



РАЗРАБОТКА АДАПТИВНЫХ ВИРТУАЛЬНЫХ АНАЛИЗАТОРОВ ДЛЯ ПРОМЫШЛЕННЫХ РЕКТИФИКАЦИОННЫХ КОЛОНН С ПРИМЕНЕНИЕМ КЛАСТЕРИЗАЦИИ

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

Рассматривается решение задачи построения адаптивных виртуальных анализаторов с использованием методов кластеризации на примере реакционно-ректификационного технологического процесса производства метил-трет-бутилового эфира и ректификационных колонн установки первичной переработки нефти. Методы кластеризации предлагается использовать для оценки целесообразности обновления параметров модели. Предложен и протестирован на промышленных данных алгоритм функционирования адаптивного виртуального анализатора с применением «движущегося окна» и кластеризации. Проведено исследование зависимости точности показаний виртуального анализатора от ширины окна обучающей выборки и рассмотрены критерии для выбора оптимального значения ширины окна. Показано преимущество предложенного адаптивного виртуального анализатора с кластеризацией по точности и по временным затратам для пересчета параметров модели, по сравнению с традиционным подходом к адаптации параметров модели на каждом шаге.

Ключевые слова: виртуальный анализатор, адаптация, кластеризация, метод чередующихся условных математических ожиданий, первичная переработка нефти, реакционно-ректификационный процесс.

Введение

В настоящее время при оценке качества выходных продуктов ректификационных колонн используются данные аналитического (лабораторного) контроля, а также поточных анализаторов. Однако результаты анализов, получаемых в заводских лабораториях, не всегда обладают необходимым уровнем оперативности, поэтому не могут использоваться для управления качеством в реальном времени. Для решения данной проблемы на производстве используют виртуальные анализаторы (ВА) [1], позволяющие оценить качество выходных продуктов по результатам измерений технологических переменных (расходы потоков, температура, давление и др.) и входящие в структуру систем усовершенствованного управления технологическими процессами (СУУТП) [2]. В связи с изменением во времени параметров большей части промышленных технологических процессов нефтепереработки и нефтехимии, для более точного оценивания показателей качества их выходных продуктов, следует периодически подстраивать параметры ВА.

Существуют различные подходы к разработке адаптивных ВА: метод движущегося окна, рекурсивные методы адаптации и многомодельные методы [3]. Принцип работы адаптивного ВА по методу «движущегося окна» заключается в том, что, при появлении нового наблюдения, пересчитываются параметры модели для оценки выходной переменной на основе обучающей выборки, из которой на каждом шаге убирается самое раннее наблюдение и добавляется новое [4]. Рекурсивные методы используют текущую

модель и только одно новое наблюдение для обновления модели. Адаптация включает в себя понижение веса предыдущей модели с помощью фактора забывания. Рекурсивные методы имеют те же проблемы с оценкой параметров, что и метод движущегося окна. Подобно методу движущегося окна, рекурсивный способ обновления параметров модели также не обеспечивает никакого механизма для обнаружения изменений технологического объекта, если только скорость затухания не будет адаптирована в соответствии со скоростью изменения характеристик объекта. Тем не менее, существуют некоторые методы адаптивной настройки фактора забывания [4].

Многомодельный подход к адаптации основан на построении некоторого числа регрессионных моделей для оценки показателя качества продукта [5]. Далее происходит комбинирование данных оценок и вычисляется финальная оценка выходной переменной. Наиболее простой и часто используемый метод вычисления — поиск среднего значения оценок выхода, полученных на множестве моделей. Однако более предпочтительно использовать взвешенное комбинирование — метод, при котором для каждой модели оценки выхода назначается свой вес, а итоговое значение выходной переменной ВА определяется в результате взвешенного суммирования выходов каждой модели. Данный метод обеспечивает большую гибкость, но теоретическое обоснование выбора весов для каждого выхода модели остается пока не исследованным.

В данной статье представлен новый подход к разработке адаптивных ВА с применением «движущегося

окна», отличающийся использованием алгоритмов кластеризации для определения целесообразности обновления параметров модели. Также предложенный метод построения адаптивного ВА обладает простотой и удобством для понимания и реализации его на производстве.

Математическая модель в составе виртуального анализатора

Применение множественной регрессии в составе ВА требует априорного допущения об известной структуре модели. Однако это допущение не всегда справедливо в реальных условиях. Использование непараметрических методов регрессии свободно от требования знать структуру 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) [6]. Регрессионная модель ACE имеет следующий вид:

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

где θ — функция выходной переменной Y , b_0 — свободный член, ϕ_i — функция входной переменной u_i , $i = 1, \dots, m$ — номер входной переменной.

Для оценки значения выходной переменной к обучающей выборке применяют алгоритм чередующихся условных математических ожиданий и получают

оптимальные преобразования выходной переменной от i -ой входной переменной. Затем для каждой входной переменной необходимо найти функцию $\phi_i(u_i)$ описывающую зависимость оптимальных преобразований от соответствующей входной переменной. В данной работе была использована полиномиальная аппроксимация оптимальных преобразований:

$$\phi_i(u_i) \approx \sum_{q=0}^{p_i} b_{(i,q)} u_i^q, \tag{2}$$

где p_i — максимальная степень полинома зависимости $\phi_i(u_i)$, $b_{(i,q)}$ — коэффициент при значении входной переменной u_i в степени $q = 0 \dots p_i$. После всех вышеописанных действий, подставляя полученные функции оптимальных преобразований (2) для каждой входной переменной в уравнение общего вида модели ACE (1), получим модель, которая функционирует в составе ВА с параметрами $\hat{B}_t = \{b_{0,t}, b_{(1,0),t}, \dots, b_{(1,p_1),t}, \dots, b_{(m,0),t}, \dots, b_{(m,p_m),t}\}$.

Разработка адаптивного виртуального анализатора с использованием кластеризации

Предлагаемый принцип работы адаптивного ВА с применением кластеризации схож с алгоритмом функционирования адаптивного ВА по методу «движущегося окна» с шириной окна h . На t -ом шаге ($t \in \{h+1, \dots, N\}$) на основе обучающей выборки, содержащей с $t-h+1$ по t наблюдения входных и выходной переменных, строится регрессионная модель на основе ACE и дальнейшей полиномиальной аппроксимацией (2) с параметрами \hat{B}_t . Затем полученная

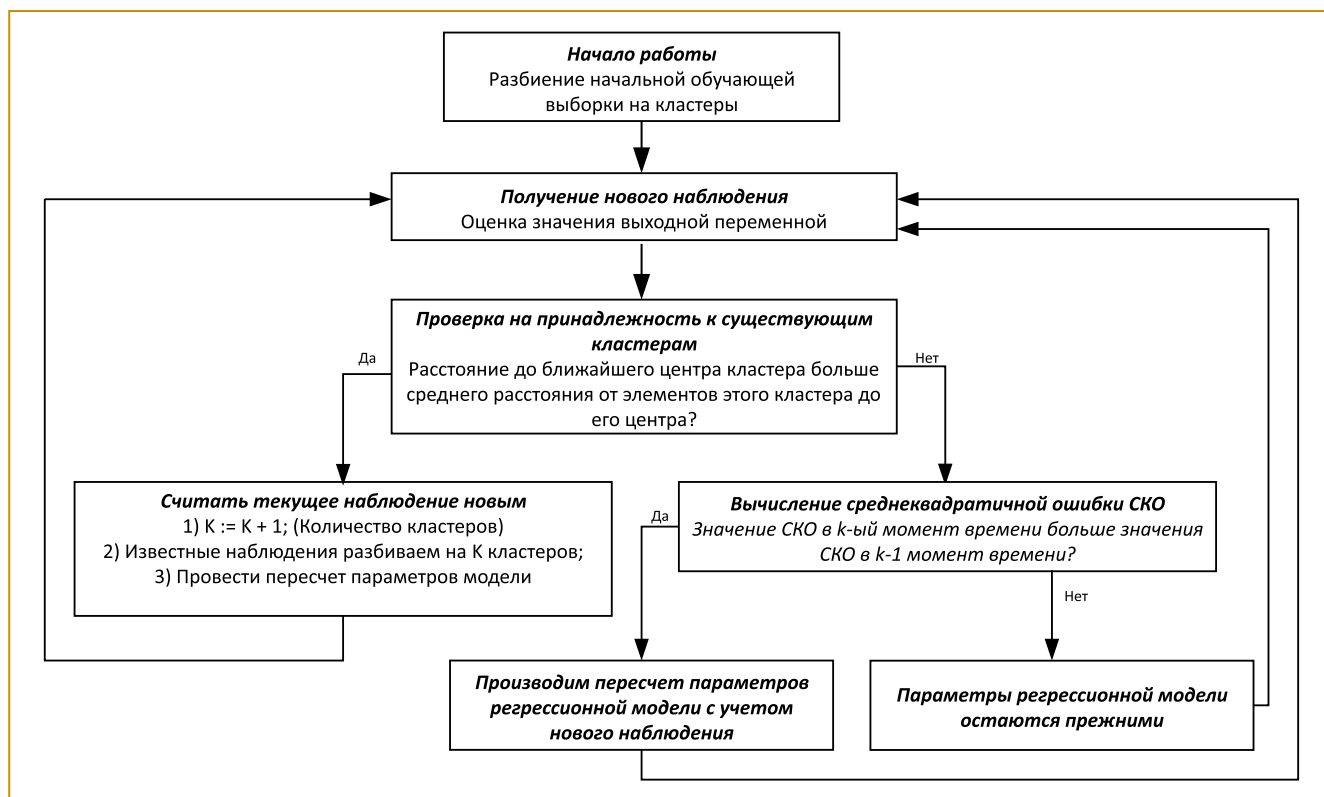


Рис. 1. Алгоритм работы адаптивного ВА с использованием кластеризации




Рис. 2. Значение отношения суммы внутрикластерных расстояний к сумме межкластерных расстояний в зависимости от значения K_0

модель используется для оценивания значения выходной переменной на $t+1$ шаге по полученным значениям входных переменных $\{u_{1,t+1}, \dots, u_{m,t+1}\}$.

При получении нового измеренного значения выходной переменной в обучающую выборку ВА включают $(t+1)$ наблюдение и исключают $(t+1-h)$ наблюдение выходной и входных переменных. Далее рассчитывается оценка оптимальных преобразований для регрессионной модели для новой обучающей выборки. Предлагаемый адаптивный ВА отличается тем, что с помощью методов кластеризации определяет необходимость обновления параметров регрессионной модели для прогнозирования значения выходной переменной на $t+1$ шаге. Алгоритм работы адаптивного ВА, использующего методы кластеризации, представлен на схеме рис. 1. Следует отметить, параметры модели в составе адаптивного ВА пересчитываются не на каждом шаге работы, а лишь при детекции нового состояния технологического объекта или при росте значения среднеквадратической ошибки оценки значения выходной переменной.

Для разбиения данных обучающей выборки (ОВ) на кластеры был использован алгоритм k -means [7], который разбивает множество наблюдений U на K наборов S_1, S_2, \dots, S_K , таким образом, чтобы минимизировать сумму квадратов расстояний от каждой точки кластера до его центра. Действие алгоритма k -means равносильно поиску:

$$\arg \min_S \sum_{k=1}^K \sum_{u \in S_k} \rho(u, \mu^{(k)})^2,$$

где $\mu^{(k)}$ — центр k -ого кластера, $\rho(u, \mu^{(k)})$ — функция расстояния между u и $\mu^{(k)}$.

На начальном этапе выбирается множество точек $\mu^{(k)}$, $k=1, \dots, K$, рассматриваемых как начальные центры кластеров $\mu_0^{(k)} = \mu^{(k)}$, $k=1, \dots, K$. Затем распределяются наблюдения по кластерам и происходит пересчет центров кластеров $\mu_t^{(k)} = \frac{1}{|S_k|} \sum_{u \in S_k} u$. Данный алгоритм действует

до тех пор, пока центры кластеров в настоящий момент времени не будут совпадать с центрами кластеров в предыдущий момент $\mu_t^{(k)} = \mu_{t-1}^{(k)}$. Так как для алгоритма k -means число кластеров K задается пользователем, то одним из параметров разработанного ВА является начальное число кластеров K_0 . Для выбора значения K_0 начальный набор из 30 наблюдений разбивался на различное число кластеров (в диапазоне 2...25 ед.) методом k -means, затем для каждого случая вычислялась сумма средних внутрикластерных расстояний:

$$\Phi_0 = \sum_{k=1 \dots K} \frac{1}{|S_k|} \sum_{u \in S_k} \rho^2(u, \mu^{(k)}),$$

где $|S_k|$ — число элементов в k -ом кластере S_k . Более эффективное разбиение на кластеры будет при том значении K_0 , для которого значение Φ_0 будет меньше. Также для каждого случая вычислялась сумма меж-

кластерных расстояний: $\Phi_1 = \sum_{k \in 1 \dots K} \rho^2(\mu^{(k)}, \mu)$. Более эф-

фективное разбиение на кластеры будет при том значении K_0 , для которого значение Φ_1 будет больше.

Для учета как межкластерных, так и внутрикластерных расстояний вычисляется отношение Φ_0 к Φ_1 [8]. На рис. 2 представлен график зависимости отношения суммы внутрикластерных расстояний к сумме межкластерных расстояний от значения начального числа кластеров K_0 . В качестве начального было принято значение числа кластеров, при котором $\Phi_0/\Phi_1 < 0,15 \times \max(\Phi_0/\Phi_1)$ [9].

После разбиение начальной ОВ на кластеры начинается основной процесс работы адаптивного ВА. Поступают измеренные значения технологических переменных и лабораторного анализа, и адаптивный ВА определяет встречалось ли текущее состояние объекта ранее. Для выяснения, является ли текущее наблюдение состоянием объекта новым, ранее не встречающимся, начальный набор наблюдений разбивается на кластеры, находятся координаты центров кластеров, а затем для последнего наблюдения предложено вычислять нормированные расстояния l_t до центров кластеров:

$$l_t = \sqrt{\sum_{i=1}^m (\tilde{u}_{i,t} - \tilde{\mu}_{i,t})^2},$$

где $\tilde{u}_{i,t}$ — нормированное значение i -ой входной переменной в момент времени t , $\tilde{\mu}_{i,t}$ — нормированное значение центра кластера по i -ой входной переменной в момент времени t . Если расстояние до центра кластера больше определенного расстояния (в данном исследовании было принято расстояние, равное половине максимального расстояния от наблюдений, входящих в кластер, до центра кластера), то можно считать, что последнее наблюдение не принадлежит данному кластеру. Для признания наблюдения новым необходимо, чтобы наблюдение не принадлежало ни одному из известных кластеров.

Так как параметры технологического объекта могут изменяться со временем, происходит устаревание

модели, т. е. при уже встречающемся ранее состоянии технологического объекта можно получить некорректную оценку качества выходного продукта, используя модель с текущими параметрами. Во избежание некорректной работы адаптивного ВА, при отсутствии новых состояний технологического объекта производится расчет средней абсолютной ошибки (MAE). Если при использовании текущих параметров модели для оценки качества выходного продукта по наблюдению состояния объекта, которое ранее встречалось, значение MAE будет расти, тогда можно предположить, что параметры объекта изменились, и следует пересчитать параметры модели оценки качества выходного продукта. Для разрабатываемого адаптивного ВА с применением кластеризации необходимо знать значение ширины окна h , на основе которого происходит формирование выборки для вычисления параметров регрессионной модели. В реальных условиях часто используют следующее правило для определения ширины окна обучающей выборки (h_0):

$$h_0 = m \cdot 10,$$

где m — число входных переменных модели.

Для выбора оптимального значения ширины окна ВА можно использовать критерий, отражающий качество адаптивного ВА через MAE прогноза значения выходной переменной на один такт:

$$J_{MAE} = \frac{1}{N - M} \sum_{t=M+1}^N |y_t - \hat{y}_t|_{\hat{b}_{t-1}^h}, \quad (3)$$

где y_t — значение выходной переменной в t момент времени; $\hat{y}_t|_{\hat{b}_{t-1}^h}$ — прогноз значения выходной переменной в t -ый момент времени на основе модели с вектором параметров \hat{b}_{t-1}^h . Оптимальной ширине окна ВА будет соответствовать ширина окна, при которой значение критерия ошибки прогнозирования будет минимальным.

При выборе оптимального значения ширины окна ВА можно также использовать критерий, учитывающий коэффициент детерминации R^2 :

$$J_{R^2} = 1 - R^2 = \frac{\sum_{t=M+1}^N (y_t - \hat{y}_t|_{\hat{b}_{t-1}^h})^2}{\sum_{t=M+1}^N (y_t - \bar{y})^2}, \quad (4)$$

где \bar{y} — среднее арифметическое значений выходной переменной. Оптимальной ширине окна ВА будет соответствовать ширина окна, при которой значение критерия J_{R^2} будет минимальным.

Для выбора оптимальной ширины окна адаптивного ВА можно использовать также критерий отражающий изменчивость параметров регрессионной модели в течение передвижения «окна» с обучающей выборкой по ряду данных. Для определения изменчивости параметров регрессионной модели используется среднее квадратическое отклонение оценок параметров модели:

$$S_{\hat{b}_{(i,q)}^h} = \sqrt{\frac{1}{N - M} \sum_{t=M+1}^N (\hat{b}_{(i,q),t}^h - \bar{b}_{(i,q)}^h)^2},$$

где $\hat{b}_{(i,q),t}^h$ — (i,q) -ый параметр модели аппроксимации оптимальных преобразований выходной переменной в t -ый момент времени при ширине окна ВА h , $\bar{b}_{(i,q)}^h$ — среднее арифметическое значений (i,q) -ого параметра регрессионной модели при передвижении ВА с шириной окна h .

В качестве еще одного критерия выбора оптимального значения ширины окна рассмотрим сумму среднеквадратических отклонений оценок параметров модели (критерий изменчивости всех параметров модели ВА):

$$J_{\hat{b}} = \sum_{i=0}^m \sum_{q=0}^{n_i} S_{\hat{b}_{(i,q)}^h}. \quad (5)$$

В настоящей работе предлагается также рассматривать векторный критерий (свертка критериев):

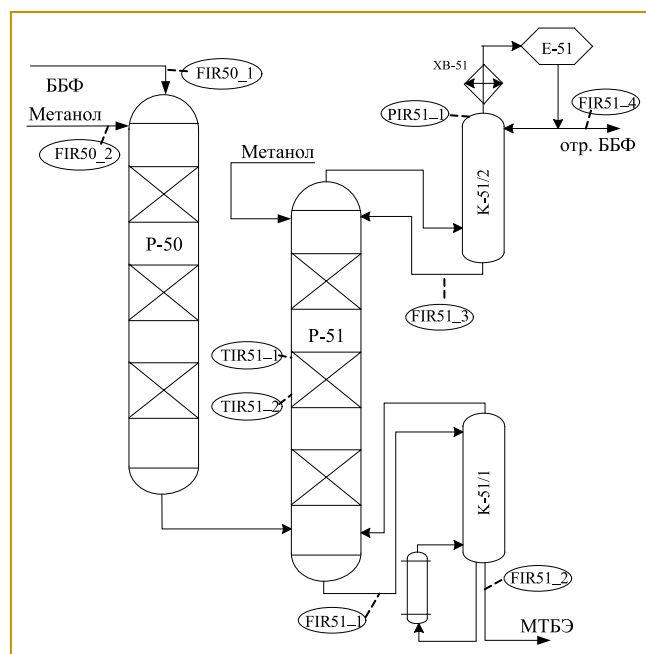
$$J = \tilde{J}_{MAE} + \tilde{J}_{R^2} + \tilde{J}_{\hat{b}}, \quad (6)$$

где $\tilde{J}_{(\cdot)}$ — нормированное значение соответствующего критерия в относительных единицах.

Тестирование предложенного адаптивного ВА с кластеризацией

Для тестирования выбраны два технологических объекта: реакционно-ректификационный процесс (РРП) производства метил-трет-бутилового эфира (МТБЭ) и атмосферный блок установки первичной переработки нефти. Разработанный алгоритм функционирования адаптивного ВА с использованием кластеризации опробован на исторических данных выбранных объектов. Проведено сравнение значений средней абсолютной ошибки (MAE) и временных затрат на адаптацию ВА в ходе испытания.

Реакционно-ректификационный технологический процесс производства метил-трет-бутилового эфира



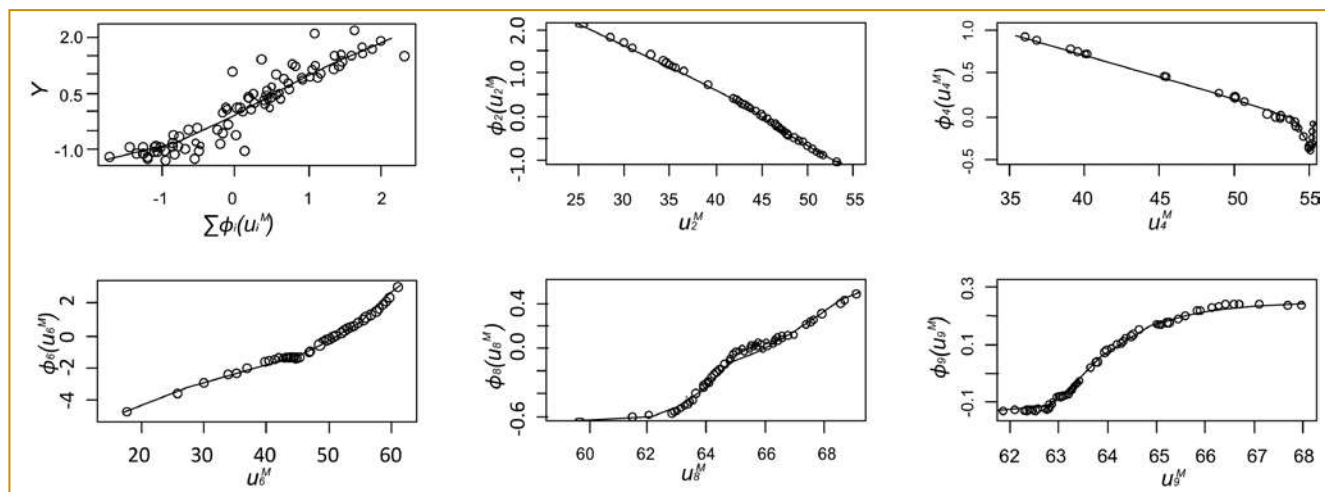


Рис.4. Графики зависимости функций $\varphi_i(u_i)$ от значения входной переменной u_i для ВА по содержанию МВБЭ в выходном продукте РРП

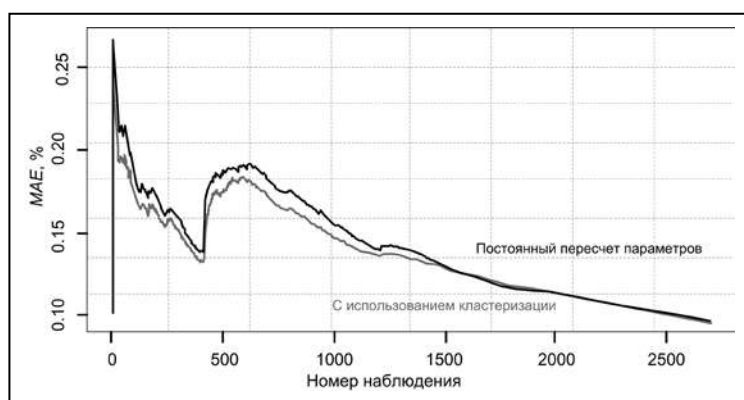


Рис.5. График изменения MAE работы ВА по содержанию МВБЭ в выходном продукте РРП

Особенность РРП заключается в совместном протекании обратимой химической реакции с частичным или практически полным разделением образующейся реакционной смеси веществ посредством ее ректификации. Продуктом РРП является МТБЭ, который получил широкое применение в производстве высокооктановых бензинов. Для его получения используются метанол и изобутилен, поступающий

с бутан-бутиленовой фракцией (ББФ). Схема технологической установки получения МТБЭ представлена на рис. 3. Частичная реакция синтеза МТБЭ происходит в прямоточном реакторе форконтакта (Р-50) и в реакционно-ректификационном аппарате, представляющим собой две ректификационные колонны (К-51/1 и К-51/2) и расположенный между ними реактор синтеза (Р-51). Реакционная смесь из реактора Р-51 выводится двумя потоками: сверху реактора отбирается газовая фаза; снизу реактора отбирается жидкая фаза, каждая из которых идет на дальнейшее разделение. Ключевым показателем качества выходного продукта РРП является концентрация (% масс.) в нем примесей в виде метил-втор-бутилового эфира (МВБЭ). Рассматривается задача построения ВА по содержанию МВБЭ. В качестве регрессоров использовались следующие измеряемые технологические параметры: u_1^M — расход МТБЭ (FIR51_2); u_2^M — расход отработанной ББФ (FIR51_4); u_3^M — расход ББФ в Р-50 (FIR50_1); u_4^M — расход орошения К-51/2 (FIR51_3); u_5^M — расход метанола на форконтакт (FIR50_1); u_6^M — расход реак-

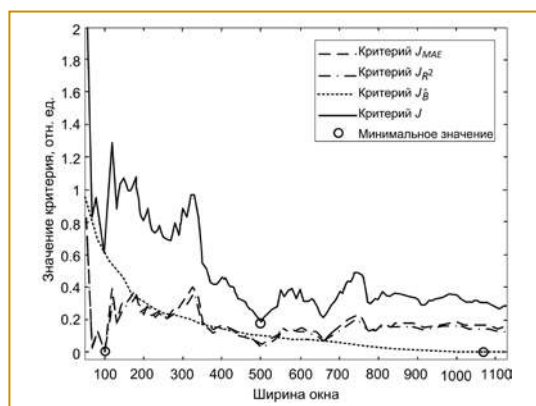


Рис.6. Значения критериев для выбора оптимальной ширины окна адаптивного ВА

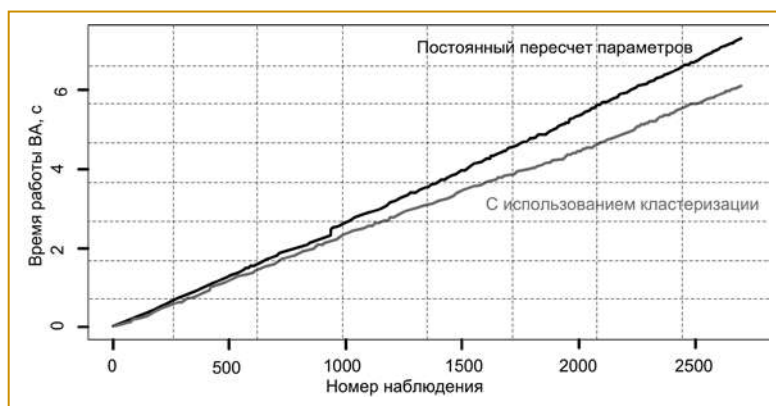


Рис.7. Сравнение временных затрат на адаптацию ВА по содержанию МВБЭ в выходном продукте РРП

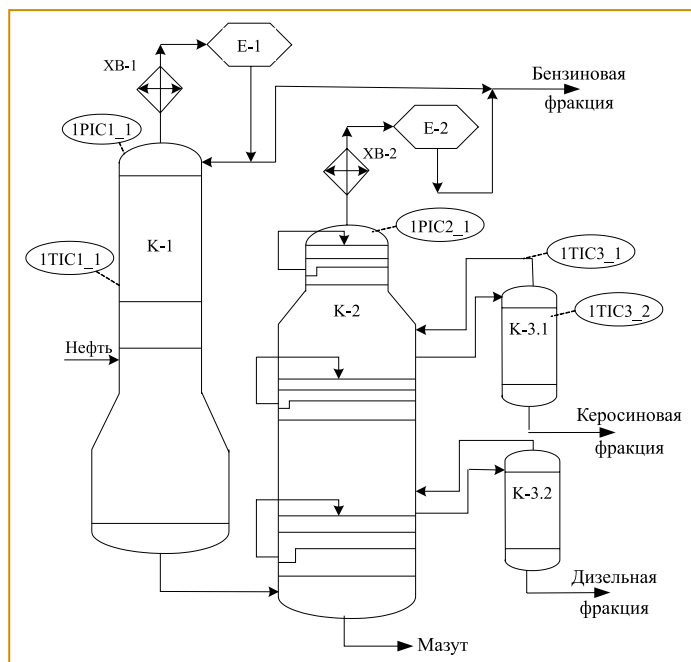


Рис. 8. Технологическая схема атмосферного блока установки первичной переработки нефти

ционной массы, поступающей в K-51/1 (FIR51_1); u_7^M — давление верха K-51/2 (PIR51_1); u_8^M — температура в среднем слое катализатора P-51 (TIR51_1); u_9^M — температура в среднем слое катализатора P-51 (TIR51_2). На основе имеющихся данных построена регрессионная модель, используя алгоритм ACE [10]. На рис. 4 представлен график зависимости значения выходной переменной ВА Y от $\sum \phi_i(u_i^M)$.

На рис. 5 представлено сравнение значения MAE в ходе испытания для ВА, работающего по методу «движущегося окна», и разработанного адаптивного ВА с кластеризацией. Анализируя данный график, можно увидеть, что в ходе испытания значение MAE для разработанного алгоритма было ниже. На 2700-м шаге преимущество предлагаемого метода составляет 1,6%.

На рис. 6 представлены график изменения значений критериев (3)- (6) от ширины окна адаптивного ВА по концентрации МВБЭ и отмечены значения ширины окна, для которых значения критериев минимальны.

При исследовании различных критериев выбора оптимальной ширины окна адаптивного ВА, было установлено, что критерии J_{MAE} и J_R^2 имеют схожее поведение, их оптимальные значения совпадают при одном и том же значении ширины движущегося окна. Критерий изменчивости параметров является убывающей функцией, его оптимальное значение наблюдается при ширине окна близкой к верхней границе интервала. Векторный критерий выражает компромисс между критериями и может быть использован, если при выборе оптимального значения ширины окна ставится условие учета изменчивости параметров во время функционирования адаптивного ВА. Таким образом, оптимальное значение ширины окна для рассматриваемого технологического объекта равно 100.

На рис. 7 представлено сравнение временных затрат на адаптацию ВА с постоянным пересчетом параметров модели и с использованием кластеризации. На 2700-м шаге преимущество по быстродействию адаптации предлагаемого ВА составляет 19,1%.

Атмосферный блок установки первичной переработки нефти

В ходе процесса первичной переработки нефти осуществляется разделение нефтяного сырья на фракции, различающиеся по интервалам температур кипения. Рассматривается атмосферный блок установки первичной переработки нефти (рис. 8). Нефтяное сырье поступает в отбензинивающую колонну (K-1), в которой верхним продуктом отбирается основная часть бензиновой фракции. Отбензиненная нефть с куба K-1 поступает в атмосферную колонну (K-2), в которой разделяется на бензиновую, керосиновую, дизельную фракции и мазут. В верхней части K-2 также

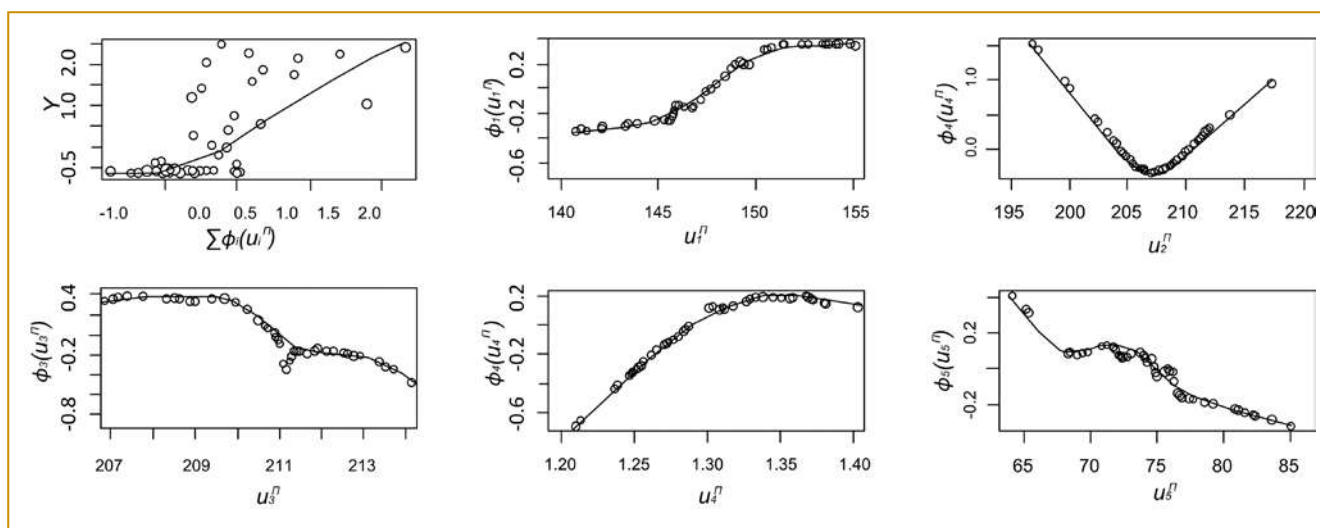


Рис.9. Зависимости функций $\phi_i(u_i)$ от значений входных переменных u_i для ВА ТКК БФ

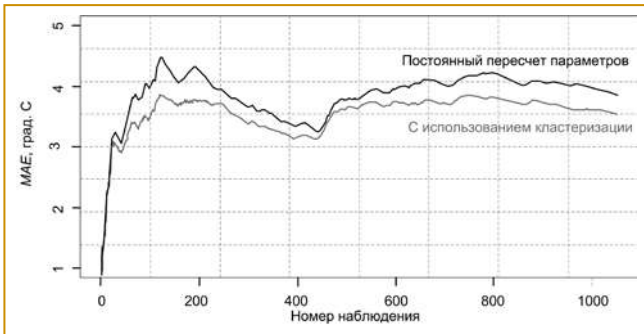


Рис. 10. Сравнение MAE адаптивных ВА по ТКК БФ



Рис. 11. Сравнение временных затрат на адаптацию ВА по ТКК БФ

отбирается бензиновая фракция и смешиваясь с бензиновой фракцией из К-1 выходит с установки. Задача заключается в построении ВА по температуре конца кипения (ТКК) смеси бензиновой фракции (БФ) из К-1 и К-2. В качестве регрессоров использовались измеряемые технологические параметры: u_1^n — температура подаваемого сырья (1TIC1_1); u_2^n — температура потока из К-3.1 в К-2 (1TIC3_1); u_3^n — температура в К-3.1 (1TIC3_2); u_4^n — давление верха К-2 (1PIC2_1); u_5^n — давление верха К-1 (1PIC1_1). На рис. 9 представлены полученные с помощью алгоритма АСЕ зависимости $\phi_i(u_i^n)$ от u_i^n , а также зависимость значения Y выходной переменной (ТКК БФ) от $\sum \phi_i(u_i^n)$.

Рис. 10 содержит результаты сравнительного анализа значений MAE для ВА, работающего по методу «движущегося окна» и адаптивного ВА с кластеризацией. Установлено, что на 1100-м шаге преимущество предлагаемого ВА составляет 8.4% с точки зрения снижения MAE.

Анализ временных затрат, необходимых для вычисления выходной переменной адаптивного ВА, показал, что на 1100-м шаге преимущество предложенного ВА составляет 11.9% (рис. 11) с точки зрения вычислительных ресурсов.

Заключение

Основным результатом работы является новый подход к построению адаптивных ВА с использова-

нием кластеризации, который позволил решить следующие важные задачи с точки зрения промышленной эксплуатации систем управления с ВА:

— уменьшение временных затрат на адаптацию моделей ВА;

— снижение риска адаптации ВА на данные, которые могут содержать ошибки измерений или данные нестандартных производственных ситуаций, так как использование кластеризации позволяет более качественно подойти к формированию обучающей выборки.

Разработаны адаптивные ВА, основанные на методе «движущегося окна», использующие в ходе работы алгоритм кластеризации k-means. На основе исторических данных двух технологических установок было показано преимущество перед адаптивными ВА, функционирующими по методу «движущегося окна» с постоянным пересчетом параметров модели. Увеличение точности (уменьшение MAE) адаптивных ВА может быть достигнуто в среднем на 5%, а сокращение времени для пересчета параметров модели (адаптации) и расчета показаний ВА составляет в среднем 15%.

Список литературы

1. Torgashov A., Skogestad S. The use of first principles model for evaluation of adaptive soft sensor for multicomponent distillation unit // Chemical Engineering Research and Design. — 2019. — v. 151. — P. 70-78.
2. Дозорцев В.М., Ицкович Э.П., Кнеллер Д.В. Усовершенствованное управление технологическими процессами (APC): 10 лет в России // Автоматизация в промышленности. 2013. №1. С. 12-19.
3. Kaneko H., Funatsu K. Moving window and just-in-time soft sensor model based on time differences considering a small number of measurements // Industrial & Engineering Chemistry Research. 2015. Vol. 54(2). P. 700-704.
4. Kadlec P., Grbic R., Gabrys B. Review of adaptation mechanisms for data-driven soft sensors // Computers and Chemical Engineering. 2011. Vol. 35. P. 1-24.
5. Shao W., Tian X. Adaptive soft sensor for quality prediction of chemical processes based on selective ensemble of local partial least squares models // Chemical Engineering Research and Design. 2015. Vol. 95. P. 113-132.
6. Hengl D., Kreuz C., Timmer J., Maiwald T. Data-based identifiability analysis of non-linear dynamical models // Bioinformatics. 2007. Vol. 23 No. 19. P. 2612-2618.
7. Алгоритм k средних (k-means) // AlgoWiki URL: [http://algorithms-wiki-project.org/ru/Алгоритм_k_средних_\(k-means\)](http://algorithms-wiki-project.org/ru/Алгоритм_k_средних_(k-means)).
8. Воронцов К.В. Лекции по алгоритмам кластеризации и многомерного шкалирования // <http://www.ccas.ru/voron/download/Clustering.pdf>, раздел 1.1.2.
9. Шитиков В.К., Мاستицкий С.Э. Классификация, регрессия, алгоритмы Data Mining с использованием R. — Электронная книга. 2017. Адрес доступа: <https://github.com/ranalytics/data-mining>, раздел 10.1.
10. Wang S., Murphy M. Estimating optimal transformations for multiple regression using the ACE algorithm // Journal of Data Science. 2004. Vol. 2. P. 329-346.

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 11.06.2020

Принята к публикации 30.07.2020