

DOI: 10.15593/2499-9873/2021.1.01

УДК 004.896 004.942 519.873

**А.С. Нужный¹, И.С. Однолько², А.Ю. Глухов²,
М.С. Бутырин¹, Е.Н. Левченко¹, А.С. Стариков¹,
И.В. Карасев¹, С.А. Лапинова^{1,3}**

¹ ООО «ЛУКОЙЛ-Нижегородниинепфтепроект»,
Нижний Новгород, Россия

² ПАО «ЛУКОЙЛ», Москва, Россия

³ Национальный исследовательский университет «Высшая школа
экономики» – Нижний Новгород, Нижний Новгород, Россия

ОПТИМИЗАЦИЯ СОДЕРЖАНИЯ СЕДИМЕНТОВ В ПРОЦЕССЕ ГИДРОКРЕКИНГА ГУДРОНА С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Предложена математическая модель для оптимизации работы установки гидрокрекинга гудрона. Целью моделирования является улучшение экономического эффекта выпуска продукции за счет подбора оптимальных параметров, таких как расход водорода и температура реакторов. В качестве таргетируемого параметра используется показатель седиментов (осадков), определенных при горячем фильтровании (НФТ атмосферного остатка).

Модель предполагает поиск минимального значения функционала с ограничениями, представленными в виде штрафа, накладываемого при выходе параметров за рамки допустимых значений, а также при отклонении таргетируемого параметра от заданного значения. Выполнение алгоритма включает в себя два этапа. Первый этап представляет моделирование значения НФТ при заданном состоянии установки при выбранных параметрах температуры и расхода водорода с использованием виртуального анализатора, второй этап заключается в решении задачи оптимизации по подбору управляющих параметров установки. Для первого этапа была построена модель оценки показателя НФТ по технологическим показателям, включающая основные определяющие его факторы, для поиска параметров моделей использовались методы машинного обучения.

В качестве метода оптимизации был выбран алгоритм Пауэлла. Представлены результаты тестирования модели на реальных данных, предоставленных нефтеперерабатывающим заводом в г. Бургас в Болгарии. Период исследования включает в себя несколько режимов работы установки, в частности режимы интенсивной загрузки в период 2018–2019 гг. и низкой загрузки в период 2020 г. Результаты тестирования модели на реальных данных, представленные в работе, проверены экспертами в области нефтепереработки на предмет соответствия реальным состояниям.

Ключевые слова: содержание седиментов, НФТ, агрегативная устойчивость, машинное обучение, штрафные функции, стохастический градиентный спуск, задача оптимизации, крекинг, алгоритм Пауэлла, атмосферный остаток.

**A.S. Nuzhny¹, I.S. Odolko², A.Y. Glukhov²,
M.S. Butyrin¹, E.N. Levchenko¹, A.S. Starikov¹,
I.V. Karasev¹, S.A. Lapinova^{1,3}**

¹ LLC "LUKOIL-Nizhegorodniinefteproekt", Nizhniy Novgorod, Russian Federation

² PJSC "LUKOIL", Moscow, Russian Federation

³ National Research University "Higher School of Economics",
Nizhniy Novgorod branch, Nizhniy Novgorod, Russian Federation

OPTIMIZING THE CONTENT OF THE SEDIMENTS IN THE PROCESS OF HUDRON'S HYDROCRACKING WITH THE USE OF MACHINE LEARNING METHODS

The paper proposes a mathematical model to optimize the operation of the tar hydrocracking unit. The purpose of modeling is to improve the economic effect of product output by selecting optimal parameters, such as hydrogen flow rate and reactor temperature. Hot Filtered Precipitation (HFT) is used as a target.

The model involves the search for the minimum value of the functional with restrictions presented in the form of a fine imposed when the parameters go beyond the permissible values, as well as when the target parameter deviates from the specified value. The execution of the algorithm includes two stages. The first stage is the simulation of the HFT value for a given state of the installation at the selected parameters of temperature and hydrogen flow rate using a virtual analyzer, the second stage is to solve the optimization problem by selecting the control parameters of the installation. For the first stage, a model for assessing the HFT indicator by technological indicators was built, including the main factors determining it; machine learning methods were used to find the parameters of the models.

The free standard library of optimum search tools `scipy.optimize` was used to solve the optimization problem. Powell's algorithm was chosen as the optimization method. The paper presents the results of testing the model on real data provided by an oil refinery in the city of Burgas in Bulgaria. The study period includes several operating modes of the installation, in particular, the intensive load mode during 2018-2019 and low load during the 2020 period. The results of testing the model on real data presented in the work have been verified by experts in the field of oil refining for compliance with real conditions.

Keywords: sediment content, HFT, aggregate stability, machine learning, penalty functions, stochastic gradient descent, optimization problem, cracking, Powell's algorithm, atmospheric residue.

Введение

Современный нефтеперерабатывающий завод является сложным комплексом, оснащенный тысячами, а иногда и десятками тысяч датчиков, поток информации с которых поступает в режиме реального времени в систему управления. От качества обработки полученной информации и эффективности принимаемых решений зависит прибыль предприятия и безопасность сотрудников, которые невозможно обеспечить на желаемом уровне в режиме ручного управления.

На практике задача управления и оптимизации процессов нефтепереработки решается за счет использования систем улучшенного управления технологическим процессом – СУУТП (APC) [1, 2], основанных на прогнозирующих моделях объектов и многопараметриче-

ских регуляторах. Такие системы представляют собой надстройку над системами базового регулирования – распределенного управления (PCY) с алгоритмами и каскадами ПИД-регуляторов [3]. Функция APC заключается в получении от PCY актуальных значений параметров установки (контролируемых, управляющих и возмущающих переменных), расчете выходных параметров на основе динамической модели объекта, определении оптимальной стратегии управления, т.е. последовательности управляющих воздействий в рамках имеющихся ограничений, и их передаче в виде заданий ПИД-регуляторам [4]. При этом система APC способна решать два типа задач: задачи управления технологическим режимом – удержание режима установки в рамках установленных норм (в стационарном или переходном процессе), с выдержкой при этом качества продуктов в пределах спецификаций, а также задачи оптимизации – на достижение наилучших значений целевой функции оптимизации [3].

Однако недостатком данных систем является отсутствие сбалансированности в выборе параметров, жесткая привязка к заложенным моделям и неспособность системы к самонастраиванию и самообучению. Это особенно актуально в связи с процессом так называемой деградации установки, когда со временем наблюдается зашлакованность технической системы, что приводит к изменению параметров ее работы. Также модель часто занижает технологические возможности установки, следствием чего является недополучение прибыли и рост расходов. Подобные недостатки должны исправить виртуальные анализаторы (BA) лабораторных показателей качества продукта, которые представляют собой компьютерные модели связи состояния установки и качества производимых продуктов.

Известно [3, 5], что в составе многопараметрических контроллеров и BA, как правило, используются линейные регрессионные модели, которые не всегда полноценно описывают поведение технологических процессов, многие из которых характеризуются нелинейными и неаддитивными зависимостями [6, 7]. Повысить точность расчетов можно за счет использования строгих моделей и нелинейных контроллеров, позволяющих учитывать кинетику физико-химических процессов. Как правило, это требует серьезных технологических доработок APC.

Современный взгляд на проблему основывается на комбинации моделей машинного обучения и методов оптимизации, а также элемен-

тах проектирования систем с обратной связью [7]. Как правило, это совокупность моделей, обеспечивающих достаточно полное представление о поведении системы.

В работе рассматривается установка гидрокрекинга гудрона, находящаяся на Бургасовском заводе компании «ЛУКОЙЛ» [8]. Установка состоит из реакторного блока, в котором происходит гидрокрекинг, и ректификационного. В работе [8] был предложен метод построения виртуального анализатора оценки лабораторного показателя содержания седиментов (НФТ). Данный показатель в основном зависит от работы реакторного блока, поэтому его можно использовать для оптимизации работы реактора. Оптимизация заключается в таком выборе значений управляющих параметров установки, который приводит к желаемому значению НФТ.

В данной статье рассматривается модель оптимизации реактора и программа, реализующая эту модель. Программа выдает рекомендуемые значения управляющих параметров установки, которые должны привести ее к состоянию, дающему указанное пользователем значение НФТ.

1. Краткая характеристика установки

Установка гидрокрекинга гудрона с псевдооживленным слоем катализатора H-oil (технология Axens) позволяет перерабатывать тяжелые нефтяные остатки в ценные дистилляты, обеспечивая при этом конверсию более 60 % [9].

В качестве сырья используются остатки вакуумной разгонки с установок АВТ-1 и ВД-2 (+538 °С), а также другие компоненты (например, широкая масляная фракция, шлам и т.д.).

Установка гидрокрекинга H-oil включает в себя следующие секции: реакторный блок и блок сепарации, секцию фракционирования, секцию аминовой очистки, секцию компримирования и очистки водородсодержащего газа, секцию резервуарных парков и емкостей для хранения азота, вспомогательную секцию.

Для достижения максимальной конверсии реализована технологическая схема с двумя последовательно соединенными реакторами и промежуточным сепаратором. Используется никель-молибденовый катализатор в псевдооживленном слое. Для поддержания оптимальной активности катализатора ежедневно идет подача свежего катализатора. Основными параметрами, используемыми для регулирования процесса, являются значения температуры в реакторах.

В реакторном блоке проходят основные химические реакции превращения сырья на катализаторе в атмосфере водорода – конверсия высокомолекулярных соединений, входящих в состав нефтяных остатков, в более низкомолекулярные – газожидкостную смесь продуктов реакции, которая затем на секции ректификации разделяется на основные компоненты: газ, низкооктановый бензин, дизельные фракции, вакуумный газойль, а также вакуумный остаток с низким содержанием серы (неконвертируемый остаток). Остаток переработки используется в качестве компонента для получения котельного или судового топлива.

Проблемы со стабильностью получаемого остатка (содержанием седиментов – НГТ) определяют максимально достижимую конверсию процесса. Наблюдаются существенные колебания стабильности продукта при изменении состава поступающего сырья, особенно в случае переработки специфических нефтей. При превышении параметра НГТ атмосферного и вакуумного остатков проводится корректировка технологического режима за счет снижения температуры реакторов WABT (средневзвешенная температура слоя).

2. Модель виртуального анализатора показателя содержания седиментов (НГТ)

В работе [8] был предложен подход к построению виртуальных анализаторов – компьютерных моделей, которые по описанию текущего состояния установки (набора показаний датчиков) строят прогноз значений лабораторных показателей. Данный подход после подбора лагов сводит задачу к классической проблеме обучения с учителем (регрессии) [10]. Решение ищется в виде некоторой функции, зависящей от параметров:

$$y = f(\mathbf{x}, \mathbf{w}),$$

где $y \in Y$ – значение лабораторного показателя; \mathbf{x} – вектор входных значений датчиков с установки, $\mathbf{x} = \{x_1, x_2, \dots, x_L\}$; L – число датчиков, включенных в модель; \mathbf{w} – вектор адаптивных параметров модели. Значения датчиков установки берутся в моменты времени, отстоящие от момента взятия пробы на некоторую величину – лаг, определяемый корреляционным методом [8].

Параметры модели \mathbf{w} подбираются таким образом, чтобы получившаяся в итоге функция f , которая выполняет отображение L -мерного

множества X в скалярное множество Y , выдавала значения лабораторного показателя, минимально отличающиеся от измеренных. Подбор параметров модели обычно осуществляется путем минимизации ее ошибки на обучающей выборке – наборе известных примеров соответствия состояний установки лабораторным значениям:

$$L(\mathbf{w}) = \sum_{i=1}^L (y_i - f(x_i, \mathbf{w}))^2 \quad (1)$$

В общем случае задача (1) является математически некорректной и требует регуляризации [10] или применения других методов борьбы с некорректностью, которую в теории машинного обучения принято называть «переобучением».

В работе [8] виртуальный анализатор строился с помощью градиентного бустинга на деревьях [11]. Эта модель дала наиболее точные результаты на тестовой выборке. Однако решение, которое предоставляет данная модель, является неаналитическим и, самое главное, модель градиентного бустинга имеет дискретный спектр выходных значений, что, как будет показано в следующем подразделе, не позволяет использовать ее в задаче оптимизации. Таким образом, для целей оптимизации необходимо заменить бустинг другой регрессионной моделью, дающей непрерывный спектр выходных значений. В качестве такой модели может выступить модель на основе функционального базиса [10], RBF [12] или, например, классический персептрон [13]. Был выбран последний метод, поскольку из всех рассмотренных моделей, отвечающих условию непрерывности спектра значений на выходе, он показал наилучшую точность предсказания лабораторного показателя.

Для построения нейронной сети обучения была выбрана реализация из библиотеки `Scikit-Learn.neural_network`. Данная модель представляет собой многослойный персептрон, оптимизирующий квадрат потерь с помощью LBFSGS (алгоритм Бройдена – Флетчера – Гольдфарба – Шанно [14]) или стохастического градиентного спуска [15]. Перед обучением нейросети все входные данные (признаки и целевая переменная) нормировались с помощью `sklearn.preprocessing.StandardScaler` ($z = (x - u) / s$, где u – среднее значение обучающей выборки, s – стандартное отклонение). Для оптимизации весов был выбран алгоритм Adam, основанный на стохастическом градиенте [16].

Подбор других параметров сети осуществлялся экспериментально. Структура сети содержит два скрытых слоя. Количество нейронов в слоях

нейронной сети подбиралось исходя из минимизации функции ошибки, оценивающей отклонение предсказанных значений от экспериментальных. На тестовой выборке подобранные значения: число нейронов на первом слое – 15, на втором слое – 50. В качестве функции активации нейронов скрытых слоев была выбрана сигмоидальная функция

$$f(x) = \frac{1}{1 + e^{-x}}.$$

Выбранный режим обучения – Adaptive, поддерживающий постоянную скорость обучения, пока потери в обучении продолжают уменьшаться, в противном случае, если две последовательные эпохи не уменьшают потери на заданное минимальное значение, текущая скорость обучения делится на 5.

Для борьбы с переобучением используется регуляризация по метрике L2 [9].

3. Задача оптимизации

Управление технологическими процессами, для анализа которых используется виртуальный анализатор, подчиняется законам экономической эффективности, т.е. необходимости максимизировать прибыль при минимизации затрат. Прибыль во многом определяется конверсией сырья, которая характеризуется НФТ. Уровень этого показателя устанавливается оператором исходя опять же из экономических соображений, но не связанных с работой установки. Иными словами, по сути, пользователь устанавливает целевой уровень НФТ, а программа оптимизации дает рекомендации по значениям управляющих параметров, которые должны привести к этому целевому уровню.

Здесь необходимо отметить, что заданного уровня по НФТ можно достигнуть при разных состояниях установки. Следовательно, из всех допустимых при заданном НФТ состояний нужно определить одно оптимальное, наложив некоторые дополнительные ограничения. В частности, необходимо минимизировать затраты установки, основной вклад в которые вносит расход водорода. В первом приближении расходом водорода можно описать все операционные издержки. Принимаем стоимость водорода 1,178 долл. за кг.

Оценки экспертов показывают, что при прочих равных условиях повышение средней температуры WABT реакторного блока на один гра-

дус повышает конверсию установки на один процент. Известно, что один процент конверсии стоит около 16,7 тыс. долл. в сутки, или 696 долл. в час, что дает приближенную формулу экономического эффекта установки:

$$E = 174(610TI074.DACA.PV + 610TI094.DACA.PV) - 1,178(610FIC016.PID_PLA.PV + 610FI015.DACA.PV), \quad (2)$$

где E – приближенный экономический эффект работы установки; 610TI074.DACA.PV и 610TI094.DACA.PV – значения температур входа одноименных виртуальных датчиков, а 610FIC016.PID_PLA.PV и 610FI015.DACA.PV – значения потоков водорода в первом и во втором виртуальном реакторе соответственно; коэффициент 174 – приближенная оценка средневзвешенной стоимости конверсионного продукта на выходе в \$ при повышении температуры реакторов на один градус.

Математически задача поиска оптимальных значений управляющих параметров сводится к оптимизации данного выражения при дополнительных условиях:

$$F(\mathbf{x}) = \min_{\substack{\lambda \rightarrow \infty \\ \Lambda \rightarrow \infty}} \left(-E(\mathbf{x}) + \lambda (\text{hft}(\mathbf{x}) - \text{target})^2 + \Lambda \sum_{i=1}^L (x_i < \underline{x}_i) + \Lambda \sum_{i=1}^L (x_i > \bar{x}_i) \right), \quad (3)$$

где target – целевое значение показателя НФТ; $\text{hft}(\mathbf{x})$ – функция виртуального анализатора НФТ; $E(\mathbf{x})$ – экономический эффект, полученный согласно формуле (2); \mathbf{x} – вектор входных параметров; \underline{x}_i и \bar{x}_i – технологические ограничения на значения отдельных параметров установки $x_i \in \mathbf{x}$; λ – значение штрафа за отличную от нуля разницу между расчетным и целевым значениями показателя НФТ ($\text{hft}(\mathbf{x}) - \text{target}$), Λ – параметр штрафа за выход за пределы ограничений на $x_i \in \mathbf{x}$.

Поскольку выполняется поиск минимума в условиях ограничений, был применен метод штрафных функций [17].

В результате мы имеем двухшаговый алгоритм:

– На первом шаге строится виртуальный анализатор параметра НФТ.

– На втором шаге выполняется максимизация экономического эффекта установки (2) при заданном пользователем целевом значении НФТ и технологических ограничениях (3).

При решении задачи оптимизации использовалась стандартная свободная библиотека инструментов поиска оптимума `scipy.optimize` (<https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.minimize.html>). В качестве метода оптимизации был выбран алгоритм Пауэлла [18].

Для обучения сети были использованы данные работы установки гидрокрекинга, расположенной в г. Бургас (Болгария). Размер выборки составил 1218 точек. Обучающая выборка составила 80 % от исходной. Тестирование проводилось на 20 % от исходной выборки.

4. Результаты численного тестирования оптимизатора

Для проверки корректности работы оптимизатора были выполнены расчеты на реальных данных нефтеперегонной установки (таблица). Параметры, определяющие начальное состояние системы, были выбраны следующие:

- температура входа первого реактора R-1001 (610TI074);
- температура входа второго реактора R-1002 (610TI094);
- загрузка установки (610FIC021);
- расход водорода в первом реакторе R-1001 (610FIC016);
- расход водорода во втором реакторе R-1002 (610FI015);
- плотность шлама крекинга (12DI053_1_15);
- плотность гудронового сырья (Param10);
- показатель НФТ.

Результаты тестирования оптимизатора на данных установки гидрокрекинга, расположенной в г. Бургас (Болгария)

Параметр	Точка 35		Точка 71		Точка 175		Точка 258	
	До	После	До	После	До	После	До	После
610TI074	349,82	356,7	351,42	356,95	356,77	344,83	355,19	346,88
610TI094	376,36		376,63		378,96		378,04	
610FIC021	255352,6		257395,8		259274,4		240689	
610FIC016	7448,79	7448,41	7450,64		7498,84	7499,09	7450,75	7451,06
610FI015	6499,31		6601,97		6653,22		6430,89	
12DI053_1_15	1089,2		1096,26		1106,68		1108,83	
Param10	995,03		996,97		990,18		992,3	
НФТ	0,2	0,25	0,21	0,25	0,34	0,25	0,31	0,25
Показатель экономической эффективности E		1197,13		962,16		-2077,6		-1443,4

Для тестирования были выбраны произвольные точки из исторических данных, отражающие состояние установки. Далее проведена оптимизация к целевому показателю $HFT = 0,25$. Из результатов, представленных в таблице, видно, что повышение температуры на входе в реактор повышает конверсию установки и, соответственно, улучшает экономический показатель. Данная модель хорошо показывает не только качественное изменение экономического показателя, но и количественное. Результаты эксперимента показали, что модель работает корректно и можно ориентироваться на ее показатели при управлении установкой. Из представленных в таблице результатов видно, что при снижении показателя HFT экономический показатель растет за счет снижения температуры входа в реактор, а также снижения потребления водорода. Границы работы установки по показателю HFT составляют от 0,1 до 0,35, именно в этой области наблюдается хорошая работа оптимизатора.

Заключение

В работе предложена математическая модель подхода к оптимизации установки гидрокрекинга гудрона, который заключается в максимизации экономической эффективности при установленном ограничении по допустимому значению HFT атмосферного остатка. Данный подход не учитывает инерцию установки, работая в предположении, что при изменении управляющих параметров система сразу переходит в новое равновесное состояние, однако, несмотря на это, тестирование модели показало, что выдаваемые ею рекомендации хорошо согласуются с экспертными оценками.

Разработанный метод может быть обобщен на другие типы установок нефтепереработки. Например, при оптимизации работы установки атмосферной и вакуумной дистилляции (АВТ) можно аналогичным образом искать оптимальные значения управляющих параметров, максимизируя 95%-ную температуру выкипания дизеля.

Модель оптимизатора не только отражает физику процесса, а также хорошо показывает изменение экономического показателя, что позволяет оператору ориентироваться на ее показатели при управлении установкой.

Список литературы

1. Дозорцев В.М., Кнеллер Д.В. APC – усовершенствованное управление технологическими процессами // Датчики и системы = Sensors & Systems. – 2005. – № 10. – С. 56–62.

2. Захаркин М.А., Кнеллер Д.В. Применение методов и средств усовершенствованного управления технологическими процессами (АРС) // Датчики и системы = Sensors & Systems. – 2010. – № 10. – С. 57–71.

3. Ицкович Э.Л., Дозорцев В.М., Кнеллер В.В. Усовершенствованное управление технологическими процессами (АРС): 10 лет в России // Автоматизация в промышленности. – 2013. – № 1. – С. 12–19.

4. Опыт разработки и внедрения систем усовершенствованного управления технологическими процессами нефтепереработки на базе виртуальных анализаторов качества / А.Г. Шумихин, Д.А. Мусатов, С.С. Власов, А.М. Немтин, В.Г. Плехов // Вестник Пермского национального исследовательского политехнического университета. Химическая технология и биотехнология. – 2016. – № 2. – С. 39–53.

5. Неаддитивные изменения свойств углеводородных систем при смешении / В.М. Капустин, Е.А. Чернышева, О.Ф. Глаголева, И.В. Пискунов, А.Ю. Садыров, В.И. Кувькин, А.Н. Гайнетдинова // Нефтепереработка и нефтехимия. Научно-технические достижения и передовой опыт. – 2017. – № 4. – С. 3–9.

6. Современные методы математической обработки и их роль в оптимизации технологических процессов нефтехимии и нефтепереработки / Д.В. Писаревский, В.А. Будник, К.А. Куцуев, Б.С. Жирнов // Нефтепереработка и нефтехимия. Научно-технические достижения и передовой опыт. – 2011. – № 8. – С. 16–20.

7. Вычисление низкотемпературных характеристик дизельного топлива с помощью искусственных нейронных сетей / С. Маринович, Т. Боланча, С. Юкич, В. Рукавина, А. Юкич // Химия и технология топлив и масел. – 2012. – № 1 (569). – С. 47–51.

8. Использование методов машинного обучения для прогнозирования содержания седиментов (НФТ) в неконвертируемом остатке с установки гидрокрекинга гудрона / А.С. Нужный, И.С. Однолько, А.Ю. Глухов, И.В. Пискунов, И.М. Вышинский, Е.Н. Левченко, А.С. Стариков // Нефтепереработка и нефтехимия. Научно-технические достижения и передовой опыт. – 2020. – № 7. – С. 1–8.

9. Дельфин Ле Бар. Максимальное увеличение конверсии тяжелых остатков с применением проверенных технологий [Электронный ресурс] // Russia & CIS BVTС, г. Москва, 23–24 апреля 2015 г. – URL: <https://docplayer.ru/57280877-Konversii-tyazhelyh-ostatkov-s-primeneniem-proverennyh-tehnologiy.html> (дата обращения: 19.12.2020).

10. Нужный А.С. Байесовский подход к регуляризации задачи обучения сети функций радиального базиса // Искусственный интеллект и принятие решений. – 2015. – № 2. – С. 18–24.

11. Friedman J.H. Greedy function approximation: a gradient boosting machine // *The Annals of Statistics*. – 2001. – Vol. 29, no. 5. – P. 1189–1232.
12. Nuzhny A.S. Bayesian regularization in the problem of point-by-point function approximation using an orthogonalized basis // *Mathematical Models and Computer Simulations*. – 2012. – Vol. 4, no. 2. – P. 203–209. DOI: 10.1134/S2070048212020111
13. Хайкин С. Нейронные сети: полный курс: пер. с англ. – 2-е изд. – М.: Вильямс, 2006. – 1104 с.
14. Nocedal J., Wright S.J. Numerical optimization. – New York: Springer-Verlag New York, 2006. – 2nd ed. – 664 p. DOI 10.1007/978-0-387-40065-5
15. Bottou L. Online algorithms and stochastic approximations // *Online Learning and Neural Networks* / ed. by D. Saad. – Cambridge: Cambridge University Press, 1998. – 35 p. – URL: <http://leon.bottou.org/papers/bottou-98x> (accessed 19 December 2020).
16. Kingma D.P., Ba J.L. Adam: a method for stochastic optimization // 3rd International Conference for Learning Representations (ICLR 2015), San Diego, CA, USA, May 7–9, 2015. – San Diego, CA, USA, 2015. – 15 p. – URL: <https://arxiv.org/abs/1412.6980> (accessed 19 December 2020).
17. Банди Б. Методы оптимизации: вводный курс / пер. с англ. О.В. Шихеевой; под ред. В.А. Волынского. – М.: Радио и связь, 1988. – 128 с.
18. Powell M.J.D. An efficient method for finding the minimum of a function of several variables without calculating derivatives // *The Computer Journal*. – 1964. – Vol. 7, no. 2. – P. 155–162. DOI: 10.1093/comjnl/7.2.155

References

1. Dozortsev V.M., Kneller D.V. APS – usovershenstvovannoe upravlenie tekhnologicheskimi protsessami [APC-advanced process control]. *Sensors & Systems*, 2005, no. 10, pp. 56–62.
2. Zakharkin M.A., Kneller D.V. Primenenie metodov i sredstv usovershenstvovannogo upravleniia tekhnologicheskimi protsessami (APS) [Application of methods and means of improved process control (APS)]. *Sensors and systems*. 2010, no. 10, pp. 57–71.
3. Itskovich E.L., Dozortsev V.M., Kneller V.V. Usovershenstvovannoe upravlenie tekhnologicheskimi protsessami (ARS): 10 let v Rossii [Advanced process control (APC): 10 years in Russia]. *Automation in industry*. 2013, no. 1, pp. 12–19.
4. Shumikhin A.G., Musatov D.A., Vlasov S.S., Nemtin A.M., Plekhov V.G. Opyt razrabotki i vnedreniia sistem usovershenstvovannogo upravleniia tekhnologicheskimi protsessami neftepererabotki na baze virtual'nykh analizatorov kachestva [Experience developments and introduction advanced technologicals

processes control oil refining based virtual quality analysers]. *Vestnik Permskogo natsional'nogo issledovatel'skogo politekhnicheskogo universiteta. Khimicheskaiia tekhnologiia i biotekhnologiia*, 2016, no. 2, pp.39–53.

5. Kapustin V.M., Chernysheva E.A., Glagoleva O.F., Piskunov I.V., Sadyrov A.Iu., Kuvykin V.I., Gainetdinova A.N. Neadditivnye izmeneniia svoistv uglevodorodnykh sistem pri smeshenii [Not additive changes of properties of hydrocarbon systems while mixing]. *Neftepererabotka i neftekhimiia*, 2017, no. 4. pp. 3–9.

6. Pisarevsky D.V., Budnik V.A., Kutsuev K.A., Zhirnov B.S. Sovremennye metody matematicheskoi obrabotki i ikh rol' v optimizatsii tekhnologicheskikh protsessov neftekhimii i neftepererabotki [Modern methods of mathematical processing and their role in the optimization of technological processes in petrochemistry and oil refining]. *Neftepererabotka i neftekhimiia*. 2011, no 8, pp.16–20.

7. Marinovich S., Bolancha T., Iukich S., Rukavina V., Iukich A. Vychislenie nizkotemperaturnykh kharakteristik dizel'nogo topliva s pomoshch'iu iskusstvennykh neironnykh setei [Calculation of low-temperature characteristics of diesel fuel using artificial neural networks]. *Chemistry and Technology of Fuels and Oils*, 2012, no. 1 (569), pp. 47–51.

8. Nuzhny A.S., Odnolko I.S., Glukhov A.Yu., Piskunov I.V., Vyshinsky I.M., Levchenko E.N., Starikov A.S. Ispol'zovanie metodov mashinnogo obucheniia dlia prognozirovaniia soderzhaniia sedimentov (HFT) v nekonvertiruемом ostatke s ustanovki gidrokrekinga gudrona [Using machine learning techniques to predict the content of sediments (HFT) in an unconverted residue from the tar hydrocrackingunit]. *Neftepererabotka i neftekhimiia*. 2020, no. 7, pp. 1–8.

9. Dolphine Le Bar. Maximize conversion of heavy residues with proven technology, available at: <https://docplayer.ru/57280877-Konversii-tyazhelyh-ostatkov-s-primeneniem-proverennyh-tehnologiy.html> (accessed 19 December 2020)

10. Nuzhnyi A.S. Baiesovskii podkhod k reguliarizatsii zadachi obucheniia seti funktsii radial'nogo bazisa [Bayesian approach to regularization for training task of radial basic functions network]. *Scientific and Technical Information Processing*, 2015, no. 2. pp. 18–24.

11. Friedman J.H. Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 2001, vol. 29, no. 5, pp. 1189–1232.

12. Nuzhny A.S. Bayesian regularization in the problem of point-by-point function approximation using an orthogonalized basis. *Mathematical Models and Computer Simulations*. 2012, vol. 4, no 2, pp. 203–209. DOI: 10.1134/S2070048212020111

13. Haykin S. Neural Networks: A Comprehensive Foundation, Second Edition. New Jersey, Prentice Hall, 1999, 842 p.

14. Nocedal J., Wright S.J. Numerical Optimization. 2nd edition. New York, Springer-Verlag New York, 2006, 664 p. DOI 10.1007/978-0-387-40065-5
15. Bottou L. Online Algorithms and Stochastic Approximations. *Online Learning and Neural Networks*. Ed. By D. Saad. Cambridge, Cambridge University Press. 1998, 35 p., available at: <http://leon.bottou.org/papers/bottou-98x> (accessed 19 December 2020).
16. Kingma D.P., Ba J.L. Adam: A Method for Stochastic Optimization. *The 3rd International Conference for Learning Representations*, 2015, available at: <https://arxiv.org/abs/1412.6980> (accessed 19 December 2020).
17. Bunday B.D. Basic Optimization Methods. London, Edward Arnold, 1984, 122 p.
18. Powell M.J.D. An efficient method for finding the minimum of a function of several variables without calculating derivatives. *The Computer Journal*, 1964, vol. 7, no 2, pp. 155–162. DOI: 10.1093/comjnl/7.2.155

Статья получена: 19.01.2021

Статья принята: 01.03.2021

Сведения об авторах

Нужный Антон Сергеевич (Нижний Новгород, Россия) – кандидат физико-математических наук, главный специалист, ООО «ЛУКОЙЛ-Нижегородниинепфтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: Anton.Nuzhnyy@lukoilrus.onmicrosoft.com).

Однолько Иван Сергеевич (Москва, Россия) – начальник департамента оптимизации бизнеса блока нефтехимии, нефтепереработки и газопереработки, ПАО «ЛУКОЙЛ» (101000, Москва, Уланский пер., 5, e-mail: ivan.odnolko@lukoilrus.onmicrosoft.com).

Глухов Алексей Юрьевич (Москва, Россия) – старший менеджер, ПАО «ЛУКОЙЛ» (101000, Москва, Уланский пер., 5, e-mail: aleksey.u.glukhov@lukoilrus.onmicrosoft.com).

Бутырин Максим Сергеевич (Нижний Новгород, Россия) – ведущий инженер, ООО «ЛУКОЙЛ-Нижегородниинепфтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: maxim.butyrin@lukoilrus.onmicrosoft.com).

Левченко Евгений Николаевич (Нижний Новгород, Россия) – начальник отдела, ООО «ЛУКОЙЛ-Нижегородниинепфтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: evgeny.n.levchenko@lukoilrus.onmicrosoft.com).

Стариков Александр Сергеевич (Нижний Новгород, Россия) – начальник центра цифрового моделирования, ООО «ЛУКОЙЛ-Нижегородниинефтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: alexandr.starikov@lukoil.com).

Карасев Игорь Вячеславович (Нижний Новгород, Россия) – ведущий инженер отдела моделирования и разработки цифровых продуктов Центра MC2, ООО «ЛУКОЙЛ-Нижегородниинефтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: Igor.V.Karasev@lukoil.com).

Лапинова Светлана Александровна (Нижний Новгород, Россия) – кандидат физико-математических наук, доцент кафедры «Математическая экономика», Национальный исследовательский университет «Высшая школа экономики» – Нижний Новгород (Нижний Новгород, ул. Большая Печерская, 25/12); ООО «ЛУКОЙЛ-Нижегородниинефтепроект» (603006, Нижний Новгород, ул. Максима Горького, 147А, e-mail: slapinova@yandex.ru).

About the authors

Anton S. Nuzhny (Nizhny Novgorod, Russian Federation) – Ph.D. in Physics and Mathematics, Chief Specialist, LLC “LUKOIL-Nizhegorodniinefteprоеkt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: Anton.Nuzhnyy@lukoilrus.onmicrosoft.com).

Ivan S. Odnolko (Moscow, Russian Federation) – Head of the Business Optimization Department of the Petrochemistry, Oil Refining and Gas Processing Unit, PJSC “LUKOIL” (5, Ulansky per., Moscow, 101000, e-mail: ivan.odnolko@lukoilrus.onmicrosoft.com).

Alexey Y. Glukhov (Moscow, Russian Federation) – Senior Manager, PJSC “LUKOIL” (5, Ulansky per., Moscow, 101000, e-mail: aleksey.y.glukhov@lukoilrus.onmicrosoft.com).

Maxim S. Butyrin (Nizhny Novgorod, Russian Federation) – Leading Engineer, LLC “LUKOIL-Nizhegorodniinefteprоеkt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: maxim.butyrin@lukoilrus.onmicrosoft.com).

Evgeny N. Levchenko (Nizhny Novgorod, Russian Federation) – Head of Department, LLC “LUKOIL-Nizhegorodniinefteprоеkt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: evgeny.n.levchenko@lukoilrus.onmicrosoft.com).

Alexander S. Starikov (Nizhny Novgorod, Russian Federation) – Head of the Center, Center for Digital Modeling, LLC “LUKOIL-Nizhegorodniinefteprоеkt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: alexandr.starikov@lukoil.com).

Igor V. Karasev (Nizhny Novgorod, Russian Federation) – Leading Engineer, Department of Modeling and Development of Digital Products of the MC2 Center, LLC “Lukoil-Nizhegorodniinefteprоеkt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: Igor.V.Karasev@lukoil.com).

Svetlana A. Lapinova (Nizhny Novgorod, Russian Federation) – Ph.D. in Physics and Mathematics, Associate Professor, Department of Mathematical Economics, National Research University “Higher School of Economics”, Nizhny Novgorod branch (25/12, Bolshaya Pecherskaya st., Nizhny Novgorod), LLC “LUKOIL-Nizhegorodniinefteproekt” (147A, Maxim Gorky st., Nizhny Novgorod, 603006, e-mail: slapinova@yandex.ru).

Библиографическое описание статьи согласно ГОСТ Р 7.0.100–2018:

Оптимизация содержания седиментов в процессе гидрокрекинга гудрона с использованием методов машинного обучения / А. С. Нужный, И. С. Однолько, А. Ю. Глухов, М. С. Бутырин, Е. Н. Левченко, А. С. Стариков, И. В. Карасев, С. А. Лапинова. – текст : непосредственный. – DOI 10.15593/2499-9873/2021.1.01 // Прикладная математика и вопросы управления = Applied Mathematics and Control Sciences. – 2021. – № 1. – С. 7–22.

Цитирование статьи в изданиях РИНЦ:

Нужный А.С., Однолько И.С., Глухов А.Ю., Бутырин М.С., Левченко Е.Н., Стариков А.С., Карасев И.В., Лапинова С.А. Оптимизация содержания седиментов в процессе гидрокрекинга гудрона с использованием методов машинного обучения // Прикладная математика и вопросы управления. – 2021. – № 1. – С. 7–22. – DOI: 10.15593/2499-9873/2021.1.01

Цитирование статьи в references и международных изданиях:

Cite this article as:

Nuzhny A.S., Odnolko I.S., Glukhov A.Y., Butyrin M.S., Levchenko E.N., Starikov A.S., Karasev I.V., Lapinova S.A. Optimizing the content of the sediments in the process of hudron's hydrocracking with the use of machine learning methods. *Applied Mathematics and Control Sciences*, 2021, no. 1, pp. 7–22. DOI: 10.15593/2499-9873/2021.1.01 (*in Russian*)