



УДК 681.5.015

© 2015 г. Г.Б. Диго,
Н.Б. Диго,

А.Ю. Торгашов, д-р техн. наук
(Институт автоматизации и процессов управления ДВО РАН, Владивосток),

С.А. Самотылова
(Дальневосточный федеральный университет, Владивосток)

СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ ПРОМЫШЛЕННЫХ ТЕХНОЛОГИЧЕСКИХ ОБЪЕКТОВ НА ОСНОВЕ РОБАСТНОЙ РЕГРЕССИИ

Рассматривается задача построения прогнозирующей математической модели, малочувствительной к меняющимся условиям функционирования промышленных технологических объектов. Обсуждаются проблемы, возникающие при использовании методов робастной регрессии, и предлагаются варианты их разрешения. Приводятся результаты применения метода робастной регрессии с оптимальными параметрами весовых функций для идентификации процесса газоразделения установки каталитического крекинга.

Ключевые слова: идентификация, промышленный технологический объект, структура модели, робастная регрессия, весовые функции.

Введение

Создание и эксплуатация систем управления промышленными и технологическими объектами существенно зависят от качества используемых моделей. Построение моделей, предназначенных для прогноза выходной реакции объекта на заданные входные переменные, требует решения трех взаимосвязанных задач, имеющих различную возможность формализации и разную степень изученности. Это задачи выбора класса структур, структуры в выбранном классе, определения параметров модели (параметрическая идентификация). И если последняя из перечисленных задач является наиболее изученной, то проблема решения первых двух при работе реальных объектов остается по-прежнему актуальной.

В реальных условиях возникают трудности, связанные со структурно-параметрической неопределенностью, вызываемой отсутствием теоретических сведений о структуре возможных моделей и входных переменных, существенно влияющих на выход объекта, а также воздействием случайных внешних факторов. И хотя эти трудности препятствуют успешному применению классического регрессионного анализа, использующего метод наименьших квадратов (МНК), во многих ситуациях такой способ построения моделей

остаётся наиболее распространённым. В настоящее время существует большой набор вычислительных приемов и средств, позволяющих использовать регрессионный анализ в условиях нарушения исходных постулатов, среди которых методы робастной регрессии (РР). В частности, при построении регрессионных моделей во многих ситуациях удается использовать M -оценки, устойчивые к нарушению исходных предположений о нормальном законе распределения [1, 2]. Они обеспечивают высокую эффективность в широком классе распределений и обладают малой чувствительностью к грубым ошибкам в наблюдениях. Такие оценки параметров регрессионных моделей сами являются нелинейными функциями наблюдений, а их построение основано на замене минимизации суммы квадратов (метод наименьших квадратов) минимизацией суммы значений медленнее растущей функции остатков.

В статье излагается подход к решению задачи построения прогнозирующей математической модели промышленного технологического объекта, малочувствительной к меняющимся условиям его функционирования, и приводятся результаты его применения при идентификации процесса газоразделения на установке каталитического крекинга.

Постановка задачи

Рассматривается многомерный технологический объект, функционирующий в условиях неопределенности, вызываемой недостатком теоретических знаний о нем, входных переменных, существенно влияющих на ход процесса, воздействием случайных внешних факторов, погрешностями измерений. Предположим, что есть основания описывать его линейной по параметрам регрессионной моделью

$$y = \sum_{i=1}^k \beta_i f_i + \varepsilon, \quad (1)$$

где y – выходная переменная; $f_i = f_i(x_1, \dots, x_m)$, $i = 1, \dots, k$ – некоторые функции входных контролируемых переменных x_1, \dots, x_m , не включающие неизвестные коэффициенты β_1, \dots, β_k ; ε – действующее на выходе неконтролируемое возмущение. Коэффициенты β_1, \dots, β_k из (1) оцениваются по экспериментальным данным, являющимся реализациями случайных величин, поэтому находятся не их истинные значения, а лишь оценки b_1, \dots, b_k , и (1) принимает вид

$$\tilde{y}_j = \sum_{i=1}^k b_i f_{ij}, \quad j = 1, \dots, n, \quad (2)$$

где \tilde{y}_j – предсказанное значение, соответствующее j -му значению y_j выходной переменной y . Использование методов робастной регрессии позволяет получать оценки b_1, \dots, b_k из (2), в том числе при отклонениях от нормального распределения промышленных данных. Согласно общим принципам робастного оценивания, вводятся в рассмотрение функции остатков, растущие медленнее, чем квадрат остатков, или весовые функции, обеспечивающие веса остатков на концах вари-

ционного ряда меньше, чем в его середине, и определяющие свойства оценок b_1, \dots, b_k . Тогда минимизация суммы квадратов остатков

$$\sum_{j=1}^n e_j^2 = \sum_{j=1}^n \left(y_j - \sum_{i=1}^k b_i f_{ij} \right)^2 \rightarrow \min_{b_1, \dots, b_k} \quad (3)$$

заменяется минимизацией сумм медленнее растущих функций остатков. Так, для получения M -оценок (3) преобразуется к виду

$$\sum_{j=1}^n \rho(e_j) = \sum_{j=1}^n \rho \left(y_j - \sum_{i=1}^k b_i f_{ij} \right) \rightarrow \min_{b_1, \dots, b_k}, \quad (4)$$

где $\rho(z)$ – некоторая функция, растущая медленнее, чем z^2 ; z – аргумент функции ρ , характеризующий ошибку модели. Очевидно, что в зависимости от способов выбора используемых в (4) функций $\rho(e_j)$ возможны разные варианты оценок, поэтому в условиях неопределенности возникает необходимость использовать многовариантный анализ.

Ставится задача разработать алгоритм построения математической модели, малочувствительной к меняющимся условиям функционирования промышленного технологического объекта, на основе методов робастной регрессии (РР) в сочетании со структурным синтезом и опробовать его на промышленных данных. В дальнейшем такие модели будем называть прогнозирующими.

Анализ задачи

Для построения моделей прогнозирования в условиях структурно-параметрической неопределенности необходимо:

- выявить особенности исследуемого объекта;
- обосновать выбор метода построения модели и критериев ее оценки;
- сформировать обучающую и проверочную выборки по имеющимся промышленным данным.

Особенности исследуемых технологических объектов на примере установки каталитического крекинга секции газоразделения. На рис. 1 приведена схема технологического блока газоразделения установки каталитического крекинга (УКК). В ней измеряемые входные переменные: x_1 – давление верха колонны, кгс/см² (PIRCSAH-1); x_2 – температура верха колонны, С (TIRC-5); x_3 – температура на шестой тарелке, С (TIR-6а) и выходная переменная y – сумма концентраций изобутана, бутана и бутиленов в ППФ, % (С₄). Расход ППФ измеряется прибором FIRC-1. Экспериментальное определение значений y происходит в заводской лаборатории.

На практике при идентификации подобных объектов возникают трудности, связанные со структурно-параметрической неопределенностью, вызываемой отсутствием теоретических сведений о структуре возможных моделей и количестве входных переменных, существенно влияющих на выход объекта, в условиях воздействия случайных внешних факторов.

Физико-химические модели сложно использовать для прогнозирования качества выходных продуктов технологического процесса в режиме реального вре-

мени из-за высокой размерности, а уравнения материальных и энергетических балансов, равновесия фаз ступеней разделения являются нелинейными и содержат большое количество параметров, значения которых не могут быть точно определены в промышленных условиях.




Рис. 1. Параметры технологического процесса газоразделения УКК.

В связи с этим при построении моделей для промышленных объектов приходится опираться на доступные измерению переменные. Для технологического процесса, представленного на рис. 1, это x_1 , x_2 , x_3 . Использование их в качестве входов в разрабатываемую модель обосновано тем, что изменение технологического режима сопровождается коррекцией только этих (ключевых с точки зрения физико-химического смысла) переменных.

Анализ проблем, возникающих при решении поставленной задачи. Согласно [3], идентификация описанных выше объектов требует решения взаимосвязанных задач, обеспечивающих выбор класса структур, выбор структуры модели из этого класса и оценивание неизвестных параметров модели при заданной ее структуре.

Зашумленность имеющихся экспериментальных данных и описанные выше условия неопределенности приводят к необходимости обращаться к методам робастной регрессии с устойчивыми M -оценками, сочетая их со структурным синтезом. Очевидно, что входящая в (4) функция $\rho(z)$ определяет свойства оценок коэффициентов модели (2), и в зависимости от ее вида они будут различными. Кроме того, отсутствие сведений о степени отклонения распределения выходной переменной y от нормального закона приводит к необходимости рассматривать несколько видов $\rho(z)$. При этом, если она невыпуклая, то в (4) возможно несколько решений, соответствующих локальным минимумам. Тогда очень важным являет-

ся этап задания начального приближения, поскольку оно может быть выбрано из области, далекой от глобального минимума, и найденные оценки не будут обладать требуемыми устойчивыми свойствами.

При получении M -оценок необходимо решать следующие подзадачи [2, 4]:

выбор вида функции $\rho(z)$ из (4);

подбор параметров функции $\rho(z)$ или ограничений на них;

выбор метода решения задачи минимизации (4).

Каждая из них, в силу условий неопределенности, подразумевает просмотр различных вариантов и выбор среди них наилучшего по заданному критерию.

Поскольку используемые критерии должны охватывать и структурную, и параметрическую идентификации, следуя рекомендациям из [3, 5, 6], были выбраны:

1) коэффициент детерминации (доля объясненной дисперсии отклонений зависимой переменной от ее среднего значения)

$$R^2 = 1 - \frac{\sum_i (y_i - y_i^m)^2}{\sum_i (y_i - \bar{y})^2}; \quad (5)$$

2) среднеквадратическая ошибка (СКО)

$$RMSE = \left(\frac{\sum_{i=1}^M (y_i - y_i^m)^2}{M} \right)^{1/2}; \quad (6)$$

3) информационный критерий Акаике (Akaike) (AIC)

$$AIK(q) = n \cdot \ln SS(RES)_p + 2 \cdot q - n \ln(n); \quad (7)$$

4) критерий Байеса-Шварца (BSC)

$$BSC(q) = n \cdot \ln(SS(RES)_p) + q \cdot \ln(n) - n \cdot \ln(n). \quad (8)$$

В (5) – (8) y_i – наблюдаемое значение выходной переменной; y_i^m – ее значение, полученное по модели объекта; \bar{y} – среднее значение наблюдаемой выходной переменной; n – число наблюдений; $SS(RES)_p$ – сумма квадратов остатков; $q = p + 1$, p – число независимых переменных. Построенная модель тем больше соответствует исследуемому объекту, чем ближе к единице значение коэффициента детерминации R^2 либо чем ближе к нулю значение СКО. Информационные критерии (7), (8) основаны на некоем компромиссе между точностью и сложностью модели и различаются тем, как они обеспечивают этот баланс при выборе структуры модели.

Построение моделей

Исходной информацией для построения прогнозной модели являются обучающая и проверочная выборки (матрицы, сформированные на основе промышленных данных, содержащих значения входных и выходной переменных). Метод построения модели включает следующие этапы:

1. Выбор класса структур моделей, исходя из априорной информации и имеющегося физико-химического описания.

2. Структурная идентификация (выбор структуры модели из заданного класса структур).

2.1. Построение моделей из выбранного класса структур методом исключения по обучающей и проверочной выборкам.

2.2. Отбор среди построенных моделей лучших по информационным критериям (7), (8).

3. Параметрическая идентификация (оценивание неизвестных параметров модели при заданной ее структуре).

3.1. Определение параметров отобранных моделей с помощью M -оценок (3) для различных весовых функций $\rho(z)$ и параметров z .

4. Выбор прогнозирующей модели, оптимальной по критериям (5) – (6).

Эффективность описанного алгоритма проверена на реальных данных процесса построения модели для прогноза примесей в пропан-пропиленовой фракции (ППФ) секции газоразделения установки каталитического крекинга (УКК), представленного решением следующих задач:

формирование обучающей и проверочной выборок по промышленным данным;

выбор вида весовой функции $\rho(z)$;

выбор параметра весовой функции $\rho(z)$;

выбор регрессоров для структурного синтеза модели;

разработка моделей для прогнозирования C_4 в ППФ методом РР;

выбор наилучшей прогнозирующей модели.

Обучающая выборка сформирована из входных x_1, x_2, x_3 и выходной y переменных в виде матрицы размерностью 149×4 . Проверочная выборка имеет объем 78×4 . Исследуемые весовые функции РР представлены в табл.1, сформированной согласно рекомендациям из [4].

Таблица 1

| Весовая функция | Вид весовой функции | Параметр весовой функции (r_{def}) |
|-----------------|---|--|
| ω_1 | $\omega = r \cdot \sin(r) / r, \quad r < \pi$ | 1.339 |
| ω_2 | $\omega = r \cdot (1 - r^2)^2, \quad r < 1$ | 4.685 |
| ω_3 | $\omega = 1 / (1 + r^2)$ | 2.385 |
| ω_4 | $\omega = 1 / (1 + r)$ | 1.400 |
| ω_5 | $\omega = 1 / \max(1, r)$ | 1.345 |
| ω_6 | $\omega = \tanh(r) / r$ | 1.205 |
| ω_7 | $\omega = 1 \cdot r , \quad r < 1$ | 2.795 |
| ω_8 | $\omega = \exp(-r^2)$ | 2.985 |

Структура модели определялась на основе пошаговой регрессии (метод исключения) с введением дополнительных входов. Матрицы входных переменных для обучающей и проверочной выборок формировались по структурам, представленным в табл. 2. При выборе лучших из рассмотренных структур использовались критерии (5) – (8).

Для выбора лучших моделей по каждой из весовых функций табл. 1 использовались различные значения параметра r . В частности, осуществлялся поиск оптимального параметра весовой функции r_{opt} для каждой из структур в смысле ин-

формационных критериев (7), (8).

Таблица 2

| № п/п | Набор параметров модели | № п/п | Набор параметров модели |
|-------|--|-------|--|
| 1 | $S_1 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_1^2, x_2^2, x_3^2]$ | 15 | $S_{15} = [x_1, x_2, x_3, x_2x_3]$ |
| 2 | $S_2 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_1^2, x_2^2]$ | 16 | $S_{16} = [x_1, x_2, x_3, x_1^2, x_2^2]$ |
| 3 | $S_3 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_1^2, x_3^2]$ | 17 | $S_{17} = [x_1, x_2, x_3, x_1^2, x_3^2]$ |
| 4 | $S_4 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_2^2, x_3^2]$ | 18 | $S_{18} = [x_1, x_2, x_3, x_2^2, x_3^2]$ |
| 5 | $S_5 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_1^2]$ | 19 | $S_{19} = [x_1, x_2, x_3, x_1^2]$ |
| 6 | $S_6 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_2^2]$ | 20 | $S_{20} = [x_1, x_2, x_3, x_2^2]$ |
| 7 | $S_7 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3, x_3^2]$ | 21 | $S_{21} = [x_1, x_2, x_3, x_3^2]$ |
| 8 | $S_8 = [x_1, x_2, x_3, x_1x_2, x_1x_3, x_2x_3]$ | 22 | $S_{22} = [x_1, x_2, x_3];$ |
| 9 | $S_9 = [x_1, x_2, x_3, x_1x_2, x_1x_3]$ | 23 | $S_{23} = [x_1, x_2]$ |
| 10 | $S_{10} = [x_1, x_2, x_3, x_1x_2, x_2x_3]$ | 24 | $S_{24} = [x_1, x_3]$ |
| 11 | $S_{11} = [x_1, x_2, x_3, x_1x_3, x_2x_3]$ | 25 | $S_{25} = [x_2, x_3]$ |
| 12 | $S_{12} = [x_1, x_2, x_3, x_1^2, x_2^2, x_3^2]$ | 26 | $S_{26} = [x_1]$ |
| 13 | $S_{13} = [x_1, x_2, x_3, x_1x_2]$ | 27 | $S_{27} = [x_2]$ |
| 14 | $S_{14} = [x_1, x_2, x_3, x_1x_3]$ | 28 | $S_{28} = [x_3].$ |

В результате структурного синтеза установлено, что наилучшей по информационным критериям является модель структуры S_{22} при $q = 4$ (рис. 2).




Рис. 2. Значения критериев AIC и BSC, полученные PP при r_{opt} на обучающей и проверочной выборках.

На рис. 3, 4 показано влияние параметра весовой функции r модели S_{22} при $q = 4$ на коэффициент детерминации R^2 и СКО.

В результате проведенного анализа моделей, полученных на проверочной выборке по различным весовым функциям $\omega_1 - \omega_8$ из табл. 1, установлено, что наилучшей из них по критерию коэффициента детерминации является модель струк-

туры S_{22} при ω_4 ($R^2 = 0.713$).




Рис. 3. Зависимость коэффициента детерминации R^2 от параметра r весовой функции РР.




Рис. 4. Зависимость СКО от параметра r весовой функции РР.

Улучшение по сравнению, например, с весовой функцией ω_5 модели S_4 равно $100 \cdot (0.713 - 0.5411) / 0.5411 = 31.7\%$ (рис. 5). Уравнение модели S_{22} имеет вид: $y = 7.2 - 2.1x_1 + 0.38x_2 + 0.31x_3$.




Рис. 5. Зависимость значения коэффициента детерминации R^2 от различных структур моделей при оптимальных r_{opt} весовых функций ω .

Заключение

Применение методов робастной регрессии для построения прогнозирующих моделей реальных технологических объектов позволяет улучшить их качества за счет использования M -оценок с подбором весовых функций и их параметров по обучающим и проверочным выборкам.

Основным результатом исследования является улучшение качества модели для данного технологического объекта на 31.7% за счет проведения структурного синтеза на основе выбора оптимальной весовой функции РР и использования информационных критериев.

ЛИТЕРАТУРА

1. Вучков И., Бояджиева Л., Солаков Е. Прикладной регрессионный анализ. – М.: Финансы и статистика, 1987.
2. Хьюбер П. Робастность в статистике. – М.: Мир, 1984.
3. Перельман И.И. Методология выбора структуры модели при идентификации объектов управления // Автоматика и телемеханика. – 1983. – №11. – С.5-29.
4. Holland P.W., Welsch R.E. Robust regression using iteratively reweighted least-squares // Communications in Statistics – Theory and Methods. – 1977. – Vol.6, No 9. – P.813-827.
5. Rawlings J.O., Pantula S.G., Dickey D.A. Applied regression analysis: a research tool. – NY.: Springer-Verlag Inc., 1998.
6. Akaike H. A new look at the statistical model identification // IEEE Transactions on Automatic Control. – 1974. – 19 (6). – P.716-723.

Статья представлена к публикации членом редколлегии О.В. Абрамовым.

E-mail:

Галина Борисовна Дуго – bernatsk@iacp.dvo.ru;

Наталья Борисовна Дуго – digo@iacp.dvo.ru;

Андрей Юрьевич Торгашов – torgashov@iacp.dvo.ru;

Самотылова Светлана Александровна – studvvsu@gmail.com.