1452 (2005)
- 10) Kamata, M. et al.: ISIJ Int. 55 (6), 1327 (2015)
- 11) 伊藤雅浩 ほか：CAMP-ISIJ. 19, 302 (2006)
- 12) 入田 ほか：鉄と鋼. 68, S107 (1982)
- 13) 加瀬 ほか：鉄と鋼. 66, 1928 (1980)
- 14) 伊藤雅浩 ほか：CAMP-ISIJ. 16, 1109 (2003)
- 15) Matsuzaki, S. et al.: ISIJ Int. 45 (7), 1453 (2005)
- 16) Zheng, Q. et al.: Trans. Soc. Instrum. Control Eng. 37, 640 (2001)
- 17) 伊藤雅浩 ほか：鉄と鋼. 90, 917 (2004)
- 18) Kaneko, N. et al.: Proc. of Int., Conf. on Control, Automation and Systems 2008. ICROS, Seoul, 2008, p.2240
- 19) Kaneko, N. et al.: ISIJ Int. 7, 939 (2010)
- 20) 伊藤雅浩 ほか：CAMP-ISIJ. 18, 1141 (2005)
- 21) Hyvarinen, A.: IEEE Transactions on Neural Networks. 10, 626 (1999)
- 22) Hijikata, Y. et al.: Proceedings of SICE-ICASE International Joint Conference 2006. Oct.18-21, 2006, p.4112
- 23) Xinmin, Z. et al.: Computers and Chemical Engineering. 121, 442 (2019)
- 24) Hazama, K. et al.: 化学工学会第47回秋季大会. (2015)
- 25) Hazama, K. et al.: Intell. Lab. Syst., 146, 55 (2015)



松崎眞六 Shinroku MATSUZAKI
プロセス研究所 製鉄研究部
主幹研究員 博士(工学)
千葉県富津市新富20-1 〒293-8511



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



伊藤雅浩 Masahiro ITO
設備・保全技術センター
システム制御技術部 システム制御技術室
主幹