

АДАПТАЦИЯ СТРУКТУРЫ И ПАРАМЕТРОВ НЕЛИНЕЙНЫХ ВИРТУАЛЬНЫХ АНАЛИЗАТОРОВ НА ПРИМЕРЕ ПРОМЫШЛЕННОГО РЕАКЦИОННО-РЕКТИФИКАЦИОННОГО ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА

О.Ю. Снегирев, А.Ю. Торгашов (Институт автоматизации и процессов управления ДВО РАН)

Рассматривается построение виртуального анализатора (ВА) с адаптацией структуры и параметров модели и учетом фактора времени с использованием методов кластеризации на примере реакционно-ректификационного технологического процесса. Предложено улучшить разработанный ранее алгоритм функционирования адаптивного ВА с применением «движущегося окна» и кластеризации путем обновления модели на основе алгоритма условных чередующихся математических ожиданий и с учетом фактора времени. Показано преимущество предложенного адаптивного ВА по точности в сравнении с ранее разработанным алгоритмом адаптации без учета фактора времени и с адаптивным ВА на основе нейронной сети¹.

Ключевые слова: виртуальный анализатор, адаптация, кластеризация, метод чередующихся условных математических ожиданий, фактор времени, реакционно-ректификационный процесс.

Введение

По мере того как современные технологические установки процессов нефтепереработки и нефтехимии становятся все более сложными, растут объемы данных о процессе, хранящиеся в базе данных, которые могут быть использованы для мониторинга, управления и оптимизации процесса. Виртуальный анализатор (ВА) может рассматриваться как инструмент анализа данных, который построен для оценки значений трудноизмеримых переменных с использованием значений доступных измерению переменных. По сравнению со строгими методами моделирования, основанными на физико-химических закономерностях, виртуальные анализаторы являются более гибкими и могут быть легко реализуемы на реальных промышленных предприятиях.

В настоящее время на производстве используются ВА, в основе которых лежат линейные регрессионные модели, что предполагает некоторые допущения о линейной структуре модели технологического объекта. Однако это допущение не всегда справедливо в реальных условиях. Использование непараметрических методов регрессии свободно от требования о знании структуры модели. Непараметрические регрессионные методы могут быть классифицированы на те, которые не преобразуют выходную переменную, такие как обобщенные аддитивные модели (Generalized Additive Model - GAM), и преобразующие выход, такие как чередующиеся условные математические ожидания (Alternating Conditional Expectations - ACE) [1]. Также весьма популярны модели на основе нейронных сетей [2]. Нейронные сети - исключительно мощный метод моделирования, позволяющий

воспроизводить чрезвычайно сложные зависимости. Нейронные сети обучаются на примерах. Пользователь нейронной сети подбирает представительные данные, а затем запускает алгоритм обучения, который автоматически воспринимает структуру данных. В данной статье предлагается использовать для построения ВА метод чередующихся математических ожиданий и провести его сравнение с нейросетевым моделированием.

В реальных условиях промышленных предприятиях состояние процесса часто изменяется на разных уровнях в зависимости от различных условий производства. Как правило, деградация модели является одной из важнейших проблем, с которыми сталкиваются разработчики виртуальных анализаторов, что может привести к ухудшению точности прогнозирования. Это часто происходит после изменения технического состояния установки, воздействия неизмеряемых возмущений по составу сырья, старения катализатора, загрязнение труб и деградация оборудования. Часто ВА разрабатывается на установленном технологическом режиме, модель усваивает информацию только одного или ограниченного числа режимов. Даже если модель разработана успешно, ее точность ухудшается при изменении состояния процесса, так как в модели отсутствует информация о новом состоянии. Для решения этой задачи были предложены адаптивные виртуальные анализаторы, использующие новые данные измерений. Типичные адаптивные виртуальные анализаторы строятся на основе таких методов, как just-in-time (JIT) [3], time difference (TD) [4] и moving window (MW) подходы [5]. Модели JIT широко используются при построении адаптивных ВА с использованием выбранных

¹ Работа осуществлялась при финансовой поддержке Российского фонда фундаментальных исследований (проекты 20-37-90027 Аспиранты, 21-57-53005 ГФЕН_а).

обучающих выборок. Метод JT нуждается в выбранном наборе данных из базы данных АСУТП, который содержит информацию обо всем процессе. Выбранный набор данных может быть очень велик, и поиск похожих выборок из него всегда занимает много времени.

Обычно модели ВА рассматриваются как некоторые функции, входные/выходные переменные которых определяются как x -переменные и y -переменная соответственно. В моделях ВА на основе TD дифференциал или разности первых порядков x -переменных берутся в качестве входных сигналов модели для оценки приращения y -переменной [4], и это приращение добавляется к прогнозируемому значению y -переменной.

Для метода MW набор данных в окне обновляется путем включения новых выборок и исключения более старых наблюдений. В большинстве случаев набор данных, сформированный в окне, считается наиболее подходящим для текущего состояния технологического объекта. Каждый раз, когда окно обновляется, в нем содержится последняя информация о процессе, по которой построенная модель может эффективно описывать текущее состояние, даже если характеристики технологического объекта начинают постепенно смещаться. Тем не менее для модели MW трудно справиться с сильной нелинейностью процесса с быстрым или мгновенным изменением, поскольку модель подвержена влиянию старых данных до изменения.

Применения методов кластеризации при разработке адаптивного виртуального анализатора на основе MW в известных методах заключается в разбиении данных на кластеры и построении отдельной модели для каждого набора наблюдений [6]. В данной работе представлен алгоритм, отличающийся от ранее предложенного в [7], где кластеризация используется для определения необходимости обновления параметров модели, тем, что допол-

нительно учитывается временной фактор для своевременной адаптации ВА к изменяющимся характеристикам технологического объекта.

Технологический объект и переменные ВА

В качестве объекта исследования рассматривается массообменный (реакционно-ректификационный) технологический процесс (МТП). Особенность МТП заключается в совместном протекании обратимой химической реакции с частичным или практически полным разделением образующейся смеси посредством ее ректификации. Продуктом МТП является метил-трет-бутиловый эфир (МТБЭ), который широко применяется в производстве высокооктановых бензинов. Для его получения используются метанол и изобутилен, поступающий с бутан-бутиленовой фракции (ББФ) (рис. 1). Частичная реакция синтеза МТБЭ происходит в прямоточном реакторе форконтакта (P-50) и в реакционно-ректификационном аппарате, представляющем собой две ректификационные колонны (K-51/1 и K-51/2) и расположенный между ними реактор синтеза (P-51). Реакционная смесь из реактора P-51 выводится двумя потоками: сверху реактора отбирается газовая фаза; снизу реактора отбирается жидкая фаза, каждая из которых идет на дальнейшее разделение. Основным показателем качества продукта МТБЭ является содержание в нем метил-втор-бутилового эфира (МВБЭ). Концентрация МВБЭ является выходной переменной (Y) ВА.

В качестве регрессоров в модели ВА используются измеряемые технологические параметры: u_1 – расход МТБЭ (FIR51_2); u_2 – расход отработанного ББФ (FIR51_4); u_3 – расход ББФ в P-50 (FIR50_1); u_4 – расход орошения K-51/2 (FIR51_3); u_5 – расход метанола на форконтакт (FIR50_1); u_6 – расход реакционной массы, поступающей в K-51/1 (FIR51_1); u_7 – давление верха K-51/2 (PIR51_1); u_8 – температура в среднем слое катализатора P-51 (TIR51_1); u_9 – температура в среднем слое катализатора P-51 (TIR51_2).

Математическая модель в составе ВА

Регрессионная модель ACE имеет общий вид:

$$\theta(Y) = b_0 + \sum_{i=1}^m \varphi_i(u_i), \quad (1)$$

где $\theta(Y)$ – функция оптимальных преобразований выходной переменной Y , b_0 – свободный член, φ_i – функция оптимальных преобразований входной переменной u_i , $i = 1, \dots, m$ номер входной переменной.

Преобразуя уравнение (1), получим модель для оценки выходной переменной \hat{Y}_{ACE} [8]:

$$\hat{Y}_{ACE} = \theta^{-1} \left(b_0 + \sum_{i=1}^m \varphi_i(u_i) \right), \quad (2)$$

Процесс использования алгоритма ACE для оценки качества выходного продукта.

1. Производим расчет оптимальных преобразований методом ACE для данных обучающей выборки.
2. Аппроксимируем полученные оптимальные преобразования для вычисления функций $\varphi_i(u_i)$ и θ^{-1} .

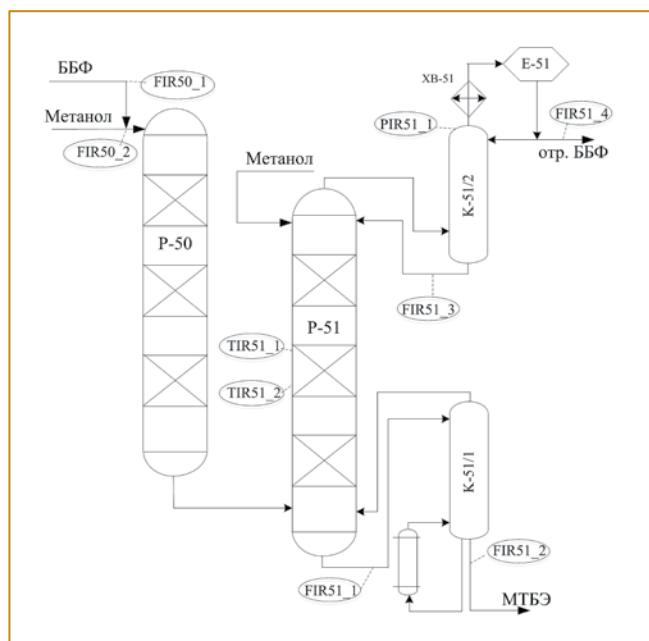


Рис. 1. Технологическая схема массообменного (реакционно-ректификационного) процесса

3. Подставляем вычисленные функции в уравнение (2).

В работе использована полиномиальная аппроксимация оптимальных преобразований, общий вид:

$$\varphi_i(u_i) \approx \sum_{q=0}^{p_i} b_{(i,q)} u_i^q \quad (3)$$

где p_i - степень полинома зависимости $\varphi_i(u_i)$, $b_{(i,q)}$ - коэффициент при значении входной переменной u_i в степени $q = 0 \dots p_i$.

Выбор минимально допустимой степени аппроксимирующего полинома

Одной из проблем является правильный подбор степени полинома p . Данный параметр влияет на качество аппроксимирующей функции [9]. На рис. 2 представлены график оптимальных преобразований методом АСЕ и графики аппроксимирующих полиномиальных функций с разным значением степени полинома p . Если значение p меньше необходимого, то можно заметить несовпадение аппроксимирующей функции с оптимальными преобразованиями. Если значение p больше необходимого, то разница ошибок аппроксимации мала, то есть для упрощения модели ВА можно пренебречь данной разницей и использовать полином меньшей степени.

В качестве критерия невязки полученной аппроксимирующей функции использовалась *средняя абсолютная ошибка* [10]:

$$MAE_{\varphi_i} = \frac{1}{N} \sum_{n=1}^N |\varphi_i(u_{i,n}) - \hat{\varphi}_i(u_{i,n})| \quad (4)$$

Для определения минимально допустимой степени полинома исследовалось изменение значения MAE с увеличением степени.

Алгоритм выбора подходящего значения минимально допустимой степени аппроксимирующего полинома p .

1. Если значение переменной $pt < 4$ (действие алгоритма начинается с $pt = 1$), вычисляем MAE аппроксимации оптимальных преобразований полиномом степени pt и увеличиваем значение $pt = pt + 1$.




Рис. 2. График оптимальных преобразований и графики аппроксимирующих функций на примере u_9

2. Если значение переменной $pt \geq 4$, вычисляем MAE аппроксимации оптимальных преобразований полиномом степени pt и вычисляем уравнения кривых, проходящих через значения MAE наборов точек $w = [p - 3, pt - 2, pt - 1]$ и $q = [pt - 2, pt - 1, pt]$. Уравнения будут иметь вид $H = a_I w^2 + b_I w + c_I$ и $P = a_{II} q^2 + b_{II} q + c_{II}$ соответственно. Значения H, P соответствуют значениям MAE наборов точек w, q .

3. Если $-0,3 < H'(pt-2) < 0$, $a_I > 0$ и $P'(pt-1) \approx 0$, ($H'(pt-2)$ и $P'(pt-1)$ - значения производных функций H, P в точках $pt - 2$ и $pt - 1$ соответственно), то значение минимально допустимой степени аппроксимирующего полинома $p = pt - 2$, иначе увеличиваем значение $pt = pt + 1$ и повторяем действие алгоритма с пункта 2. На рис. 3 представлен результат работы алгоритма при аппроксимации оптимальных преобразований входной переменной (на примере u_9) ВА.

Подобрав максимальное значение степени p аппроксимирующего полинома для каждой входной переменной и вычислив функции $\varphi_i(u_i)$ и θ^{-1} , подставляя их в уравнение (2) получим модель ВА.

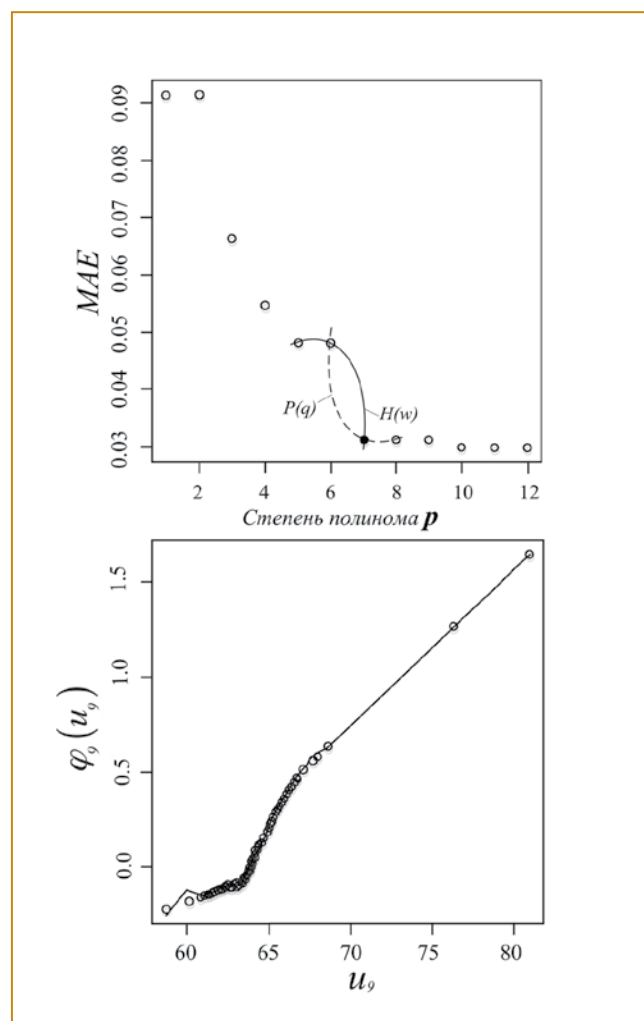


Рис. 3. Изменение MAE аппроксимации от максимальной степени полинома и график аппроксимирующей функции, соответствующий выбранному значению максимальной степени полинома

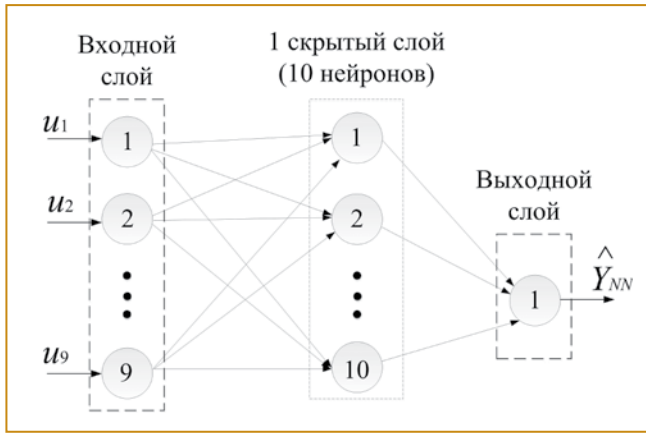


Рис. 4. Структура нейронной сети

Сравнение с нейросетевым ВА

Проведем сравнение предлагаемой модели с ВА на основе нейронной сети. В качестве архитектуры нейронной сети была выбрана структура, представленная на рис. 4. Нейронная сеть имеет входной слой с числом нейронов, соответствующим числу входных переменных модели, одного скрытого слоя, состоящего из 10 нейронов, и выходного слоя.

На рис. 5 представлено сравнение оценок выходной переменной ВА на основе нейронной сети и ВА на основе АСЕ. В результате оценок коэффициента детерминации для полученных моделей сделан вывод, что использование алгоритма АСЕ предпочтительней, чем использование нейронных сетей. Коэффициент детерминации для модели на базе нейронных сетей равен 0,563, а для моделей на основе АСЕ составляет 0,633. Также стоит учесть необходимый размер обучающей выборки для получения качественной модели. В данном эксперименте для обуче-

ния ВА на основе нейронных сетей было использовано 700 наблюдений, а для получения качественных моделей ВА на основе АСЕ можно было использовать и 250 наблюдений.

Обновление структуры и параметров модели на основе АСЕ

При рассмотрении вопроса обновления моделей ВА на основе линейной регрессии процесс обновления заключается в пересчете коэффициентов модели. По результатам предыдущих исследований [7] предложено осуществлять обновление модели по аналогии с моделями на основе линейной регрессии. На этапе инициализации находятся оптимальные преобразования выходной/входных переменных, выполняется аппроксимация с вычислением минимально допустимой степени аппроксимирующего полинома.

При последующей проверке изменчивости минимально допустимой степени полинома было выявлено, что для различных обучающих выборок значения минимально допустимой степени различно. На рис. 6 представлен график изменения минимально достаточной степени полинома для различных наборов наблюдений.

Из графика рис. 6 сделан вывод, что в ходе работы адаптивного ВА необходимо помимо коэффициентов аппроксимирующего полинома обновлять также значение его максимальной степени.

На рис. 7 представлен график изменения оптимальных преобразований в ходе функционирования ВА при получении 1, 400, 800 и 1200 наблюдений. Из этих изменений следует, что в ходе процесса с увеличением числа наблюдений могут изменяться формы оптимальных преобразований входных переменных, что приводит к ухудшению модели ВА, основанной на аппроксимации оптимальных преобразований входных переменных на предыдущем шаге работы алгоритма.




Рис. 5. График сравнения оценки выходной переменной с использованием АСЕ и нейронной сети




Рис. 6. Изменение максимальной степени аппроксимирующего полинома в ходе функционирования ВА на примере $\varphi_9(u_i)$




Рис. 7. График изменения оптимальных преобразований в ходе функционирования ВА при получении 1, 400, 800 и 1200 наблюдений

Алгоритм для обновления модели ВА на основе ACE.

1. Производим расчет оптимальных преобразований методом ACE для новой обучающей выборки.
2. Для каждой входной переменной вычисляем аппроксимирующие полиномы со степенью $p, p-1$ и $p+1$, где p - текущее значение минимально достаточной степени полинома
3. Вычисляем MAE аппроксимации оптимальных преобразований и вычисляем уравнение кривой проходящей через значение MAE соответствующих $[p-1, p, p+1]$. Уравнение будут иметь вид $y = a_{10}x^2 + b_{10}x + c_{10}$.
4. Если $a_{10} > 0$, то значение минимально достаточной степени аппроксимирующего полинома будет зависеть от значения производной $y'(p)$ (если $y'(p) < -0,3$,

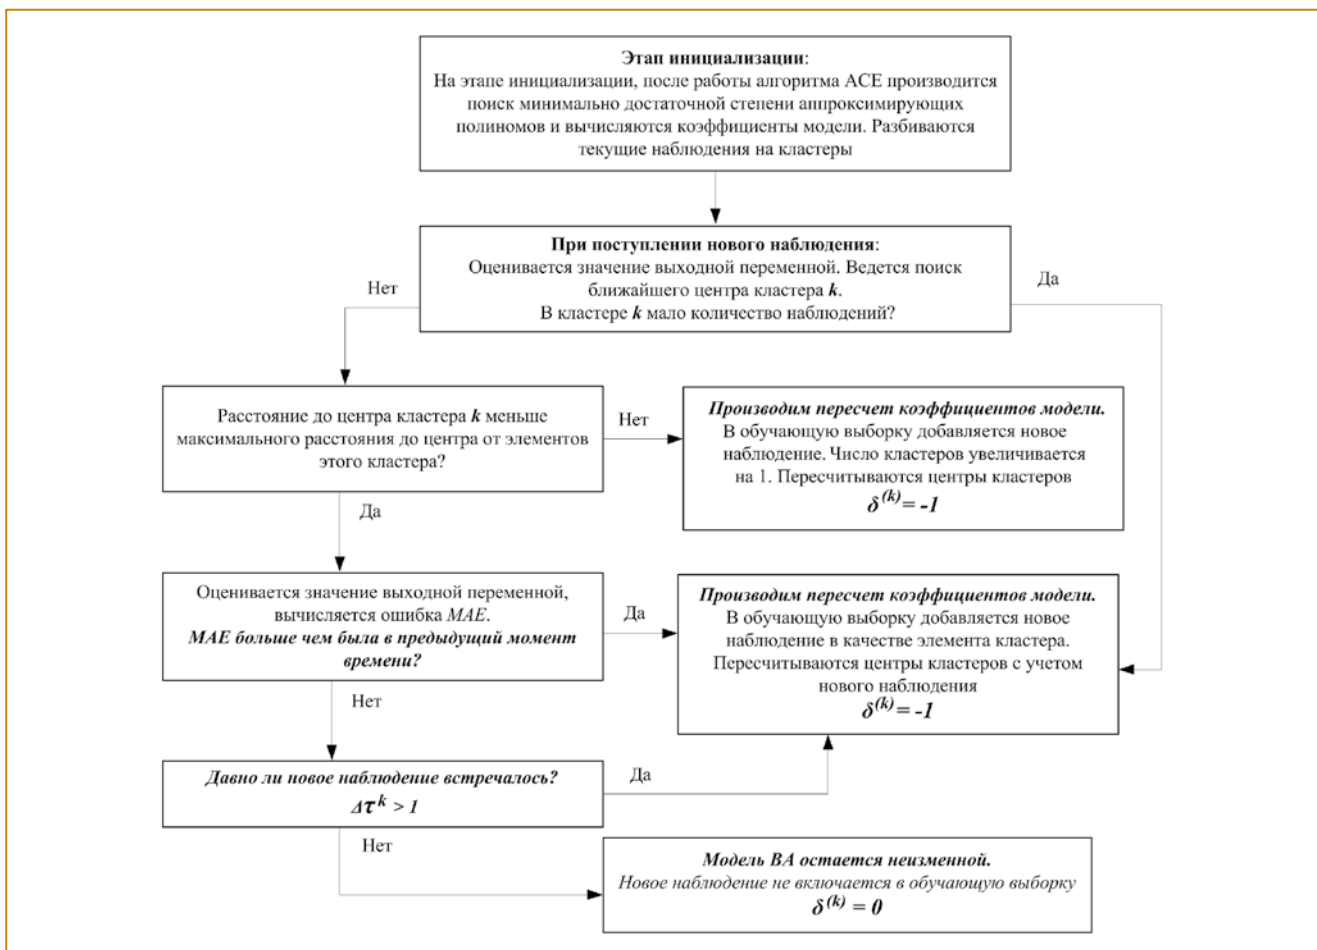


Рис. 8. Алгоритм работы предлагаемого адаптивного ВА

то $p := p + 1$; если $-0,3 < y'(p) < 0,15$, то $p := p$; если $y'(p) > 0,15$, то $p := p - 1$), иначе оно будет зависеть от значения отношения MAE для $[p + 1]$ к MAE для $[p - 1]$ (если $\frac{MAE[p + 1]}{MAE[p - 1]} > 0,8$, то $p := p - 1$, в противном случае $p := p + 1$).

Константы $-0,3$ и $0,15$ определены экспериментально на основе наблюдений изменения MAE от степени полиномов аппроксимирующих оптимальные преобразования входных переменных ВА.

5. Пересчитываем коэффициенты функции $\varphi_i(u_i)$ для новых значений минимально достаточной степени полиномов и подставляем в уравнение (2) для последующей оценки выходной переменной.

Применение кластеризации для адаптации ВА с учетом фактора времени

В данной работе методы кластеризации предлагается использовать для определения необходимости обновления текущей модели ВА. Применение методов кластеризации в работе адаптивного ВА отображено в алгоритме adapt-ACE-t (рис. 8). Кластеризация осуществляется в пространстве входных переменных модели. Обновление модели происходит с использованием обучающей выборки, в которую входят все имеющиеся наблюдения вне зависимости от кластера, к которому они принадлежат.

По сравнению с предложенным ранее алгоритмом adapt-ACE [10] помимо учета расстояния от нового наблюдения до центра ближайшего кластера и изменения значения MAE предлагается вычислять разницу по времени появления нового наблюдения и последнего в кластере (фактор времени), что позволит своевременно учесть в модели проявление нестационарных свойств объекта. На рис. 9 приведена шкала времени с наблюдениями кластера k и моментом времени появления нового наблюдения.

Для учета фактора времени в момент времени t для кластера k предлагается использовать следующий показатель:

$$\Delta \tau_t^k = \frac{\tau_t - \tau_{Q_k}^k}{\bar{T}^k}, \quad (5)$$

где τ_t - значение момента времени появления нового наблюдения, $\tau_{Q_k}^k$ - значение момента времени появления последнего элемента в кластере k . $T^k = (\tau_1^k - \tau_0^k, \tau_2^k - \tau_1^k, \dots, \tau_{Q_k}^k - \tau_{Q_k-1}^k)$ - вектор временных ин-

тервалов между появлениями наблюдений k -ого кластера, τ_0^k - начальный момент времени, \bar{T}^k - среднее значение вектора T^k .

Если значение $\Delta \tau_t^k > 1$, то необходимо добавить данное наблюдение в обучающую выборку для обновления модели ВА потому, что период между появлением нового наблюдения и последним в кластере больше среднего периода появления наблюдений кластера и увеличивается вероятность того, что характеристики объекта изменились, а точность ВА ухудшится.

На рис.10 представлены графики изменения значения $\Delta \tau^k$ для кластера номер 3, то есть $k = 3$, когда фактор времени учитывается при обновлении ВА, и в случае, когда он не учитывается. Помимо изменения значения $\Delta \tau^{(3)}$, на рис. 10 представлены значения показателя обновления ($\delta^{(k)}$) модели ВА:

$$\delta^{(k)} = \begin{cases} 0, & \text{модель не обновляется} \\ -1, & \text{обновление модели} \end{cases}$$

Сделаем вывод (рис.10), что учет фактора времени при работе адаптивного ВА увеличивает частоту обновления модели, тем самым способствует более своевременной адаптации модели ВА к изменениям технологического объекта, что приводит к улучшению качества адаптивного ВА. Уменьшение значения $\Delta \tau^{(3)}$ соответствует моменту времени, когда алгоритм выдал решение включить новое наблюдение в обучающую выборку и обновить модель, тем самым изменив средний интервал появления наблюдений в кластере и отодвинув на более позднее значение точку отчета периода до появления нового наблюдения.

На рис.10а показано, что наблюдения, принадлежащие данному кластеру, довольно часто встречались (много ненулевых значений $\Delta \tau^{(3)}$), и, оценивая расстояние от нового наблюдения до центра кластера и величину изменения MAE , алгоритм выдавал решение не включать данные наблюдения в обучающую выборку и не обновлять модель. По величине значения $\Delta \tau^{(3)}$ сделан вывод, что появление наблюдений, на основе которых строилась модель, происходило относительно давно (больше чем в 5 раз от среднего интервала появления наблюдений кластера), а за этот период параметры объекта исследования могли измениться.

На рис.10 б показано изменение значения $\Delta \tau^{(3)}$ при работе алгоритма, учитывающего фактор времени появления

наблюдения, для которого было установлено пороговое значение 1. На интервале с 620 по 660 наблюдение наиболее хорошо виден эффект учета фактора времени. В данный период в основном появлялись наблюдения, принадлежащие данному кластеру, и, оценивая расстояние




Рис. 9. Шкала времени появления наблюдений кластера k : τ_t - значение момента времени появления нового наблюдения, τ_v^k - значение момента времени появления v -го элемента кластера k ($v = 1 \dots Q_k$), Q_k - число наблюдений в k -м кластере, T_v^k - интервал времени между появлениями v -го и $(v-1)$ -го наблюдений k -го кластера

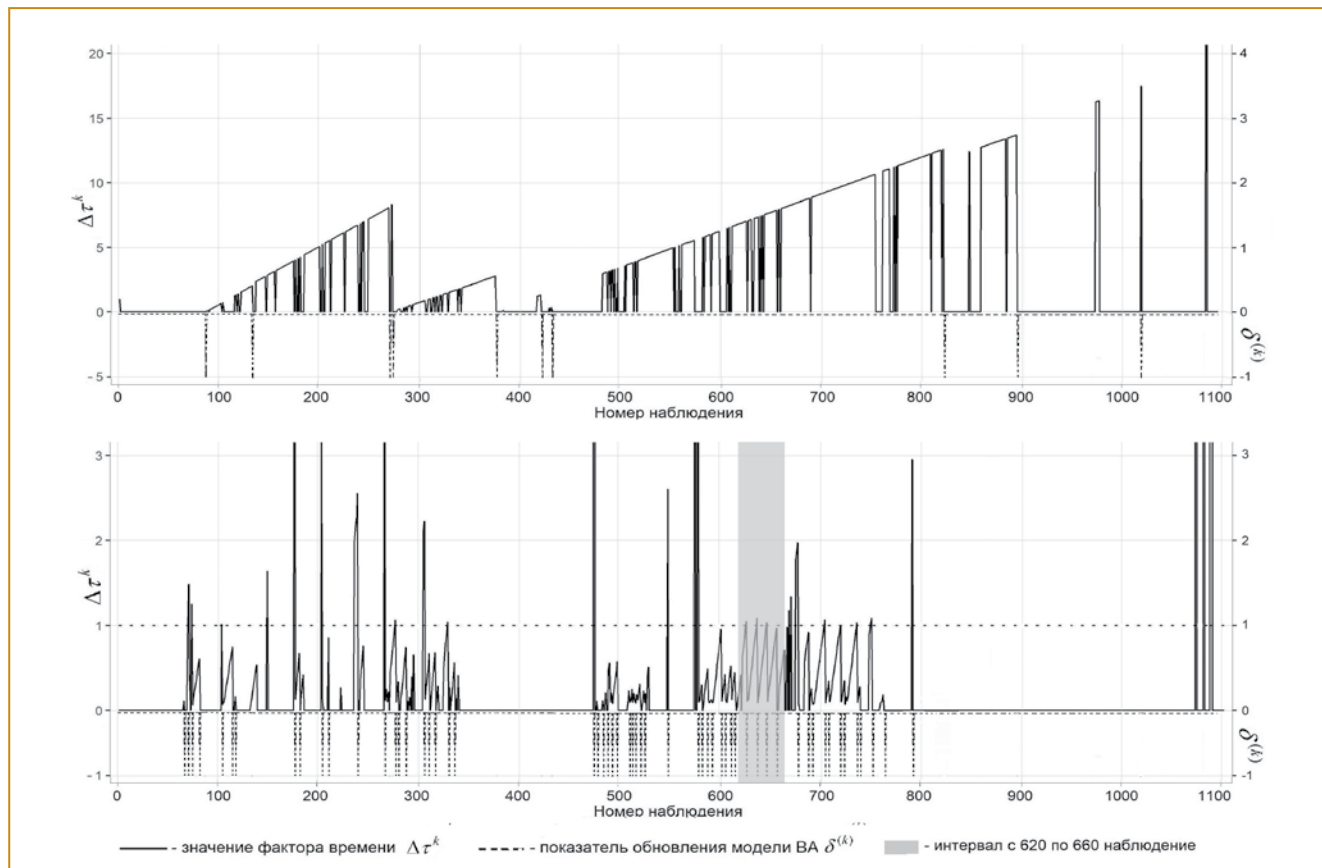


Рис. 10. Изменение значения временного фактора во время процесса: а) без учета фактора времени; б) с учетом фактора времени

от нового наблюдения до центра кластера и величину изменения MAE , алгоритм решил не включать наблюдение в обучающую выборку. Таким образом, при появлении нового наблюдения высчитывалось $\Delta\tau^{(3)}$, и при достижении порогового значения наблюдение добавлялось в обучающую выборку, и значение $\Delta\tau^{(3)}$ для следующего наблюдения было близко к 0. Таким образом достигается более эффективная адаптации модели ВА к изменениям характеристик технологического объекта, что приводит к улучшению качества адаптивного ВА.

Также проведено сравнение предлагаемого, разработанного ранее ВА [7] и ВА на основе нейронных сетей с применением кластеризации при адаптации. На рис. 11 представлен график изменения значения MAE . Из данных графика можно увидеть, что значение MAE предлагаемого алгоритма ВА adapt-ACE-t в конечный момент времени на 6,6% и 14% меньше, чем у ВА adapt-ACE, разработанного ранее [7], и у ВА на основе нейронных сетей соответственно.

Рассмотрим подробнее интервал наблюдений 206–208 (рис. 11), в котором происходит увеличение MAE , и про-

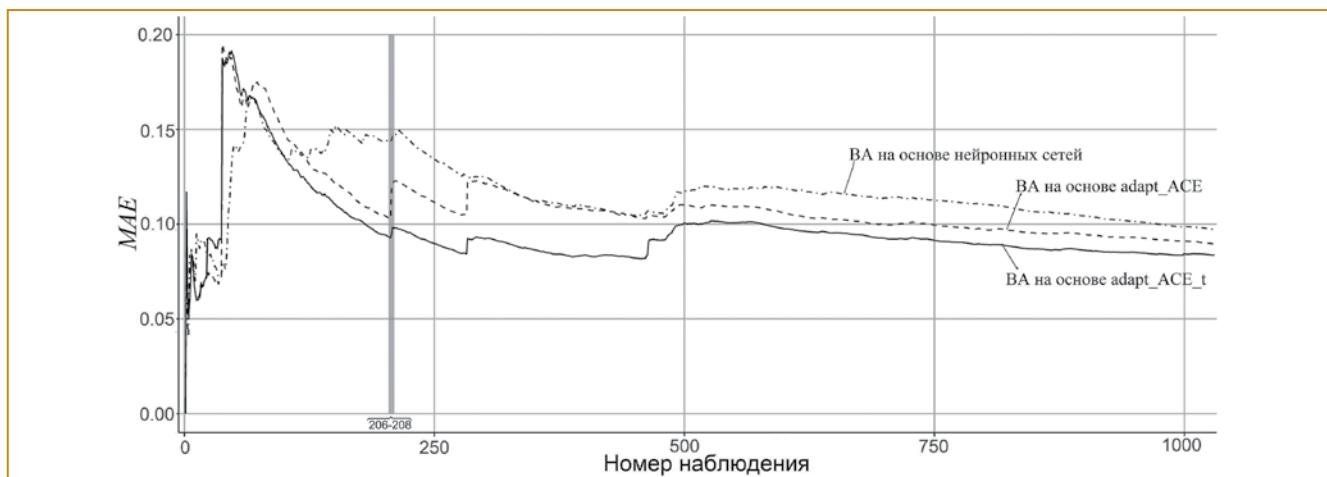


Рис. 11. Изменение значения MAE в ходе работы предлагаемого алгоритма работы ВА adapt-ACE-t, алгоритма работы ВА adapt-ACE [7] и ВА на основе нейронных сетей

анализируем причину наименьшего возрастания ошибки у предложенного алгоритма ВА adapt-ACE-t.

На рис. 12 представлены графики значений входной переменной (на примере u_9), включенных в обучающую выборку при работе алгоритмов adapt-ACE и adapt-ACE-t. Точки на графиках отображают значения входной переменной, добавленные на 207 и 208 шагах работы алгоритмов, из-за которых прошел резкий рост MAE . Заметим, что последние значения входной переменной выходят за пределы уже имеющегося набора данных. Отличие заключается в том, что у ВА с учетом фактора времени объем обучающей выборки больше, что в перспективе оказалось причиной более точной аппроксимации оптимальных преобразований в условиях появления новых наблюдений входных переменных, выходящих за существующий диапазон данных в обучающей выборке.

На рис. 13 представлены графики функций аппроксимации оптимальных преобразований на 206, 207 и 208 шагах работы алгоритмов adapt-ACE-t (рис. 13а) и adapt-ACE (рис. 13б) с выделением зоны (серый цвет) между функциями оптимальных преобразований для 206 и 208 наблюдений, отображающих отличия функции аппроксимации на разных шагах. Чем больше площадь вы-

деленной зоны, тем больше различия между функциями аппроксимаций для 206 и 208 шагов работы.

На рис. 13 также видно, что выделенная серым цветом зона для алгоритма adapt-ACE больше, чем для алгоритма adapt-ACE-t. Таким образом, аппроксимированные оптимальные преобразования (на шаге 206) входных переменных в ходе работы ВА adapt-ACE-t оказываются ближе к «истинным» оптимальным преобразованиям, которые наблюдаем на шаге 208.

Заключение

Предложен модифицированный алгоритм работы адаптивного ВА на основе ACE с применением кластеризации и учетом фактора времени. Учет фактора времени при оценке необходимости обновления модели ВА позволил снизить значение MAE в конечный момент времени на 6,6% по сравнению с предложенным ранее адаптивным ВА на основе ACE, функционирующим по методу MW с применением кластеризации для оценки необходимости обновления модели ВА.

Проведено сравнение использования алгоритма ACE и нейронных сетей при построении ВА. По результатам исследования выяснилось, что при построении модели




Рис. 12. Значения переменной u_9 входящих в обучающие выборки для ВА adapt-ACE-t и adapt-ACE




Рис. 13. Графики функций аппроксимаций оптимальных преобразований на 206, 207 и 208 шагах при появлении новых наблюдений алгоритмов *adapt-ACE-t* (а) и *adapt-ACE* (б)

на основе ACE получены более качественные модели при меньшем объеме обучающей выборки, чем у моделей на основе нейронных сетей. Значение *MAE* предлагаемого алгоритма *BA adapt-ACE-t* в конечный момент времени на 14% меньше, чем у *BA* на основе нейронных сетей.

Список литературы

1. Wang S., Murphy M. Estimating optimal transformations for multiple regression using the ACE algorithm // *Journal of Data Science*. 2004. Vol. 2. P. 329–346
2. AL-Qutami, T.A., Ibrahim, R., Ismail, I., Ishak, M.A. Development of soft sensor to estimate multiphase flow rates using neural networks and early stopping // *International Journal on Smart Sensing and Intelligent Systems* // 2017. Vol. 10. P. 199–222
3. Zheng, W., Liu, Y., Gao, Z., Yang, J. Just-in-time semi-supervised soft sensor for quality prediction in industrial rubber mixers // *Chemometrics and Intelligent Laboratory Systems*. 2018. Vol. 180. P. 36–41
4. Xiong, W., Li, Y., Zhao, Y., Huang, B. Adaptive soft sensor based on time difference Gaussian process regression with local time-delay reconstruction // *Chemical Engineering Research and Design*. 2017. Vol. 117. P. 670–680
5. Yao, L., Ge, Z. Moving window adaptive soft sensor for state shifting process based on weighted supervised latent factor analysis // *Control Engineering Practice*. 2017. Vol. 61. P. 72–80.
6. Pan, T.-H., Wong, D. S.-H., Jang, S.-S. Development of a novel soft sensor using a local model network with an adaptive subtractive clustering approach // *Industrial & Engineering Chemistry Research*. 2010. Vol. 49(10). P. 4738–4747
7. Снегирев О.Ю., Торгашов А.Ю. Разработка адаптивных виртуальных анализаторов для промышленных ректификационных колонн с применением кластеризации // *Автоматизация в промышленности*. 2020. № 8. С. 44–50.
8. Можаровский И.С., Самотылова С.А., Торгашов А.Ю. Предсказательное моделирование массообменного технологического объекта с использованием алгоритма чередующихся условных математических ожиданий // *Математическое моделирование*. 2020. Т.32. № 3. С. 127–147.
9. Жирков В.Ф., Сушкова Л.Т., Королев А.И., Большаков К.Н., Обеднин А.А., Прокофьев Г.В. Полиномиальная интерполяция в цифровой обработке сигналов при высоких требованиях к точности. // *Журнал радиоэлектроники [электронный журнал]*. 2017. №4. С. 1–22.
10. Willmott, C., Matsuura, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance // *Climate Research*. 2005. Vol. 30. P. 79–82

Снегирев Олег Юрьевич – младший научный сотрудник,
Торгашов Андрей Юрьевич – д-р техн. наук, зав. лабораторией систем управления технологическими процессами
 ФГБУН «Институт автоматизации и процессов управления Дальневосточного отделения РАН.
 E-mail: torgashov@iacp.dvo.ru

Поступила в редакцию 11.01.2021. Принята к публикации 9.03.2021