

多重モデルを用いた CSTR の監視・制御

坂倉義康 山下善之 松本繁 (東北大学)

Supervisory control of a CSTR based on multiple models

*Y. Sakakura, Y. Yamashita and S. Matsumoto (Tohoku University)

Abstract— A multiple model predictive control strategy is developed in order to supervise and choose between a number of local controllers running in parallel. In this study, local controllers are implemented by a model predictive control algorithm based on local models. Softmax function is used to weight appropriate local controllers. An iterative learning algorithm of a parameter for weighting is also proposed to optimize the control response. The method was applied to a temperature control of a highly nonlinear CSTR and showed excellent control response for set point changes.

Key Words: model predictive control ,multiple modeling ,softmax function ,adaptive control ,process control

1 緒言

化学プロセスには pH 中和プロセスや反応プロセス、蒸留プロセスなど非線形性を有するものが数多く存在し、その制御は容易ではない。モデル予測制御 (MPC) は強い非線形性を持つ対象に対しても有効なため、化学プロセスを対象とした研究が盛んに行われ [1] 実際に産業に適用されている [5]。

モデル予測制御の性能は対象のモデル化の精度に依存するところが大きい。一般に大域で使用できる良好な物理モデルを構築することは難しく、この問題に対処するためにニューラルネットワークモデルや自己回帰モデル等を適用し制御を試みる研究が行われている [8]。

一方で適用範囲を限定するとモデル化が容易になる場合も多いため、全操作領域を一つのモデルでカバーするのではなく、操作領域毎に別々のモデルを構築しておきそれらを組み合わせて制御を行おうとする多重モデルアプローチが提案されている [9]。

本報では多重モデルアプローチを用いた新たなモデル予測制御系を提案する。本手法はソフトマックス関数を用いてオンラインで利用するモデルを切り替え、さらに調整パラメータの 1 つを繰り返し学習によって最適化するものである。非線形性の強い CSTR の温度制御に適用してこの手法の有用性を検証した。

2 方法

2.1 基本的な考え方

多重モデルを用いた制御系の基本的な構造を Fig.1 に示した。あらかじめ複数の制御アルゴリズムを用意しておき、各時点において適切なアルゴリズムをスーパーバイザが選択しながら制御を行うという考え方である。制御則の適切な選択が可能であれば単一の制御アルゴリズムで制御する場合よりも良好な制御が行えるものと期待できる。この局所的な制御アルゴリズムにはどのようなものでも利用できるが、ここではモデル予測制御を用いることとした。その場合、対象の予測モデルを各時点でスーパーバイザにより選択させることになる。この場合の制御系の構造を Fig.2 に示した。

2.2 モデルの切り替え方法

複数個のモデルを使用する場合、それらのモデル出力の競合を解消する必要がある。Weigend ら [10] は複数のニューラルネットワークから構成されるニューラル

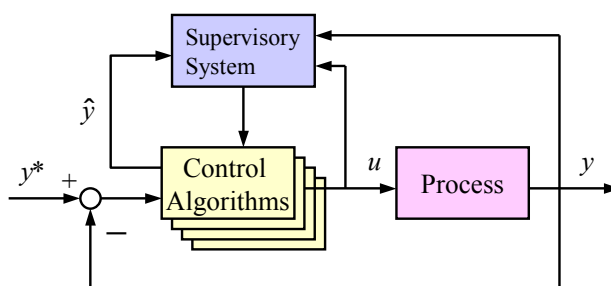


Fig. 1: Control of a multiple model controller.

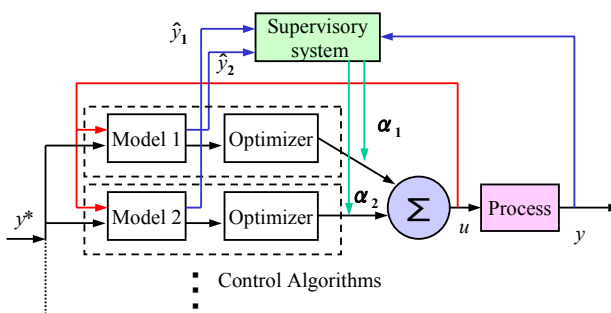


Fig. 2: Schematic structure.

ネットワークとして Gated Experts システムを提案している。今回この考え方を採用してモデルの使用領域をわかりやすく分割することとした。すなわち次のサブシステムの出力をソフトマックス関数 (1) を用いて重み付けする。

$$\alpha_i(t) = \frac{\exp(-\gamma|\hat{y}_i(t-1) - y(t-1)|)}{\sum_{k=1}^m \exp(-\gamma|\hat{y}_k(t-1) - y(t-1)|)} \quad (1)$$

α_i は i 番目のモデル出力に対する重み、 $\hat{y}_i(t-1)$ は時刻 $t-1$ における実際の制御入力 $u(t-1)$ を i 番目のモデルに入力し算出された制御出力、 $y(t-1)$ は時刻 $t-1$ における制御入力 $u(t-1)$ に対するプロセスの出力を表す。(1) の分子の γ による形状変化を Fig.3 に示した。モデル出力 $\hat{y}_i(t-1)$ と実際のプロセス $y(t-1)$ の差が大きくなるに従ってそのモデルにかけられる重みが減少して行く事が分かる。

ここでは通常のソフトマックス関数にパラメータ γ を導入しており、このパラメータを調整することで、各




Fig. 3: $\exp(-\gamma|\hat{y}_i(t-1) - y(t-1)|)$ vs. γ .

モデルの重複の度合いを調整できる。

2.3 繰り返し学習による最適化

式 (1) 中の γ は自由に決定できるパラメータであり、この値を変化させることで各モデル出力の重みを無秩序でない範囲で自由に調節する。そこでここでは制御性能の評価値に従って、 γ の値を最適化することを考えた。

今回は制御性能を評価する指標として IAE (Integral of Absolute value of Error) を用いることとする。IAE は式 (2) で表される。

$$IAE = \int_0^{\infty} |e(t)| dt \quad (2)$$

ここで e はプロセスの出力と制御目標値との差である。1 回の制御ごとに IAE を求め、その値が最小となるように γ の値を変更し、また制御を行うという手順を繰り返すことによって、 γ の最適化を計った。 γ の最適化手法としては様々な次元探索法が利用できるが、今回は黄金分割法を用いた。

バッチプロセスのように幾度となく同じ操作を繰り返す制御系に対して、本手法を適用することでより一層良好な制御性能を得ることが出来るようになる。

2.4 モデル予測制御

Fig.1 で示した局所制御アルゴリズムとして、今回は逐次線形化モデル予測制御 [2][3] を用いた。モデル予測制御 (MPC) は、プロセスのモデルを用いて状態変数を予測することによって、目標値からの偏差を最小とするように将来の入力値を操作する制御法である。状態方程式と出力方程式

$$\frac{dx}{dt} = f(x, u, p), \quad y = h(x) \quad (3)$$

を制約条件として、

$$J(\Delta U) = (Y - Y^*)^T Q_P (Y - Y^*) + \Delta U^T R_P \Delta U \quad (4)$$

$$Y = [y_{k+1}^T, y_{k+2}^T, \dots, y_{k+P}^T]^T \quad (5)$$

$$\Delta U = [\Delta u_k^T, \Delta u_{k+1}^T, \dots, \Delta u_{k+P-1}^T]^T \quad (6)$$

で示される評価関数を最小とする入力を求める最適化問題として定式化される。式 (3) が非線形である場合、この問題をオンラインで解くことは困難であるので、状態変数が観測されるたびに逐次線形化を行うことにす




Fig. 4: Case study plant.

る。すると予測ベクトル Y と入力列 ΔU の関係式は

$$Y = C + D \Delta U \quad (7)$$

となる。これを式 (4) に代入すると ΔU に関する二次形式となるので、 $\partial J / \partial \Delta U = 0$ として ΔU について解くと最適な入力列

$$\Delta U = (D^T Q_P D + R_P)^{-1} D^T Q_P (Y^* - C) \quad (8)$$

が得られる。

さらに高い制御性能を実現するために参照軌道 [4] として次のようにな式を使用した。

$$y_{k+j}^{tr} = \alpha^j y_k + (1 - \alpha^j) y_{k+j}^* \quad (9)$$

$$\text{for } j = 1, 2, 3, \dots \quad 0 \leq \alpha < 1$$

参照軌道を用いる場合、制御則は次式となる。

$$\Delta U = (D^T Q_P D + R_P)^{-1} D^T Q_P (Y^{tr} - C) \quad (10)$$

3 適用例

3.1 制御対象

上述の手法を非線形性を有する代表的な化学プロセスの一つである連続攪拌層型反応器 (CSTR) の温度制御プロセスに適用した。プロセスの概略図を Fig.4 に示す。一般に CSTR は複数の定常点を持ち、時にはリミットサイクルを形成するなど特殊な動特性を持つことが知られている [7]。

反応物 A は温度 T_0 、濃度 C_{A0} 、流量 F で反応器内に流入する。反応器内部では A (反応物) B (生成物) の一次不可逆反応が起こり濃度が C_A 、温度が T へと変化する。本プロセスの制御目的は反応器内部温度 T を設定温度 T^* に保つようにジャケットへの熱媒流入量 F_j を適切に調整することである。

完全混合を仮定すると反応器内の物質収支、熱収支より反応器内部温度 T 、ジャケット温度 T_j 、物質 A の濃度 C_A の動特性を表現する微分方程式は以下のようになる。なお式 (14) はアレニウスの式である。

$$\frac{dC_A}{dt} = \frac{FC_{A0}}{V} - \frac{FC_A}{V} - kC_A \quad (11)$$

$$\frac{dT}{dt} = \frac{FT_0}{V} - \frac{FT}{V} + \frac{k\lambda C_A}{\rho C_p} - \frac{UA_h(T - T_j)}{\rho V C_p} \quad (12)$$

$$\frac{dT_j}{dt} = \frac{F_j T_{j0}}{V_j} - \frac{F_j T_j}{V_j} + \frac{UA_h(T - T_j)}{\rho_j V_j C_{j}} \quad (13)$$

$$k = k_0 \exp\left(\frac{-E}{RT}\right) \quad (14)$$

Table 1: Initial values.

Variable	Value	Unit
F	0.0524	m^3/min
T_0	294.4	K
C_{A0}	8.24	kmol/m^3
F_j	0.099	m^3/min
T_{j0}	294.4	K
T	300	K
T_j	290	K
C_A	0.1	kmol/m^3

Table 2: Local models.

Model No.	Best fit at	k
Model 1	-	0
Model 2	$T = 300[\text{K}]$	0.00083
Model 3	$T = 330[\text{K}]$	0.01056
Model 4	$T = 350[\text{K}]$	0.04519
Model 5	$T = 400[\text{K}]$	0.90606

シミュレーションの初期値を Table 1 に示す. この CSTR の不安定な定常点は $T = 333.3[\text{K}]$, $T_j = 318.2[\text{K}]$, $C_A = 4.148[\text{k mol}/\text{m}^3]$ にあることが分かっている [6]. 今回はこの不安定な定常点への定値制御を行うことを目的とした.

3.2 制御結果

局所モデルとして Table.2 に示した 5 種類のモデルを使用した. これらのモデルは式 (14) の値がそれぞれ一定であるとしたモデルであり, ある特定温度領域でのみ適用できる.

3.2.1 制御応答とモデルの重み

まず式 (1) 中の $\gamma = 1$ として制御を行った. この時の制御結果を Fig.5, 6 に示した. 図中には Model 3 のみを用いた MPC による制御結果 (MPC) も示したが $\gamma = 1$ として 5 つのモデルを用いた制御結果のほうが振動も少なく良好な制御が行えていることが分かる.

またモデルの重みの経時変化を Fig.7 に示した. 制御開始から途中までは Model 1 と Model 2 が主に使われているが, 温度が上昇した後半は Model 3 が主に使用されており, 温度の上昇に従ってやわらかくモデルが使い分けられていることがわかる. さらに出力との差が特に大きい Model 5 に対しては全制御区間を通じて $\alpha_5 \equiv 0$ となっており適合度の低いモデルは実質的に使用されないことが分かる.

3.2.2 学習による最適化

γ の初期値を $\gamma = 0.050, 1.668, 1.050, 0.668$ とした上で制御を繰り返し行い IAE を最小とするように γ を黄金分割法を用いて最適化した. 最終的な準最適解は $\gamma = 0.200$ となった. 最適化されていく様子を Fig.8, 9 に示す. またその時のモデルの重みの変化を Fig.10 に示す. 学習が進むに従って IAE の値が減少し制御性能が向上している. なお, Model 3 を唯一のモデルとして用いた MPC では IAE = 7698.0 となった.




Fig. 5: Control response.





Fig. 6: A part of control response.

Fig. 7: Time series of local model weights α_i ($\gamma = 1$).

$\gamma = 0.200$ の場合の制御結果を Fig.5 に, またその拡大図を Fig.6 に示した. またその際のモデルの重み α の経時変化を Fig.10 に示した. $\gamma = 1$ の場合よりさらに良好な制御結果が得られていることが分かる.

4 結論

多重モデルを用いたモデル予測制御系を提案した. モデルの結合は非線形領域の分割に適した Gated Experts の考え方を元にソフトマックス関数を導入した. さらに繰り返し学習による制御パラメータの調整手法も提案した. 本手法は広い操業範囲で使用できる大域モデルが作成できなくとも, 複数のモデルを使用することで良好な制御が可能となる.

参考文献

- [1] M.Morari and J.H.Lee. Model predictive control; past, present and future. *Computers and Chemical Engineering*, Vol. 23, pp. 667–682,1999.

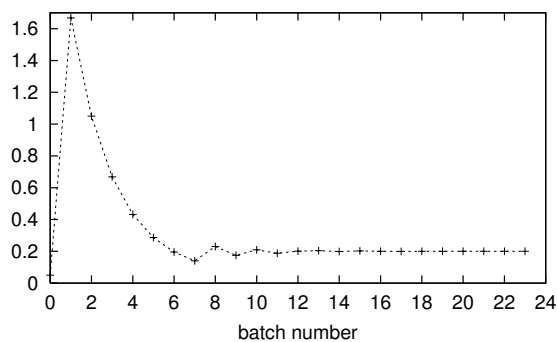


Fig. 8: Iteration of γ .

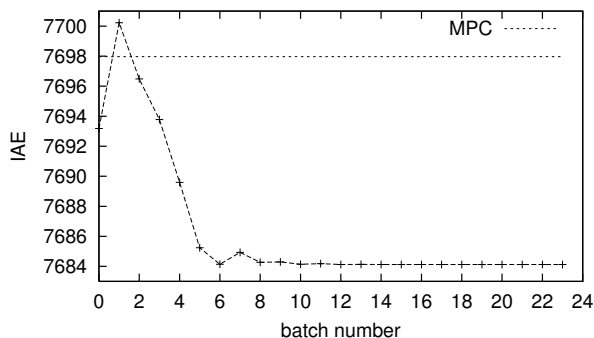


Fig. 9: Learning curve.




Fig. 10: Time series of local model weights α_i ($\gamma = 0.200$).

- [2] 鹿内, 山下, 鈴木. ロバストなモデル予測制御系の設計に関する一考察. 第45回自動制御連合講演会論文集, pp. 571–572, 2002.
- [3] 鹿内, 山下, 松本. 制約付き非線形プロセスのモデル予測制御. 第4回SICE制御部門大会資料, pp. 631–634, 2004.
- [4] 松山, 橋本, 西谷, 仲. 新体系化学工学プロセスシステム工学. オーム社, 1992.
- [5] 新見. モデル予測制御の産業応用への展望, 計測と制御. Vol.43 pp. 647–653 2004.
- [6] K.Yamura Rani and K.Gangiah. Nonlinear dynamic matrix control of an open-loop unstable process with least-squares minimization for constraints *Chemical Engineering Science*, Vol. 46(5/6), pp. 1520–1525, 1991.

- [7] W. H. Ray A. Uppal and A. B. Poore. On the dynamic behavior of continuous stirred-tank reactors. *Chemical Engineering Science*, Vol. 29, pp. 967–985, 1974.
- [8] Po-Feng Tsai. Developing a robust model predictive control architecture through regional knowledge analysis of artificial neural networks. *Journal of Process Control*, Vol. 13, pp. 423–435, 2002.
- [9] Ning Li, Shao-Yuan Li and Yu-Geng Xi. Multi-model predictive control based on the takagi-sugeno fuzzy models: a case study. *Information Science*, Vol. 165, pp. 247–263, 2004.
- [10] Andreas S. Weigend, Morgan Mangeas and Ashok N. Srivastava. Nonlinear gated experts for time series discovering regimes and avoiding overfitting. *International Journal of Neural Systems*, Vol. 6, pp. 373–399, 1995.