

ТЕХНОЛОГИИ ГИБКОГО ПРОАКТИВНОГО УПРАВЛЕНИЯ ПРОИЗВОДСТВЕННЫМИ ПРОЦЕССАМИ И СИТУАЦИЯМИ НА ОСНОВЕ СЦЕНАРНОГО ПРОГНОЗИРОВАНИЯ

Д.В. Елпашев

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: den.elpshv@gmail.ru

А.А. Черешко

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: chereshkoalex@gmail.com

А.С. Сулейкин

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: aless.sull@mail.ru

В.Н. Кушнарев

Институт проблем управления им. В.А. Трапезникова РАН
Россия, 117997, Москва, Профсоюзная ул., 65
E-mail: grand_yarl@mail.ru

Ключевые слова: про-активное управление, ассоциативный поиск, сценарное предиктивное моделирование, сценарное прогнозирование, индуктивная база знаний.

Аннотация: Представлены методы сценарного прогнозирования состояния динамических процессов и ситуаций в технических, природных и социальных системах. Описаны технологии проактивного управления на основе сценарного on-line моделирования и метода ассоциативных правил. Предложены методы оптимизации управления на основе цифровых идентификационных двойников.

1. Введение

Разработка систем управления на основе предиктивных моделей реального времени становится все более актуальной. Концепция про-активного управления продемонстрировала свою эффективность в таких сферах, как: промышленное производство, электроэнергетика, логистические процессы, трейдинг и др. На основе on-line прогнозов определяются условия устойчивого функционирования, предлагаются методы и алгоритмы оптимизации всей производственной и бизнес-деятельности предприятий и компаний [1]. Под предиктивным моделированием динамического процесса понимают оценивание его будущего состояния на основе анализа текущего

состояния и его возможного изменения (тенденций) в результате воздействия внешних возмущений. Предиктивное моделирование представляет собой один из видов прогнозирования и может осуществляться для анализа, а также для принятия оптимального решения – при управлении либо планировании. Распространенным является вероятностное описание возможного изменения состояния процесса [2]. Выделяют следующие основные типы прогнозов: поисковые (или исследовательские, трендовые, генетические и т.п.) и нормативные (программные, целевые) [3]. При поисковом прогнозировании определяется возможное (вероятное) состояние процесса в будущем без учета возможных факторов изменения текущих тенденций (как внешних, так и обусловленных динамикой процесса). Нормативное прогнозирование определяет способы и сроки достижения возможных состояний, декларируемых как целевые.

Под производственной ситуацией мы понимаем вектор состояний исследуемого производственного/бизнес-процесса, расширенный за счет дополнительных факторов, характеризующих функционирование этих процессов. К таким факторам относятся, например, состояния соответствующих производственных, информационных и кадровых ресурсов, условия поставок сырья и комплектующих и многие другие. Среди них могут быть трудно формализуемые показатели, значения которых определяются, в частности, на основе экспертного анализа. Также производственная ситуация характеризуется определенным режимом производственного процесса, что определяет структуру модели.

Авторами предложены методы сценарного прогнозирования состояний динамических процессов и ситуаций. На основании сценариев осуществляется формирование рекомендуемых управляющих воздействий – как для систем автоматического управления, так и для поддержки принятия решений. Для построения моделей используются алгоритмы идентификации, основанные на индуктивных знаниях – закономерностях, извлекаемых с помощью методов интеллектуального анализа из данных функционирования исследуемого процесса [4-5].

2. Технологии про-активного управления и поддержки принятия решений

Ассоциативная модель в случае замкнутой системы с управлением в цепи обратной связи имеет вид:

$$(1) \quad y(n) = \sum_{k=0}^{n-1} \sum_{i=1}^S a_{ik} x_i(n-k) + \sum_{r=0}^{n-1} c_r u(n-r) + \sum_{j=1}^{n-1} b_j y(n-j),$$

где S – размерность вектора входов x , выход y и управление u будем полагать одномерными. В отличие от обычной регрессионной модели, в (1) только определенные коэффициенты будут отличны от 0. Структура модели определяется на этапе обучения ассоциативной модели. Введем обозначение для «расширенного вектора входов»:

$$\tilde{x}(n) = [x_i(n-k), i = 0, \dots, M; k = 0, \dots, n-1; u(n-r), r = 0, \dots, n-1; y(n-j), j = 1, \dots, n-1],$$

Тогда модель (1) можно записать в виде:

$$(2) \quad y(n) = \sum_{h=0}^{n-1} d_h \tilde{x}(n)(n-h).$$

В отличие от обычной регрессионной модели, в ассоциативной (которая строится отдельно для каждого момента n) только некоторые из коэффициентов d_h отличны от нуля.

Предположим, что в момент времени n :

- значения компонент $x_i(n)$ входного вектора принадлежит кластеру $Q_{p_x}, p_x = 1, \dots, P_x$;

- значения компонент $y(n)$ входного вектора принадлежит кластеру $Q_{p_y}, p_y = 1, \dots, P_y$;
- значения $u(n)$ управляющего сигнала принадлежит кластеру $Q_{p_u}, p_u = 1, \dots, P_u$;

Для нахождения коэффициентов модели (2) составляются уравнения, аналогичные (1). В этих уравнениях фигурируют известные значения \tilde{x} из базы знаний, принадлежащие кластеру Q_{p_x} , в том числе – известные, реальные значения управлений и выходов в выбранные прошлые моменты времени. С учетом статистической зависимости компонент вектора $\tilde{x}(n)$ находим псевдорешения системы составленных линейных уравнений, например, посредством процедуры Мура-Пенроуза [6-7]. Далее, подставляя в модель с найденными коэффициентами значения текущего вектора входов, известные значения предыдущих выходов и произвольное значение управления, получаем прогноз выхода. В идентификаторе модель формируется методом ассоциативного поиска. Эта модель является точечной и наилучшей в смысле выбранного критерия и использует всю накопленную к данному моменту информацию об объекте. Для определения оптимального управления на основе прогнозирующей модели положим в (2):

$$y(n) = y_{opt},$$

где y_{opt} – некоторое желаемое значение выхода, $y_{opt} \in Y$.

$$(3) \quad y_{opt} = \sum_{k=0}^{n-1} \sum_{i=1}^M a_{ik} x_i(n-k) + \sum_{r=1}^{n-1} c_r u(n-r) + c_n u(n) + \sum_{j=1}^{n-1} b_j y(n-j),$$

Можно в качестве y_{opt} на каждом шаге выбирать новые «желаемые» значения и находить соответствующие значения управляющих воздействий. Периодически систему следует дообучать, корректируя кластерное размещение данных в базе знаний.

По сути, идентификатор в цепи обратной связи, формирующий цифровые модели реального времени, является цифровым двойником объекта управления. В отличие от известных подходов, в предлагаемой схеме используются не имитационные модели, а цифровые модели, формируемые посредством интеллектуальных алгоритмов идентификации (рис. 1).

3. Сценарное прогнозирование

Рассмотрим модель динамического процесса (1) для случая, когда в течение продолжительного времени на вход объекта не поступают ни наблюдаемые входы $x(n-k)$, ни управления $u(n-r)$, что характерно для определенных технологических процессов. Модель принимает вид:

$$y(n+1) = \sum_{j=1}^{n-1} b_j y(n-j),$$

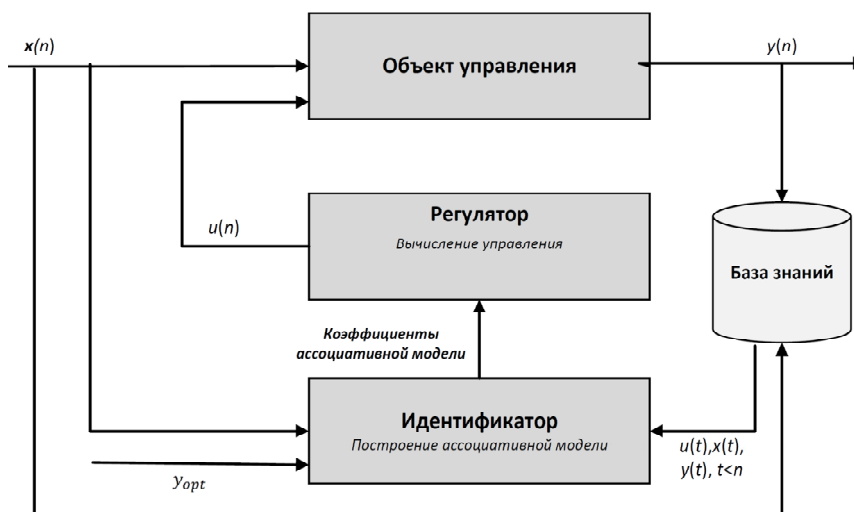


Рис. 1. Модель системы управления с идентификатором.

Определим кластерные метки для кластеров сценариев изменения состояния технологического процесса. Для простоты, без ограничения общности, рассмотрим случай, когда значения $y(n)$ в базе знаний процесса подразделены на четыре кластера. Предположим, что динамика процесса достаточно адекватно описывается его состояниями на временных интервалах длины T , предшествующих текущему моменту:

$$n = [n - T + 1, n - T + 2, \dots, t].$$

В каждый момент времени для описания ситуации используется не только соответствующая кластерная метка, но и ее предыстория на предыдущем временном интервале. Предположим, что имеется некоторый порядок нумерации возможных цепочек. Тогда, если длина цепочки равна T , а алфавит кластерных меток имеет длину l , то общий размер пространства равен $N_c = l^T$ элементов. Произвольная цепочка состояний может быть представлена в виде вектора размерности N_c , где единица стоит только в той позиции, которая по номеру совпадает с порядковым номером этой цепочки, а в остальных местах стоят нули. Для сформированной бинарной цепочки можно получить прогноз на основе методов интеллектуального анализа данных – поиска ассоциативных правил - одного из методов обнаружения знаний в базах данных (Knowledge Discovering Databases, KDD, [8]). Тип анализа данных на основе поиска ассоциативных правил предназначен для поиска часто встречающихся комбинаций двух наборов значений переменных состояния. Исследуются также наборы в моменты времени, отстоящие друг от друга на несколько позиций. Таким образом, модель прогноза настраивается в зависимости от значений отдельных параметров на предшествующих тактах. В результате прогнозирования получается бинарная цепочка, представляющая собой номер последовательности кластерных меток (в нашем примере – четырех кластерных меток). Расшифровка номера дает информацию, в какой кластер попадут значения $y(n - j)$, фигурирующие в модели вычисления $y(n)$ для моментов времени на несколько тактов вперед с помощью алгоритма ассоциативного поиска. В итоге, получаем прогноз динамики состояний исследуемого процесса на несколько тактов вперед.

4. Сценарное моделирование

Для моделей (3) построить прогноз на несколько тактов вперед не представляется возможным, поскольку невозможно предугадать, какие значения примут входные

воздействия. В этом случае можно осуществлять сценарное прогнозирование в виде моделирования сценариев. На этапе обучения для каждого кластера, на которые можно разделить значения компонент расширенного вектора входов, строится модель методом ассоциативного поиска. Далее определяется, в какой кластер попал текущий расширенный вектор входов \tilde{x} . Могут быть решены задачи достижения:

- оптимального значения выхода y_{opt} на каждом из последующих тактов;
- требуемых (различных) значений выхода y_{opt}^n на каждом из последующих тактов, т.е. формирования условий для реализации заданной динамики процесса на несколько тактов вперед;

На этапе обучения строится матрица решений, которую можно использовать для нахождения оптимального управления на каждом такте с учетом того, в какой кластер попадает вектор входов $x(n)$ в текущий момент n . Заметим, что речь идет именно о матрице, а не о дереве решений, поскольку на каждом такте мы строим новую ассоциативную модель.

5. Заключение

Исследованы методы ассоциативного поиска для построения цифровых on-line моделей с переменной структурой производственных процессов. Предложены методы оптимизации управления на основе цифровых идентификационных двойников. Предложены методы сценарного on-line моделирования на основе метода ассоциативных правил.

Исследование выполнено в рамках научной программы Национального центра физики и математики, направление № 9 «Искусственный интеллект и большие данные в технических, промышленных, природных и социальных системах».

Список литературы

1. Bakhtadze N.N., Lototsky V.A. Knowledge-Based Models of Nonlinear Systems Based on Inductive Learning // *New Frontiers in Information and Production Systems Modeling and Analysis: Incentive Mechanisms, Competence Management, Knowledge-based Production*. Heidelberg, Germany: Springer, 2016. P. 85-104.
2. Бахтадзе Н.Н., Елпашев Д.В., Кушнарев В.Н., Максимов Е.М., Максимова Н.Е., Сулейкин А.С., Черешко А.А. Интегрированная система управления промышленным предприятием как цифровая экосистема // *Автоматизация в промышленности*. 2023. № 6. С. 3-11.
3. Omar N., Amer W., Ibrahim N. Predictive Modeling for Developing Maintenance Management in Construction Projects // *Civil Engineering Journal*. 2019. Vol. 5, P. 892-900.
4. Бахтадзе Н.Н., Кушнарев В.Н., Черешко А.А. Сценарное прогнозирование на основе цифровых смарт-моделей динамических процессов // *Информационные технологии и вычислительные системы*. 2023. № 3. С. 70-78.
5. Bakhtadze N.N., Cheresenko A.A., Elpashev D.V., Suleykin A.S., Purtov A. Predictive associative models of processes and situations // *IFAC-PapersOnLine*. 2022. Vol. 55, No. 2. P. 19-24.
6. Moore E. On the reciprocal of the general algebraic matrix // *Bull. Am. Math. Soc.* 1920. Vol. 26. P. 394-395.
7. Penrose R. A generalized inverse for matrices // *Proc. Camb. Philos. Soc.* 1955, Vol. 51. P. 406-413.
8. Agrawal, R., Imielinski, T., Swami, A., Mining Associations between Sets of Items in Massive Databases // *Proc. of the 1993. ACM-SIGMOD Int'l Conf. on Management of Data*. 1993, P. 207-216.