

大規模データベースオンラインモデリングの 逐次予測システムの構築と工業炉プロセスへの応用

小川 雅俊*・葉 怡君*・
大貝 晴俊*・立野 繁之*・内田 健康**

Development of sequential prediction system for Large scale database-based Online Modeling and its application to industrial furnace

Masatoshi OGAWA*, Yichun YEH*,
Harutoshi OGAI*, Shigeyuki TATENO*, Kenko UCHIDA**

Abstract: Recently, with the development of computing machines and database systems, it becomes possible to accumulate and retrieve a large amount of data at very high speed. Attention has been drawn by the local modeling techniques of a new idea called “Just-In-Time (JIT) modeling” or “Lazy Learning”. To apply “JIT modeling” to a large amount of database online, “Large-scale database-based Online Modeling (LOM)” has been proposed. LOM is such a technique that makes the retrieval of “neighboring” data more efficient by using “stepwise method” and quantization. This paper reports a sequential prediction system of LOM. The sequential prediction system is able to predict process variables over a long period, the approach is to repeat a process that predicts the process variables of the next step by using both the predicted process variables of the previous step and prepared manipulated variables. Furthermore, to improve the prediction accuracy, a similarity criterion considering the contribution of a variable to the predicted variable is proposed. The system is applied to a dynamic intertwined industrial furnace with a number of physical phenomena; practical effectiveness of the system is verified. As a result, the system has predicted the process variables with satisfactory accuracy. The practical effectiveness has been confirmed.

Key Words: LOM, JIT modeling, dynamic modeling, database, industrial furnace process, sequential prediction

1. 緒言

近年の計算機ハードウェアやデータベースシステム技術の発展に伴い、大量データの蓄積と高速検索が可能になったことなどを背景に、“Just-In-Time (以後、JITと略す)モデリング”^{1), 2)}や“Lazy Learning”³⁾、“Model-on-Demand”⁴⁾と呼ばれる新しい考え方の局所モデリング手法が注目されている。

これらは、観測したデータをそのままデータベースに蓄積しておき、システムの予測などの必要が生じたときに、入力である“要求点(Query)”と関連性の高いデータをデータベースから近傍データとして検索し、検索したデータの出力を補間する局所モデルを構成して、“要求点”の出力を得るモデリング手法である。観測データの更なる蓄積があるたびに既存の局所モデルを廃棄し、再び新たな局所モデルを構築し、対応していく点に特徴を有する。

また、実プロセスの大規模なデータベースに JIT モデリングをオンラインで適用するにあたり、ステップワイズ法による相空間の低次元化と、低次元化した相空間の量子化による近傍検索の効率化と計算負荷の大幅な低減を図った手法として大規模データベースオン

ラインモデリング⁵⁾⁻⁸⁾ (Large-scale database-based Online Modeling, 以後、LOMと略す。)が提案されている。

しかしながら、通常、LOMによってプロセスの予測をしようとした場合、LOMはプロセスの将来の操作変数による影響を考慮しておらず、一般的な操作が施されたときのプロセス値の予測が行われる。そのため、将来の操作量の影響が大きく反映されるほどの長期的な将来予測は一般的に困難である。長期的な将来予測を実用上十分な予測精度で予測するには、将来の操作変数の影響を考慮した予測手法を実現することが課題となる。

そこで、本研究では、LOMではまだ報告されていない、最初に一度だけ必要な現在のプロセスの情報をすべてLOMに与え、1ステップ先の予測をLOMで行い、その後は得られた予測値と設定した操作量だけを利用して1ステップ先の予測処理を繰り返すことによって、プロセスの操作変数の影響を考慮し、プロセスの数時間後の長期の将来予測を行なう逐次予測システムを構築する。本システムは、事前に将来の数時間先の操業パターンが設定されている場合に、操業パターンの影響を反映したプロセス挙動を予測し、評価できる。また、適用対象プロセスの一例として、入力される熱量変動が大きく炉内物理現象が複雑な工業炉プロセスを取り上げ、システムの有効性を検証した。

さらに予測変数に対するプロセス変数の寄与率を考慮した相似度を提案することによって、炉内のプロセス変数の予測精度向上を図った。

* 早稲田大学大学院情報生産システム研究科 福岡県北九州市若松区ひびきの 2-7

** 早稲田大学理工学部 東京都新宿区大久保 3-4-1

* Graduate School of Information, Production and Systems engineering, Waseda University

** Waseda University Science and Engineering

(Received December 10, 2007)

その結果、工業炉プロセスの炉内温度の予測値と実測値の挙動が類似した結果を示し、LOM で得られた予測値を利用して逐次予測することによってプロセスの予測が可能であることを確認した。

工業炉プロセスは反応時間の異なる多くの化学反応、物理反応からなっており、各プロセス値はそれらの反応の結果であることから、その時間的な挙動は異なる周波数成分をもったデータの合成となっている。プラントの操業にあたっては、秒単位や分単位の短い時間スケールのプロセス挙動のみならず、時単位あるいは日単位の比較的長い時間スケールのプロセス挙動の安定化も重要である。

LOM を用いて、将来の工業炉のプロセス変動を予測し、その炉況に応じた望ましい操業条件を探索、設定していくことによって、更なる合理的な操業が可能となる。

また、比較的長い時間スケールのプロセス状態を予測しようとした場合、予測をしようとしている時間スケールに比して非常に短い周期のプロセス値の変化が予測精度に悪影響を及ぼし、実用上十分な予測精度が得られないことがある。以後、このような予測しようとしている時間スケールに比して非常に短い周期で変動するプロセス値の成分をノイズと呼ぶことにする。

以下、本論文の構成を述べる。2 章では本システムの基盤となる大規模データベースオンラインモデリングについて述べ、3 章では、構築した LOM ベースの逐次予測システムと提案する寄与率を考慮した相似度について述べる。4 章では工業炉プロセスへの応用を説明し、本システムの有効性を検証する。最後に 5 章で本論文の結論を述べる。

2. 大規模データベースオンラインモデリング (LOM: Large scale database-based Online Modeling)⁵⁾⁻⁹⁾

まず、大規模オンラインデータベースモデリングの基本的な概念となる JIT モデリングを概説する。

2.1 Just-In-Time モデリング^{1), 2)}

対象とするシステムは非線形かつ動的なシステムであり、次式で表される回帰モデル式で与えられる。

$$y(t+p) = f\{y(t), y(t-1), \dots, y(t-n_y), u(t-d), u(t-d-1), \dots, u(t-d-n_u)\} \quad (1)$$

ここで、

- $u(t)$: 時刻 t におけるシステムの制御入力ベクトル
- $y(t)$: 時刻 t におけるシステムの観測出力ベクトル
- n_u : 制御入力ベクトルの次数
- n_y : 観測入力ベクトルの次数

- p : 予測時間
- d : むだ時間
- f : 未知の非線形関数

である。このとき、システムの入力ベクトル x^k と出力ベクトル y^k を(2)式、(3)式のように再定義すると、

$$y^k = y(k+p) \quad (2)$$

$$x^k = \{y(k), y(k-1), \dots, y(k-n_y), u(k-d), u(k-d-1), \dots, u(k-d-n_u)\} \quad (3)$$

時間推移に伴い入力ベクトル x^k と出力ベクトル y^k のデータセットが $(x^1, y^1), (x^2, y^2), \dots$ のように対象システムから大量に取得され、データ集合 $\{(x^k, y^k)\}$, ($k=1, 2, \dots$) としてデータベースに蓄積される。 k は離散化時間である。このとき JIT モデリングは、予測や制御の要求のたびに蓄積されている $\{(x^k, y^k)\}$ から非線形関数 f^k を求めることに相当する。

たとえば、時刻 t において、システムの予測が必要となったとき、現在のシステムの状態 $\{(x^{k_q}, y^{k_q})\}$ は要求点 (Query) と呼ばれ、この要求点に類似した近傍データセット $\{(x^{k_i}, y^{k_i})\}$ ($k_i < k_q$) を過去の観測データ集合から選び出す。複数の近傍データセットが得られたときは、これらのデータセットの出力を補間する局所モデルを構成し、その局所モデルを用いてシステムの出力 y^{k_i} を予測する。その後、その局所モデルを廃棄し、次の予測では新たにデータが更新された観測データ集合から近傍データセットを選び出し、予測を行なう。

2.2 LOM

JIT モデリングは、データベースから類似データを検索するためにすべてのデータ対に対して距離を測り、順序付けるプロセスを、予測を行なう都度実行しなければならない。これはデータベースが大規模になった場合、計算負荷が増大してしまうという問題が生じる。

そこで、LOM では、JIT モデリングを大規模なデータベースに適用するにあたり、ステップワイズ法による相空間の低次元化と、低次元化した相空間の量子化による近傍検索の効率化を行い、計算負荷の大幅な低減を図っている。ステップワイズ法というのは、回帰式モデルにおいて、できるだけ入力変数を少なくし、かつ観測値と予測値の差の平方和が実用に耐えうるほど小さいものとするために、ある検定基準を設けて入力変数の追加と削除を行なう方法である。LOM の概略図を Fig.1 に示す。

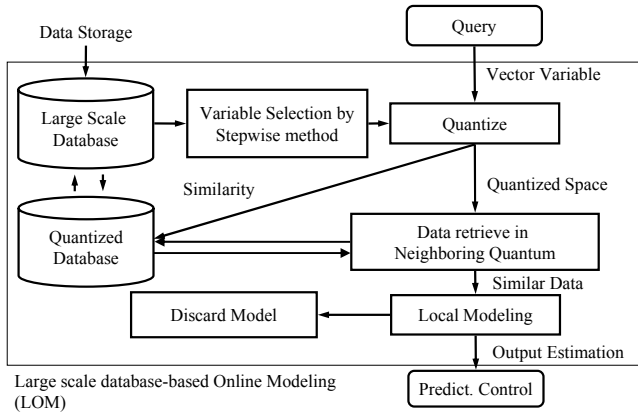


Fig. 1 Schematic diagram of LOM

2.3 相空間の量子化と近傍検索

まず、入力変数ベクトル x^k の値域である入力空間を量子化し、量子空間 X^k を次式のように定義することで入力変数 x^k の分類を行なう。

$$X^k = Z(x^k), (i=1,2,\dots,n) \quad (4)$$

ここで、 $Z(\cdot)$ は量子化演算子、 n は同一量子空間 X^k に属するデータの数とする。

続いて、量子空間 X^{k_i} と X^{k_j} との相似度 $S(k_i, k_j)$ を

$$S(k_i, k_j) = \|X^{k_i} - X^{k_j}\|_\infty \quad (5)$$

と定義する。ただし、 $\|\cdot\|_\infty$ は ∞ ノルムである。このとき、要求点ベクトル x^{k_q} を含む量子空間を X^{k_q} とし、要求点ベクトル x^{k_q} の近傍空間を

$$\Omega_q = \{X^{k_p} \mid S(k_q, k_p) = \min_{X^{k_p} \in T} S(k_q, k_p)\} \quad (6)$$

と定義する。ここで、 T は相空間を表す。

相空間の量子化幅の決定方法はいくつかの方法が考えられる。ここでは、最も単純な一様均等分割法を用いる。

2.4 局所モデル

JITモデリングにおける代表的な局所モデルには重み付き線形平均法 (LWA) や重み付き局所回帰法 (LWR) などが提案されているが、ここでは最も単純な相加平均法を紹介する。

すなわち、要求点ベクトル x^{k_q} に対する出力の推定値ベクトル y^{k_q} を

$$\hat{y}^{k_q} = F(X^{k_q}) = \frac{1}{M} \sum_{y^k; (x^k, y^k) \in \Omega_q} y^k \quad (7)$$

で算出する。ただし、 M は近傍空間 Ω_q に属する出力ベクトル y^k の個数である。

3. LOM による逐次予測システム

3.1. LOMによる逐次予測方法

逐次予測は過去に得られた予測値を利用して、更につぎの状態予測を行なう処理を繰り返し、予測を行なう方法であり、制御入力ベクトル以外のすべての入力変数の予測が必要となる。逐次予測方法の概略図を Fig.2 に、その手順を以下に示す。

- 1) 現在の制御入力ベクトル $u(t)$ と観測入力ベクトル $y(t)$ から構成される要求点データ x^t を LOM に与え、良好に予測可能な短期間の 1 ステップ先の $y(t+1)$ を予測する。
- 2) $u(t+1)$ は予め任意の値を与える。更に $u(t+1)$ と $y(t+1)$ からなる x^{t+1} を LOM に与え $y(t+2)$ を予測する。
- 3) 時間 t を更新して、2) の処理を予測処理の終了まで繰り返す。




Fig. 2 Outline of sequential prediction

3.2. LOMによる逐次予測システム

LOM による逐次予測システムの処理フローを Fig.3 に示し、その処理手順を以下に示す。観測データの追加更新がなされた場合の処理を(1)から(4)に示す。

- (1) 予め大規模なデータベースにプロセスから得られる観測データを蓄積する。
- (2) 大規模データベースから設定したサンプリング周期に応じてデータを取得する。ここで、フィルタリングによるデータのノイズ除去を施す。
- (3) 変数ごとに時間を遅らせた変数を生成し、ステップワイズ法によって予測変数に対して寄与率の高い変数群に絞り込む。
- (4) 絞り込まれた変数を自動的にデータベースに格納する。

予測の要求の都度行われる処理を 1.から 9.に示す。8.で計算終了判定を行い、その後、計算終了まで 9.と 4.から 8.までの処理を順に繰り返す。

1. 要求点データと予測設定情報を取得する.
2. データベースより観測データを取得する.
3. 観測データの正規化と量子化を行なう.
4. 要求点データの正規化と量子化を行なう.
5. 量子単位での要求点の近傍データを検索し, 予め設定した数だけ近傍データを取得する.
6. 得られた複数の近傍データから局所モデルを構成する. つまり, すべての観測入力ベクトルの予測値を生成する.
7. 予測の都度, 構成した局所モデルは廃棄される.
8. 計算終了の判定を行なう.
9. 観測入力ベクトルの予測値と設定した制御入力ベクトルから 1 ステップ先の要求点データを新たに生成する.

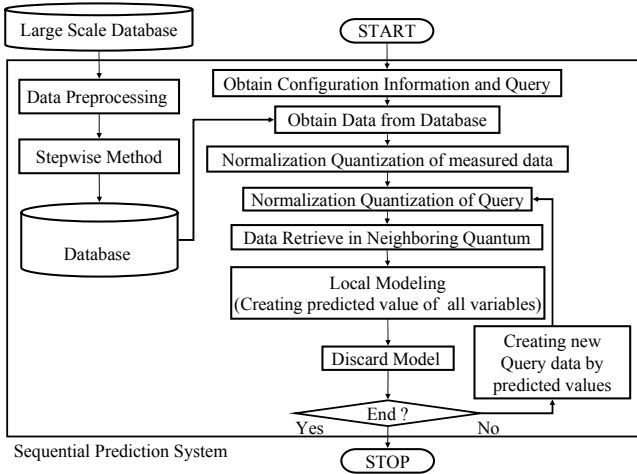


Fig. 3 Processing flow of Sequential Prediction System

3.3. 逐次予測における寄与率を考慮した相似度の提案

2.3節で紹介した(5)式の ∞ ノルムによる相似度では, 予測対象に対しての寄与率 (F値) の高い変数も低い変数も等価に扱われてしまう. そこで, 更なる予測精度向上を図るために, プロセス変数の個々の寄与率に応じて重み付けをすることによって, プロセス変数の寄与率の違いを考慮した相似度を提案する. ここで, 相似度は, 要求点ベクトルと近傍データベクトルとのベクトル間距離である.

要求点ベクトル x^{k_q} と近傍データベクトル x^{k_p} の相似度を

$$S(k_q, k_p) = \sum_{i=1}^N \sqrt{f_i} \cdot |x_i^{k_q} - x_i^{k_p}| \quad (8)$$

と定義する.

ここで,

$x_i^{k_q}$: 要求点ベクトルの第 i 成分,

$x_i^{k_p}$: 近傍データベクトルの第 i 成分

f_i : 第 i 成分の寄与率

N : ベクトル成分数

である.

これは, 要求点ベクトルの第 i 成分と近傍データベクトルの第 i 成分間の距離に個々のプロセス変数の寄与率 (F値) の平方根を重みとして乗ずることで, 個々の変数間の寄与率の違いを考慮した相似度を定義している. 観測データから相似度が小さい近傍データベクトルを伴うデータセットを順に要求点に対する過去の類似事例データとして採用し, その類似事例データに基づいて予測値を生成する.

3.4. 逐次予測に用いた局所モデル

局所モデルは, 相加平均法のように得られた近傍データをすべて等価に扱うのではなく, 要求点と近傍データ間の相似度に対応して, 予測値に対するその近傍データの影響度を調整し, 要求点に他の近傍データより近い近傍データは影響度を大きくし, 要求点からより離れている近傍データは影響度を小さくする重み付き線形平均法を用いた. 重み付き線形平均法は, 要求点から相似度が大きいデータも影響度の小さい近傍データとして採用することができ, より多くの近傍データを利用して予測値を構成できるため, 予測精度の向上に繋がると考えられる.

ここで, 重み付き線形平均法 (LWA) は, 要求点ベクトル x^{k_q} に対する出力の推定値ベクトル y^{k_q} を相似度 S に基づいて, 重み w を

$$w = \begin{cases} \left\{ 1 - \left(\frac{S - L_{Min}}{L_{Max} - L_{Min}} \right) \right\}^n & (d \leq L_{Max}) \\ 0 & (d > L_{Max}) \end{cases} \quad (9)$$

n : 重みの影響度 (大きいほど影響度が大きい)

L_{Max} : 過去データにおける距離の最大値

L_{Min} : 過去データにおける距離の最小値

S : 相似度

と定義して, 重み付き線形平均法により予測値 \hat{y}^{k_q} を

$$\hat{y}^{k_q} = \frac{\sum_{i=1}^m w_i y^{k_i}}{\sum_{i=1}^m w_i} \quad (10)$$

で算出する. ただし, M は近傍空間 Ω_q に属する出力ベクトル y^k の個数である.

4. LOMの逐次予測システムによる工業炉プロセスへの応用

LOMによる逐次予測システムを用いて、工業炉プロセスの炉内温度Aの予測事例を示す。

4.1 工業炉プロセスの予測条件と変数選択

対象データベースを工業炉プロセスの実操業データとし、サンプリング間隔1分による約2年分のデータを利用した。

プロセスの数分単位の細かい変動ではなく、数時間単位の大きな変動を捉えるために、プロセス値には4時間の移動平均処理を施し、20分周期でデータのサンプリングを行った。炉内温度Aの生データと移動平均法による平滑化を施した後のデータの比較図をFig.4に示す。ここで、本論文ではグラフの温度域を基準となる温度からの偏差で表示する。Fig.4において、平滑化を施した炉内温度Aは、数分単位の細かい周期変動が取り除かれ、数時間単位の大きな変動のみとなっていることが確認できる。




Fig. 4 The comparison diagram between the original data and the filtering data of moving average method

データの入力変数は、5時間まで遅れさせた変数を含む385変数のなかからステップワイズ法を用いて炉内温度Aに対する寄与率の高い47変数を選択した。選択した変数群の一部をTable.1に示す。1時間後の炉内温度Aに関連する変数として、現在、20分前の炉内温度A、80分前、140分前、100分前の炉内温度Bなどの47変数が選択された。

さらに、局所モデルの構成に利用する近傍データ数(過去事例データ)は一定の個数だけ取得されるようにし、今回のプロセスにおいては近傍データ数を30個としたときに高い予測精度が得られたため、近傍データを30個だけ取得し、(9)式と(10)式による重み付き線形平均法を用いて局所モデルを構成するようにしている。ここで、(9)式の重みの影響度は最も高い予測精度を得た $n=2$ に設定した。

Table 1 Selected variables for Temperature A after 1 hour by stepwise method

No.	Content	Delay	F value
1	Temperature A	Present	342027
2	Temperature A	before 20 minute	32018
3	Temperature B	before 80 minute	2630
4	Temperature B	before 140 minute	2964
5	Temperature B	before 100 minute	784
6	Temperature A	before 240 minute	737
7	Temperature A	before 180 minute	3262
8	Temperature A	before 260 minute	3314
9	Temperature B	Present	313
10	Temperature B	before 300 minute	254
...
47	Controlled variable C	before 120 minute	24

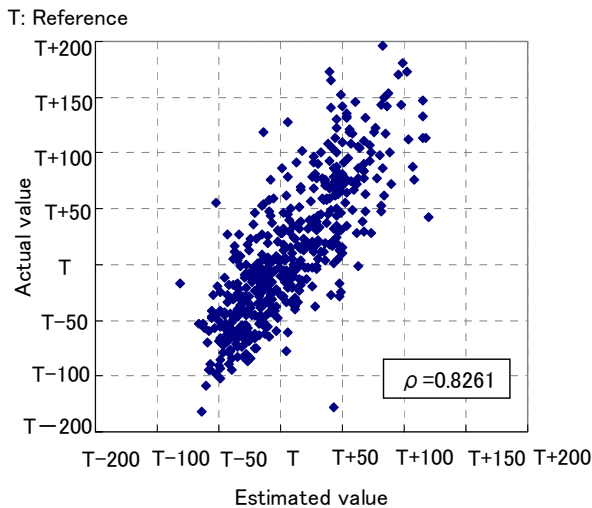
4.2 工業炉プロセス応用のための予測精度の評価

1時間後の予測結果を利用して更に先の1時間後を予測する処理を繰り返すことで逐次的に予測を実施することを考えたとき、1時間後の予測が十分な精度で行わなければ逐次予測を実現することはできない。そこで、逐次予測が可能であるかを判断するために、工業炉プロセスの実操業データを用いて、1時間後の予測精度の検証を行った。要求点を無作為に選択し、炉内温度Aの1時間後の予測を500回行い、実測値と予測値の相関を調べた。


初めに、(5)式の ∞ ノルムによる相似度を用いたLOMによる1時間後の予測結果による実測値と予測値の散布図をFig.5(a)に示す。このときの炉内温度Aの予測値と実測値の相関係数が0.8261となり1時間後に関して良好に予測できていることが確認でき、逐次予測が可能であると判断できる。さらに、(8)式の提案した寄与率を考慮した相似度を用いたLOMによる1時間後の予測結果による実測値と予測値の散布図をFig.5(b)に示す。このときの炉内温度Aの予測値と実測値の相関係数が0.9571となり、提案した個々のプロセス変数の寄与率の違いを考慮した相似度を用いることによって、 ∞ ノルムによる相似度を用いたときよりも高い予測精度を得ることができた。また、このとき実用上十分な処理時間で予測処理が実施できた。

4.3 工業炉プロセスへの逐次予測システムの応用

LOMによる逐次予測システムを用いて、要求点時刻から1時間後を予測し、その予測結果を利用してさらに1時間後を予測する処理を繰り返すという逐次予測を行った。このとき、初回の予測時のみステップワイズ法によって絞り込まれた47変数の実際のプロセス値を与え、要求点データを構成し、2回目以降は操作変数に関しては実際に実施された値を与え、操作変数以外の変数に関してはLOMで予測した値を与えることによって要求点データを構成し、予測を逐次的に行なう。



(a) Estimated result using similarity criterion of infinite norm



(b) Estimated result using similarity criterion based on F value

Fig. 5 Correlation between Actual and estimated data of furnace temperature 'A' after 1 hour by LOM

ここで、4.2節で高い予測精度が得られた、個々のプロセス変数の寄与率の違いを考慮した相似度を用いた。

例として、要求点 No.1 を選択し、1 時間後から 10 時間後までの炉内温度 A を予測したときの、通常の LOM による予測値、逐次予測システムによる予測値、実測値を Fig.6 に示す。通常の LOM では数時間後の長期の予測になると、十分なプロセスの変動を予測できていないことが確認できるのでに対して、逐次予測手法による予測値は実測値に近い傾向を捉えられていることが確認できる。このとき、1 時間後から 10 時間後まで、プロセスの操作量に関する変数以外は、真値の情報を与えておらず、数値シミュレータのように操作量の情報のみを新たに与えることで予測をすることができるシステムを実現した。

さらに、要求点 No.2 を選択し、同様に 1 時間後から

10 時間後までの炉内温度 A を予測したときの通常の LOM による予測値、逐次予測システムによる予測値、実測値を Fig.7 に示す。このように変動の激しい箇所では、通常の LOM では十分に予測が行なわれていないことが確認できる。それに対して、逐次予測手法では 8 時間後までの傾向を再現し、実測値と予測値の傾向が類似していることがわかる。

また、本予測を実用上十分な処理時間で行なうことができた。このように LOM による逐次予測システムを用いることによって、炉内温度 A の動的な傾向を示すことができ、オペレータなどに有益な情報を提供できることが示唆される。




Fig. 6 Actual and estimated data of Temperature A after 14 hours (Query No.1)




Fig. 7 Actual and estimated data of Temperature A after 14 hours (Query No.2)

5. 結言

本論文では LOM においてまだ報告されていない、LOM による過去の予測値を利用して逐次的に 1 ステップ先の予測処理を繰り返し、プロセスの将来の変動を予測する逐次予測システムを構築した。さらに予測変数に対するプロセス変数の寄与率を考慮した相似度を提案することによって、炉内のプロセス変数の予測精度向上を実現した。

本システムを工業炉プロセスの実データに適用し、システムの有効性を検証した結果、工業炉プロセスの

炉内温度の予測値と実測値の挙動が類似した結果を示し、予測が良好に行われることを確認した。また、実用上十分な処理速度で予測が可能であった。

現在の操業データと将来の操作量データがあれば、将来のプロセス変数の変動を予測することができ、数値シミュレータのように取り扱うことができる。そのため、工業炉プロセスなどにおいて、本システムを用いることにより、事前に将来の数時間先の複数の操業パターンを検討でき、オペレータや技術者などに有益な情報が提供できることが示唆される。

【参考文献】

- 1) Stenman, A., Gustafsson, F. and Ljung, L.: "Just In Time Models For Dynamical Systems", Proc. 35th Conf. Decision and Control, 1115/1120 (1996)
- 2) 牛田, 木村: "Just-In-Time モデリング技術を用いた非線形システムの同定と制御", 計測と制御, **44**, 2, 102/106 (2005)
- 3) Bontempi, G., Bersini, H. and Birattari, M.: "The local paradigm for modeling and control from neuro-fuzzy to lazy learning, Fuzzy Sets and Systems", **121**, 1, 59/72 (2001)
- 4) Inoue, D. and Yamamoto, S.: "An Operation Support System based on Database-Driven On-Demand Predictive Control", Proc. SICE Annual Conf., 2024/2027 (2004)
- 5) 伊藤, 松崎, 大貝, 大館, 内田, 斉藤, 佐々木: "高炉操業における大規模データベースオンラインモデリング", 鉄と鋼, **90**, 11, 59/66 (2004)
- 6) Ito, M., Matsuzaki, S., Odate, N., Uchida, K., Ogai, H. and Akizuki, K.: "Large scale database Online Modeling for Blast Furnace", Proc. 2004 IEEE CCA, 906/911 (2004)
- 7) Ito, M., Matsuzaki, S., Ogai, H., Mori, K., Uchida, K., Saito, S., and Sasaki, N.: "Application of Large scale database-based Online Modeling of Blast Furnace operation", Proc. 16th IFAC World Congress, Prague CD-ROM (2005)
- 8) 内田, 大貝, 伊藤: "大規模データベースオンラインモデリング-高炉への適用-", 計測と制御, **44**, 2, 107/111 (2005)
- 9) 小川, 田島, 大貝, 立野, 伊藤, 松崎, 内田: "大規模データベースオンラインモデリングのクロスプラットフォームシステムの開発と高速化" 日本設備管理学会誌 **19**, 1, 1/8 (2007)
- 10) 立野, 柘植, 松山: "大量の運転データを含むデータベースを利用した動的モデリング法の開発" 電子情報通信学会 (信学技報), **102**, 383, 19/24 (2002)

【著者紹介】

小川 雅俊 (正会員)



2005年早稲田大学大学院情報生産システム研究科 情報生産システム工学専攻修士課程修了。2008年, 同博士後期課程修了。博士(工学)。2007年より早稲田大学情報生産システム研究センター研究助手, 現在に至る。工業炉, 自動車エンジンなどのプロセスのモデリング, シミュレーション・制御技術の研究に従事。電気学会, システム制御情報学会, 日本鉄鋼協会などの会員。

葉 怡君 (正会員)



2005年早稲田大学大学院情報生産システム研究科 情報生産システム工学専攻修士課程修了。2008年, 同博士後期課程修了。博士(工学)。2008年より早稲田大学情報生産システム研究センター助手, 現在に至る。微生物による廃棄物処理プロセスのモデリングとシミュレーション・制御技術の研究に従事。電気学会, 防菌防黴の会員。

大貝 晴俊 (正会員)



1974年早稲田大学工学部電気工学科卒業。76年東京工業大学大学院理工学研究科修士課程修了。同年, 新日本製鐵(株)入社。鉄鋼プロセス制御の開発に従事。2003年より早稲田大学大学院情報生産システム研究科教授。博士(工学), プロセス制御, プロセスモデリング, シミュレーション技術などの研究に従事。電気学会, システム制御情報学会, 人工知能学会, 日本鉄鋼協会などの会員。

立野 繁之 (正会員)

2003年早稲田大学大学院情報生産システム研究科准教授。博士(工学)。

内田 健康 (正会員)



1971年早稲田大学工学部電気工学科卒業。76年早稲田大学大学院理工学研究科 博士課程修了。工学博士。83年より早稲田大学教授(現在, 電気・情報生命工学科)。制御系の情報構造, ロバスト制御および最適化制御の理論と応用, 生物における制御問題などの研究に従事。電気学会, システム制御情報学会, 日本鉄鋼協会, IEEEなどの会員。