

Прогнозирующее управление резервуарным реактором непрерывного действия на основе нечеткой модели

К.Б. Фам

Тверской государственной технической университет

Аннотация: В настоящее время резервуарный реактор непрерывного действия широко используется в различных отраслях промышленности, и существует множество методов управления данным реактором. В статье представлен метод проектирования модельного прогнозирующего контроллера (Model predictive control - MPC) на основе нечеткой модели. Объект управления моделируется с помощью нечеткой модели Такаги-Сугено, задача оптимизации решается с помощью генетического алгоритма. Использование нечетких моделей и генетических алгоритмов для реализации контроллера MPC позволило добиться лучшего качества, чем в традиционных контроллерах MPC.

Ключевые слова: метод проектирования модельного прогнозирующего контроллера, нечеткая модель, Такаги Сугено, генетические алгоритмы, множественные входы-множественные выходы.

Введение

Модельный прогнозирующий контроллер (Model predictive control - MPC) [1] является мощным инструментом управления промышленными процессами, особенно нелинейными процессами с множеством входов и несколькими выходами. Идеология MPC [2]:

- Использование объектной модели для прогнозирования результатов объекта/процесса в будущем (так называемый горизонт вывода) (рис. 1).

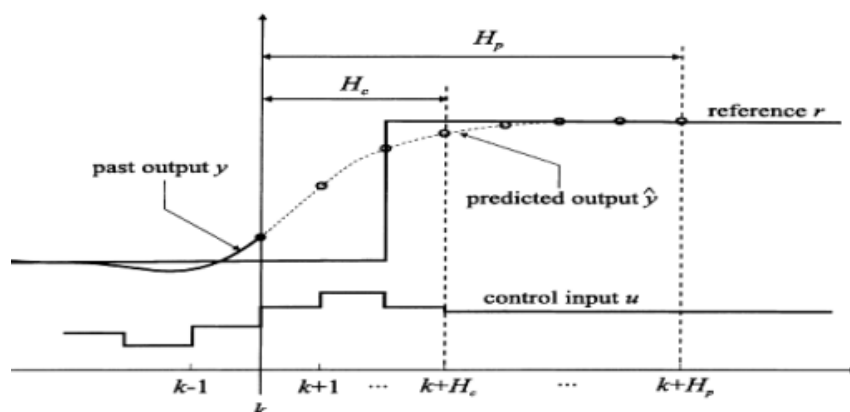


Рис. 1. – Прогнозирование для выходного сигнала $y(t)$ и управляющего сигнала $u(t)$

- Расчёт последовательности сигналов управления на основе минимизации целевой функции.

MPC имеет преимущества перед другими методами контроля [3]:

- Применимо к различным промышленным объектам с простыми или сложными динамическими характеристиками.
- Подходит для объектов с несколькими входами и несколькими выходами.
- Обладает возможностью автоматической компенсации задержки.

Однако этот метод также имеет следующие недостатки: модель прогнозирования должна быть очень точной, чтобы иметь возможность определить состояние процесса в будущем. На самом деле это непростая проблема.

С целью устранения данных недостатков в статье представлено применение нечетких моделей для построения моделей прогнозирования и генетических алгоритмов для решения оптимизационных задач в MPC.

Прогнозирующее управление на основе нечеткой модели

Теорию нечетких множеств можно использовать при моделировании систем. Моделирование выполняется с помощью системы нечеткого вывода. Системы нечетких рассуждений — это процессы, которые преобразуют числовую информацию в лингвистические переменные с помощью фаззификации [4, 5]. Это процесс преобразования физических величин в нечеткие значения, представленные через нечеткие множества. Система правил вывода построена по структуре «Если..., то...» и реализуется механизмом вывода. Выходные данные механизма вывода преобразуются в четкое значение с помощью дефаззификации.

В системах MPC нечеткая модель Такаги-Сугено (ТС) является наиболее широко исследованной и используемой [6]. Преимущество этой

модели состоит в том, что ее можно получить на основе наблюдаемых данных ввода-вывода с использованием методов кластеризации.

Структура модели строится в основном для системы множественных входы-множественных выходов (ММО) с n_i входов: $\underline{u} \in U \subset R^{n_i}, n_0$ выходов: $\underline{y} \in Y \subset R^{n_o}$. Пусть ζ, η являются полиномами с аргументом q^{-1} – оператором обратного сдвига, т.е: $\xi = a_0 + a_1q^{-1} + a_2q^{-2} \dots$ [2].

$$\{y(k)\}_m^n \stackrel{def}{=} [y(k-m), y(k-m-1), \dots, y(k-m-n-1)] \text{ при } m \leq n.$$

Модель имеет следующую структуру:

$$y_l(k+1) = F_l(x_l(k)), l = 1, 2, \dots, n_o$$

$$\underline{x}_l(k) = [\{y_1(k)\}_0^{n_{y1}}, \dots, \{y_1(k)\}_0^{n_{y1}}, \{u_1(k+1)\}_{n_{d1}}^{n_{u1}}, \dots, \{u_{n_1}(k+1)\}_{n_{d1n_1}}^{n_{un_1}}]$$

где n_y, n_u - матрица задержки каждого входа и выхода.

n_d : Матрица чисел транспортной задержки от каждого входа к выходу.

Важной частью нечеткой модели являются правила композиции::

$$R_{ii}: \text{if } x_{ii}(k) = \Omega_{ii} \text{ and } \dots \text{and } x_{ip}(k) = \Omega_{ip}$$

$$\text{then } y_{ii}(k+1) = \xi_{ii}y(k) + \eta_{ii}u(k) + \theta_{ii}, i = 1, 2, \dots, K_l, \quad (2)$$

В котором x_{ii} является элементом вектора регрессии $\underline{x}_i \Omega_{ii}$: нечеткое множество i -го правила, K_l : количество правил в l -й модели. Эта система правил оценивается на основе набора входных и выходных данных процесса. Существует множество методов определения структуры и оценки параметров нечеткой системы.

Целевая функция

Будущие выходные сигналы, расположенные в указанной области N , называемой областью прогнозирования, вычисляются в каждый момент времени t с использованием модели объекта/процесса. Выходные данные прогноза $y(t+k|t)$ $k = 1 \dots N$ зависят от прошлых входных и выходных значений до момента времени t и будущих сигналов управления $u(t+k|t)$, $k = 0 \dots N-1$.

N_1 và N_2 - верхний и нижний пределы области прогнозирования, N_u - контрольный предел. Будущие системы цепей сигналов управления рассчитываются на основе оптимизации целевой функции, чтобы процесс ближе к заданной траектории $w(t + k)$. Общее выражение целевой функции имеет следующий вид:

$$J = \sum_{j=N_1}^{N_2} \delta(j)[f(t+j) - \omega(t+j)]^2 + \sum_{j=1}^{N_u} \lambda(j)[\Delta u(t+j-1)]^2 \quad (3)$$

Числа $\delta(j)$ и $\lambda(j)$ определяют веса компонент целевой функции.

На самом деле, в промышленных процессах трудно избежать ограничивающих условий (также называемых граничными условиями), поэтому целевую функцию (3) часто комбинируют с:

$$\begin{aligned} u_{\min} &\leq u \leq u_{\max} \\ \Delta u_{\min} &\leq \Delta u \leq \Delta u_{\max} \\ y_{\min} &\leq y \leq y_{\max} \\ \Delta y_{\min} &\leq \Delta y \leq \Delta y_{\max} \end{aligned}$$

Именно эти ограничения делают задачу невыпуклой нелинейной оптимизации более сложной, с большим временем и объемом вычислений, что затрудняет применение этого алгоритма к системам с быстрой динамикой. Кроме того, алгоритмы итеративной оптимизации часто сходятся к локальному экстремуму, а метод обратного градиента часто зависит от начального значения. В этой статье мы используем генетические алгоритмы (ГА) для решения задачи оптимизации.

Генетический алгоритм

ГА — это алгоритм случайной оптимизации, основанный на механизме естественного отбора и генетической эволюции. Основной принцип генетических алгоритмов был введен Холландом в 1962 г. [7]. Ее математическая основа была разработана в конце 1960-х годов и представлена в первой книге Холланда «Адаптация в естественных и искусственных системах». В области оптимизации генетические алгоритмы

быстро разрабатываются и применяются во многих областях, таких, как оптимизация, обработка изображений, задачи путешествий, идентификация и управление системами.

Использование генетических алгоритмов в задачах оптимизации позволяет найти точки вблизи глобальных экстремумов, избегая локальных экстремумов, как утверждают некоторые другие методы. Подробности шагов по реализации генетического алгоритма приведены во многих документах [8].

Однако самым большим препятствием при использовании в задачах МРС является то, что ГА требует довольно большого количества времени вычислений. В последние годы скорость компьютерной обработки становится все выше, поэтому применение описанного выше алгоритма подходит для множества различных предметов.

Результаты моделирования управления реактором непрерывного потока

Объектом исследования является управление реактором непрерывного действия, описываемым системой нелинейных дифференциальных уравнений [9]:

$$\frac{dx_1}{dt} = -x_1 + D_a(1-x_1)e^{\frac{x_2}{1+x_2/\phi}}$$
$$\frac{dx_2}{dt} = -(1-\beta)x_2 + BD_a(1-x_1)e^{\frac{x_2}{1+x_2/\phi}} + \beta u$$

Где x_1 и x_2 представляют собой концентрацию веществ в реакции (без единиц), а e – температура реактора. Управляющим сигналом u является температура охлаждения рубашки, окружающей реактор. Физические тепловые константы: D_a : коэффициент Дамколера, ϕ : энергия активации реакции, B : температура реакции, β : коэффициент теплопередачи. Расчетные параметры системы: $D_a=0.072$, $\phi=20$, $B=8$, $\beta=0.3$. При таких параметрах

система неустойчива. Условие: $0 \leq u \leq 2$; $0.5 \leq \Delta u \leq -0.5$. Cấu trúc mô hình được đưa về dạng sau: $y(k) = f(y(k-1), y(k-2), u(k-1))$

Исходя из теории прогнозирующего управления, представленной выше, мы можем построить блок-схему прогнозирующего управления на основе нечеткой модели следующим образом (рис. 2).

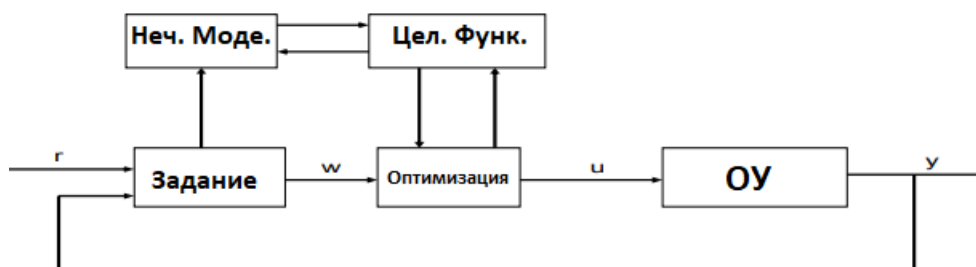


Рис. 2. – Блок-схема прогнозирующего управления на основе нечеткой модели

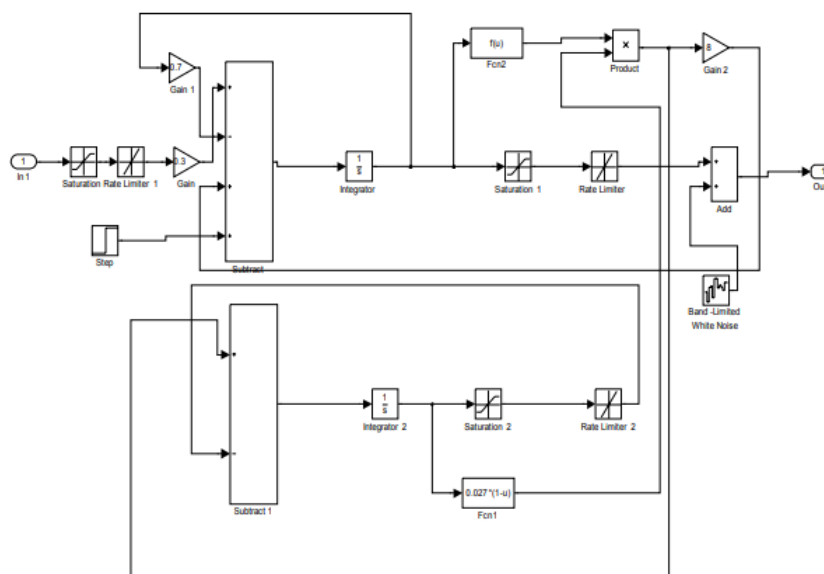


Рис. 3. – Объект в Simulink

Структура нечеткого множества: каждый вход состоит из двух нечетких множеств трапециевидной формы. Управляющая область прогнозирования $N_C=2$; прогноз выхода $N_P=6$. Использование генетического алгоритма: $n = 10$ бит; число хромосом = 50; количество поколений = 6.




Рис. 4. – Входной – выходной сигнал




Рис. 5. – Результаты обучения

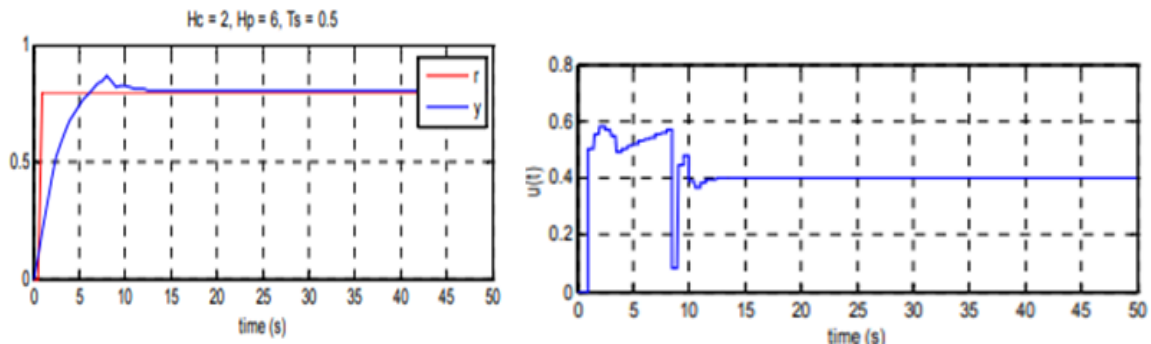


Рис. 6. – Выходной сигнал $y(t)$ и сигнал управления $u(t)$, заданный сигнал постоянный.

Заключение

Используя нечеткую модель ТС и генетический алгоритм в этой статье, мы предложили возможный алгоритм для решения проблемы прогнозирующего управления нелинейными системами. Результаты моделирования показывают, что качество регулятора достаточно хорошее, выходной сигнал $y(t)$ следует за заданным сигналом $r(t)$ с приемлемой погрешностью. С быстрым развитием индустрии информационных технологий скорость вычислений микропроцессоров значительно возросла,

что создало благоприятные условия для применения вышеуказанных алгоритмов к реальным задачам управления временем.

Литература

1. Киселева М. Ю., Смагин В. И. Управление с прогнозирующей моделью с учетом запаздывания по управлению. Вестник Томского государственного университета, 2010, Т.11, № 2, С. 5-12.

2. Сюэ Ю. Компьютерное моделирование системы стабилизации курса автомобиля с использованием прогноза. Процессы управления и устойчивость, 2014, Т.1, №1, С. 401-406.

3. Закамалдин А. А., Шилин А. А. Построение системы автоматического управления с прогнозирующей моделью для стабилизации плотности и уровня при перемешивании пульпы в горно-обогатительном оборудовании. Известия Санкт-Петербургского государственного технологического института (технического университета), 2021, № 58, С. 77-83.

4. Борисов В.В., Круглов В.В., Федулов А.С. Нечеткие модели и сети. Москва: Горячая линия – Телеком, 2012, 284 с.

5. Бобырь М.В., Милостная Н. А. Нечеткая модель интеллектуальной системы управления мобильным роботом. Проблемы машиностроения и автоматизации, 2015, № 3, С. 57-67.

6. Игонина Е.В., Масина О.Н., Дружинина О.В. Анализ устойчивости динамических систем на основе методов интеллектуального управления и свойств линейных матричных неравенств. Елец: Елецкий государственный университет им. И.А. Бунина, 2020. 174 с.

7. Holland John H. Outline for a logical theory of adaptive systems. Journal of the ACM (JACM), 1962, Vol. 3, No 9, P. 297-314.

8. Goldberg D. E. Genetic algorithms in search. Optimization, Machine Learning. Addison Wesley. 1989. no. 102. P. 36.

9. Santos Coelho Leandro dos, Krohling Renato A. Discrete Variable Structure Control Design based on Lamarckian Evolution, Springer, London, 2003, P. 361-370.

References

1. Kiseleva M. Yu., Smagin V. I. Vestnik Tomskogo gosudarstvennogo universiteta, 2010, Vol.11, № 2, pp. 5-12.

2. Syue` Yu. Processy` upravleniya i ustojchivost`, 2014, Vol.1, №1, pp. 401-406.

3. Zakamaldin A. A., Shilin A. A. Izvestiya Sankt-Peterburgskogo gosudarstvennogo texnologicheskogo instituta (texnicheskogo universiteta), 2021, № 58, pp. 77-83.

4. Borisov V.V., Kruglov V.V., Fedulov A.S. Nechetkie modeli i seti [Fuzzy models and networks]. Moskva: Goryachaya liniya. Telekom, 2012, 284 p.

5. Boby`r` M.V., Milostnaya N. A. Problemy` mashinostroeniya i avtomatizacii, 2015, № 3, pp. 57-67.

6. Igonina E.V., Masina O.N., Druzhinina O.V. Analiz ustojchivosti dinamicheskix sistem na osnove metodov intellektnogo upravleniya i svojstv linejny`x matrichny`x neravenstv [Analysis of stability of dynamic systems based on intelligent control methods and properties of linear matrix inequalities]. Elec: Eleczkij gosudarstvenny`j universitet im. I.A. Bunina, 2020. 174 p.

7. Holland John H. Journal of the ACM (JACM), 1962, Vol. 3, No 9, pp. 297-314.

8. Goldberg D. E. Optimization, Machine Learning. Addison Wesley. 1989. no. 102. P. 36.

9. Santos Coelho Leandro dos, Krohling Renato A. Springer, London, 2003, pp. 361-370.

Дата поступления: 24.09.2024

Дата публикации: 2.11.2024