

УДК 681.5.011

РАЗРАБОТКА АДАПТИВНОГО ВИРТУАЛЬНОГО АНАЛИЗАТОРА ПОКАЗАТЕЛЕЙ КАЧЕСТВА ПРОМЫШЛЕННОГО ФРАКЦИОНАТОРА

О.Ю. Снегирев

Институт автоматики и процессов управления ДВО РАН
Россия, 690041, Владивосток, ул. Радио, 5
E-mail: snegirevoleg@iacp.dvo.ru

Д.В. Штакин

Институт автоматики и процессов управления ДВО РАН
Россия, 690041, Владивосток, ул. Радио, 5
E-mail: shtakin@iacp.dvo.ru

В.В. Климченко

Институт автоматики и процессов управления ДВО РАН
Россия, 690041, Владивосток, ул. Радио, 5
E-mail: volk@iacp.dvo.ru

Ключевые слова: виртуальный анализатор, адаптация, кластеризация, распределение выборки.

Аннотация: Решается задача повышения точности оценки показателя качества выходного продукта промышленного фракционатора за счет применения адаптивного виртуального анализатора с кластеризацией. Предлагаемый адаптивный виртуальный анализатор позволяет подстроить параметры модели к изменившимся характеристикам технологического процесса и сформировать обучающую выборку так, чтобы она содержала актуальные наблюдения всех возможных режимов работы технологической установки. Проведено сравнение и показано преимущество предложенного адаптивного виртуального анализатора с кластеризацией в сравнении с адаптивным виртуальным анализатором «движущегося окна».

1. Введение

Для эффективного управления технологическим процессом необходимо знать значения показателей качества выходных продуктов. В связи с тем, что значение лабораторного анализа выходного продукта может быть получено в среднем 1 раз в 12 часов, на нефтехимических производствах широкое применение получили виртуальные анализаторы (ВА), которые являются математическими моделями, оценивающими трудно измеряемые переменные на основании доступных измеряемых переменных процесса (температура, давление, расход и др.) [1].

Одной из особенностей нефтяных ректификационных технологических процессов является их нестационарность, что приводит к устареванию модели и снижению точности ВА со временем [2].

Для решения проблемы снижения точности ВА в связи с изменением характеристик процесса необходимо подстраивать параметры ВА к изменившимся условиям. Существуют различные методы адаптации виртуальных анализаторов [3].

Выделяют несколько основных подходов к адаптации: метод «движущегося окна» (Moving window) [4], рекурсивные методы (Recursive method), метод ансамбля моделей (Ensemble method) [5], метод «точно-в-срок» (Just-in-Time) [6] и другие.

В настоящей работе рассматривается адаптивный ВА с кластеризацией применительно к промышленному фракционатору.

2. Описание технологического процесса и постановка задачи

В качестве объекта исследований рассматривается колонна фракционирования. В колонне фракционирования С-1 происходит разделение поступающего сырья на нестабильную нефту, керосиновую, легкую и тяжелую дизельную фракции и непроконвертированный остаток. Колонна С-1 имеет три дополнительные боковые стриппинг колонны: колонну отпаривания керосина С-2, колонну отпаривания легкого дизтоплива С-3 и колонну отпаривания тяжелого дизтоплива С-4. На рис. 1. представлена технологическая схема фракционатора.

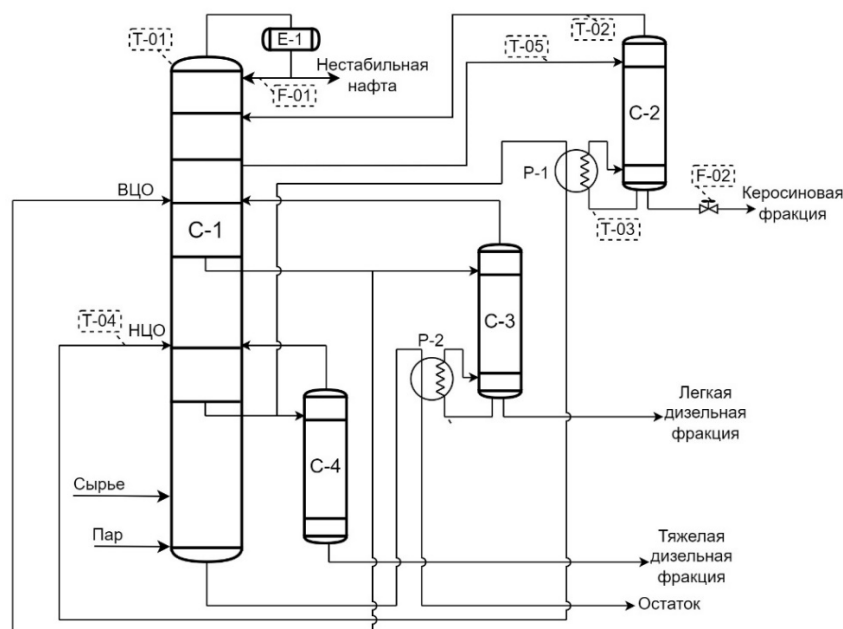


Рис. 1. Технологическая схема фракционатора.

Одним из показателей качества выходного продукта фракционатора является температура начала кипения керосиновой фракции (КФ). Для построения модели оценивания температуры начала кипения КФ в реальном времени, в качестве регрессоров использовались измеряемые технологические параметры: температура верха колонны С-1 (Т-01), расход орошения колонны С-1 (F-01), температура потока из С-2 в С-1 (Т-02), температура потока с низа С-2 в ребойлер Р-1 (Т-03), температура потока НЦО С-1 после ребойлера Р-1 (Т-04), расход керосина с установки (F-02), температура потока из С-1 в колонну С-2 (Т-05).

3. Предлагаемый алгоритм адаптивного виртуального анализатора с кластеризацией

В данной работе представлен модифицированный алгоритм адаптивного ВА на основе кластеризации, отличающийся от представленного ранее [7] тем, что при добавлении нового наблюдения в обучающую выборку, удаляется самое раннее наблюдение самого многочисленного кластера, а не всей выборки. Суть предлагаемого алгоритма адаптивного ВА заключается в том, что при появлении нового наблюдения u_t^* проводится поиск ближайшего кластера $S_{K_{\min\rho}}$, для которого

$K_{\min\rho} = \operatorname{argmin}_{k=1\dots K} \sqrt{\sum_{i=1}^m (u_{(n),i}^* - \mu_{(n),i}^{(k)})^2}$, где $\mu_{(n)}^{(k)}$ – нормированные координаты центра кластера k .

После того, как будет определен ближайший кластер, происходит проверка на удовлетворение следующих условий:

1. *Проверка достаточное ли количество наблюдений в кластере $S_{K_{\min\rho}}$.* В кластере должно быть не менее заданного числа наблюдений. Для примера взято значение $N_{K_{\min\rho}} > 7$.
2. *Проверка на принадлежность нового наблюдения кластеру $S_{K_{\min\rho}}$* путем сравнения расстояния от u_t^* до центра кластера $\mu^{(K_{\min\rho})}$ с максимальным расстоянием от элементов кластера до $\mu^{(K_{\min\rho})}$:

$$\sqrt{\sum_{i=1}^m (u_{(n),i}^* - \mu_{(n),i}^{(K_{\min\rho})})^2} < \max_{u \in S_{K_{\min\rho}}} \sqrt{\sum_{i=1}^m (u_{(n),i} - \mu_{(n),i}^{(K_{\min\rho})})^2}.$$

3. *Проверка качества оценки ВА с учетом нового наблюдения.* Для этого используется изменение САО работы ВА:

$$\Delta \text{САО} = \frac{N_{K_{\min\rho}} |y_t^* - F_{\text{ВА}}(u_t^*)| - \sum_{y, u \in S_{K_{\min\rho}}} |y_i^* - F_{\text{ВА}}(u_i)|}{N_{K_{\min\rho}} (N_{K_{\min\rho}} - 1)}.$$

4. *Проверка давности появления схожего наблюдения.* Для этого используется следующий показатель: $\Delta \tau^{K_{\min\rho}} = (t - \tau_{Q_{K_{\min\rho}}}^{K_{\min\rho}}) / \bar{T}^{K_{\min\rho}} < 1$, где t – момент времени наблюдения u_t^* , $\tau_{Q_{K_{\min\rho}}}^{K_{\min\rho}}$ – время появления последнего элемента кластера $S_{K_{\min\rho}}$, $\bar{T}^{K_{\min\rho}}$ – среднее значение вектора временных интервалов между появлениями наблюдений кластера $T^{K_{\min\rho}} = (\tau_1^{K_{\min\rho}} - \tau_0^{K_{\min\rho}}, \tau_2^{K_{\min\rho}} - \tau_1^{K_{\min\rho}}, \dots, \tau_Q^{K_{\min\rho}} - \tau_{Q-1}^{K_{\min\rho}})$.

В случае если все представленные условия удовлетворяются, то u_t^* не добавляется в обучающую выборку, и модель в составе ВА остается неизменной.

Если хотя бы одно из условий не удовлетворяется, происходит добавление в обучающую выборку наблюдения u_t^* , и удаление самого раннего наблюдения из самого многочисленного кластера $u_{\tilde{q}}^{K_{\max N}}$, где $K_{\max N} = \operatorname{argmax}_{k=1\dots K} N_k$ и $\tilde{q} = \operatorname{argmin}_{q=1\dots Q_{K_{\max N}}} \tau_q^{K_{\max N}}$.

В качестве показателей качества работы адаптивных ВА использовались средняя абсолютная ошибка (САО) и коэффициент детерминации (R^2).

На рис. 2 представлен график изменения САО в ходе функционирования адаптивного ВА «движущегося окна» и предлагаемого адаптивного ВА с кластеризацией. По графику видно, что до момента времени 05.10.2022 изменения САО были примерно равны, а после – САО предлагаемого адаптивного ВА с кластеризацией было меньше. Значение САО и R^2 для адаптивного ВА «движущегося окна» составило

2.8799 и 0.7455, а для предлагаемого адаптивного ВА с кластеризацией CAO и R^2 равны 2.6555 и 0.8182 соответственно.

На рис. 3 представлен график значений лабораторного контроля, выхода адаптивного ВА «движущегося окна» и адаптивного ВА с кластеризацией и выделен участок значений с 23.09.2022 по 13.10.2022. На графике видно, что выход адаптивного ВА «движущегося окна» в момент времени имеет большое отклонение от лабораторного контроля в сравнении с адаптивным ВА с кластеризацией.

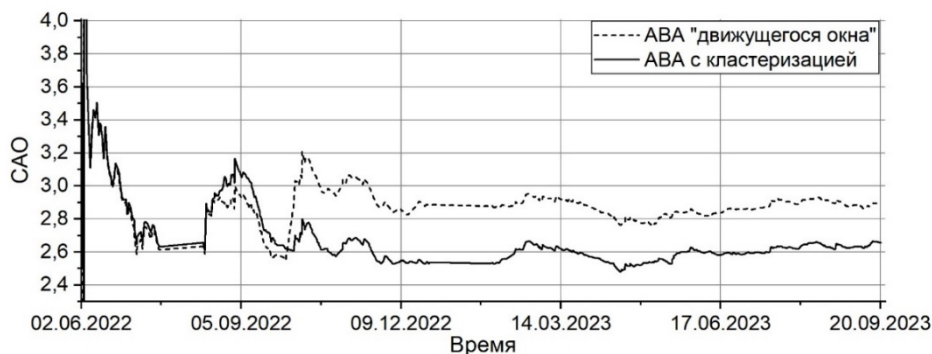


Рис. 2. Изменение CAO в ходе функционирования адаптивных ВА.

Это может быть связано с формированием обучающей выборки (ОВ) для построения модели в составе ВА. Адаптивный ВА «движущегося окна» использует в обучении заданное количество последних известных наблюдений. Адаптивный ВА с кластеризацией в ходе функционирования автоматически определяет необходимость добавления наблюдения в обучающую выборку и при добавлении убирает наблюдение из самого многочисленного кластера. Тем самым ОВ формируется более равномерно и содержит только «свежие» наблюдения.

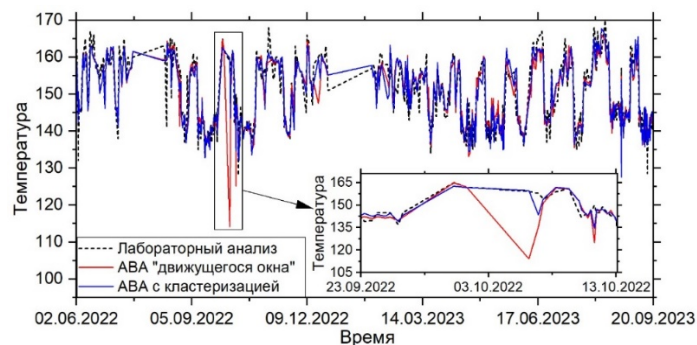


Рис. 3. Значения лабораторного анализа и оценок адаптивных ВА по температуре начала кипения КФ.

На рис. 4 представлено распределение некоторых входных переменных ОВ адаптивных ВА и отмечены значения входных переменных в моменты времени с 04.10.2022 по 06.10.2022. Из рис. 4 можно увидеть, что в ОВ адаптивного ВА с кластеризацией содержится больше наблюдений в интервале, в который попали отмеченные наблюдения, чем в ОВ адаптивного ВА «движущегося окна». Это означает, что модель в составе ВА, построенная по ОВ, которая содержит больше подобных наблюдений, более точно оценить значение выходной переменной при данных входных переменных.




Рис. 4. Распределение нормированных значений входных переменных входящих в обучающую выборку.

4. Заключение

В ходе данной работы был предложен модифицированный метод построения адаптивного ВА с кластеризацией, в ходе функционирования которого при добавлении нового наблюдения в обучающую выборку удаляется самое раннее наблюдение самого многочисленного кластера. В результате чего формируется более равномерно распределенная обучающая выборка, что позволяет получить более качественную оценку выходной переменной за счет того, что в обучающей выборке постоянно содержатся наблюдения, учитывающие все возможные диапазоны изменения входных переменных. Апробация предлагаемого адаптивного ВА с кластеризацией на данных промышленного фракционатора показала сокращение значения САО на 7.8% и увеличение коэффициента детерминации на 9.75% в сравнении с известным подходом адаптации ВА на основе «движущегося окна».

Список литературы

1. Гурьева Е.М., Кольцов А.Г. Применение виртуальных анализаторов для определения качества нефтепродуктов // *Динамика систем, механизмов и машин*. 2016. № 1. С. 296-301.
2. Fayruzov D.Kh., Bel'kov Yu.N., Kneller D.V., Torgashov A.Yu. Advanced process control system for a crude distillation unit. A case study // *Automation in Industry*. 2017. Vol. 78. P. 357-367
3. Kadlec P., Grbic R., Gabrys B. Review of adaptation mechanisms for data-driven soft sensors // *Computers & Chemical Engineering*. 2011. No. 35 (1). P. 1-24.
4. Urhan A., Alakent B. Integrating adaptive moving window and just-in-time learning paradigms for soft-sensor design // *Neurocomputing*. 2020. Vol. 392. P. 23-37
5. Yamada N., Kaneko H. Adaptive soft sensor ensemble for selecting both process variables and dynamics for multiple process states // *Chemometrics and Intelligent Laboratory Systems*. 2021. Vol. 219. P. 104443.
6. 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. No. 180. P. 36-41.
7. Snegirev O.Y., Torgashov A.Y. Adaptation of the Structure and Parameters of Nonlinear Soft Sensors by the Example of an Industrial Reactive Distillation Process // *Automation and Remote Control*. 2021. Vol. 82, No. 10. P. 1774-1786.