

DOI: 10.15593/2499-9873/2019.4.02

УДК 681.5

А.В. Затонский^{1,2}, Л.Г. Тугашова³

¹Пермский национальный исследовательский
политехнический университет, Березниковский филиал,
Березники, Россия

²Пермский национальный исследовательский
политехнический университет, Пермь, Россия

³Альметьевский государственный нефтяной институт,
Альметьевск, Россия

РАЗРАБОТКА МОДЕЛЕЙ КАЧЕСТВА И ВЫРАБОТКИ НЕФТЕПРОДУКТОВ С ПРИМЕНЕНИЕМ MATLAB

Рассмотрена задача контроля показателей качества нефтепродуктов на технологических установках. Проведен обзор методов контроля качества нефтепродуктов, рассмотрены модели для прогнозирования температур начала и конца кипения светлых нефтепродуктов на нефтеперерабатывающих установках. Получены математические модели показателей качества светлых нефтепродуктов (температур начала и конца кипения) в виде авторегрессионных моделей с внешними факторами. Факторами являются измеряемые технологические параметры нефтеперерабатывающей установки: температура, расход, давление. Модели подобной структуры могут применяться для прогнозирования показателей качества светлых нефтепродуктов на нефтеперерабатывающих установках. Предложено применение методов кластеризации для анализа ассортимента и выработки нефтепродуктов по федеральным округам. Кратко описаны итеративные и иерархические методы кластерного анализа. Приведен пример применения методов кластерного анализа для оценки выработки и ассортимента нефтепродуктов в федеральных округах за 2 года. Представлены результаты исследований, проведенных с применением программного пакета MATLAB. Полученные результаты могут применяться при анализе ассортимента нефтепродуктов первичной и деструктивной нефтепереработки в пределах крупных территориальных единиц. Рассмотрена возможность прогнозирования выработки нефтепродуктов с помощью мультипликативных моделей. Предложены модели, отличающиеся учетом сезона и видом тренда. Приведены этапы построения математической модели. По статистическим данным по выработке автомобильного бензина за 5 лет в Российской Федерации построены математические модели временного ряда. Выполнена оценка качества моделирования с помощью полученных моделей по средней относительной погрешности. По полученной модели выработки автомобильного бензина построен постпрогноз с горизонтом прогнозирования 1 год. Средняя относительная погрешность постпрогноза по Российской Федерации не превышает 5 %, по федеральным округам – не более 12 %. Модели могут применяться для прогнозов выработки светлых нефтепродуктов в федеральных округах Российской Федерации.

Ключевые слова: нефтепродукт, авторегрессионная модель, кластерный анализ, выработка, динамический ряд, индекс сезонности, тренд, показатели качества.

A.V. Zatonskiy^{1,2}, L.G. Tugashova³

¹Berezniki branch of Perm National Research Polytechnic University,
Berezniki, Russian Federation

²Perm National Research Polytechnic University,
Perm, Russian Federation

³Almetyevsk State Oil Institute, Almetyevsk, Russian Federation

MODELLING THE QUALITY AND PRODUCTION OF PETROLEUM PRODUCTS WITH MATLAB

The problem of control of indicators of quality of oil products on technological installations is considered. The review of methods of quality control of oil products is carried out, models for forecasting of temperatures of the beginning and the end of boiling of light oil products on oil refineries are considered. Mathematical models of indicators of quality of light oil products (temperatures of the beginning and the end of boiling) in the form of autoregressive models with external factors are received. The factors are the measured technological parameters of the refinery: temperature, flow, pressure. Models of such a structure can be used to predict the quality of light petroleum products in oil refineries. The application of clustering methods for the analysis of the range and production of petroleum products in the Federal districts is proposed. Hierarchical and iterative methods of cluster analysis are briefly described. An example of the application of cluster analysis methods for the evaluation of production and assortment is given. The article studies the task of monitoring the quality of petroleum products at process units. Review of controlling methods quality of mineral oil has been performed, models for forecast temperatures of starting and ending boiling of light oil products at refineries have been considered. Mathematical models of indicators quality of light oil products (temperatures of starting and ending boiling) in the form of autoregressive models with external factors have been obtained. Factors are measured technological parameters of oil refinery including: temperature, consumption, pressure. Models of a similar structure can be applied to forecasting quality indicators of light oil product at refineries. The application of clustering methods have been proposed for analyzing the range and production of petroleum products by federal districts. Iterative and hierarchical cluster analysis methods are briefly described. An example of application of cluster analysis methods to assess the production and range of petroleum products in federal districts over 2 years is given. Research results have been conducted using the MATLAB software package are presented. The obtained results can be used in the analysis of the range of petroleum products of primary and destructive refining within large territorial units. The possibility of forecasting the production of petroleum products using multiplicative models has been considered. Models with different seasonal components and trend types have been proposed. The stages of building a mathematical model have been given. According to statistical data on the development of motor gasoline over 5 years, mathematical models of a time series have been built using the example of the Russian Federation. The quality of modeling has been assessed using the obtained models according to the average relative error. According to the obtained model of production of automobile gasoline, a post-forecast has been built with a forecasting horizon of 1 year. The average relative error of post-prognosis of the Russian Federation does not exceed 5 %, in federal districts – 12 %. Models can be used to predict the production of light petroleum products in the federal districts of the Russian Federation.

Keywords: petroleum product, autoregressive model, cluster analysis, production, time series, seasonality index, trend, quality indicators.

Введение. В настоящее время на нефтеперерабатывающих установках в условиях непостоянного состава и расхода поступающего сырья важной задачей является повышение качества основных видов нефтепродуктов и увеличение выхода светлых нефтепродуктов и, следовательно, экономической эффективности их производства.

Для контроля качества применяется лабораторный анализ, поточные анализаторы, виртуальные анализаторы (ВА). ВА может либо входить в состав автоматизированной системы управления технологическим процессом (АСУ ТП) в составе системы поддержки принятия решений, либо существовать в виде интеллектуальной надстройки контура управления. ВА позволяют отслеживать параметры в режиме онлайн, дополняя существующие лабораторные системы. Создается математическая модель, выходом которой является неизмеряемый параметр качества нефтепродуктов. На вход модели можно подавать данные как из баз данных, так и из онлайн-источников, таких как ОРС. В случае отклонения показателя от желаемого возможно принимать решение по коррекции параметров процесса, не дожидаясь получения лабораторных анализов.

Ассортимент и объемы производства различных видов нефтепродуктов определяются структурой транспортного парка, сезонностью потребления, способом доставки, требованиями ГОСТов, технических регламентов. Требования к бензинам и дизельным топливам установлены в техническом регламенте «О требованиях к автомобильному и авиационному бензинам, дизельному и судовому топливу, топливу для реактивных двигателей и топочному мазуту», утвержденном Постановлением Правительства Российской Федерации от 27.02.2008 г. № 118. Технический регламент определяет единое обозначение экологического класса топлива – классификационный код (К2, К3, К4, К5), определяющий требования безопасности топлива. Класс топлива зависит от количества и качества присадок, используемых при его производстве.

В работе проведен обзор методов контроля качества нефтепродуктов, рассмотрены модели для прогнозирования температур начала и конца кипения светлых нефтепродуктов на нефтеперерабатывающих установках. Предложено применение методов кластеризации для анализа ассортимента и выработки нефтепродуктов, а также способ прогнозирования выработки нефтепродуктов с применением моделей, учитывающих фактор сезонности.

Контроль качества нефтепродуктов. Одним из важных показателей качества нефтепродуктов является фракционный состав, определяемый в химико-аналитических лабораториях (ХАЛ) нефтеперерабатывающих заводов. В настоящее время применяются системы управления лабораторной информацией (ЛИМС, лабораторные ин-

формационные менеджмент-системы), которые позволяют управлять рабочим процессом лаборатории, результатами исследований, оборудованием, персоналом, но не выполняют функции управления качеством получаемой продукции.

В лаборатории для определения фракционного состава нефти и нефтепродуктов применяется разгонка по Энглеру (ГОСТ 2177–99). Определение фракционного состава определяется перегонкой в стандартной колбе путем постепенного испарения анализируемого образца при атмосферном давлении. Зарубежным аналогом данного метода является стандарт ASTM D86. Более точным способом определения фракционного состава является перегонка в аппарате АРН-2 (ГОСТ 11011–85). По результатам перегонки можно построить кривые истинных температур кипения (ИТК), определяющие температуру, при которой выкипает заданное количество вещества (мас. %). Аналогом данного метода является стандарт ASTM D1160.

В большинстве случаев оперативное управление технологическими процессами нефтепереработки осуществляется на основе сбора и первичной обработки данных, включающих в себя результаты применения измерительных средств, а также лабораторные анализы промежуточной и товарной продукции. Чем раньше будет известно о нарушении качественных показателей, тем меньше будут возможные издержки от потери качества. Наличие оперативного контроля позволяет в течение длительного времени поддерживать стабильно заданное качество нефтепродуктов.

В настоящее время задача оперативного контроля решается в том числе применением ВА показателей качества нефтепродуктов. ВА показателей качества нефтепродуктов установки представляет собой математическую зависимость между моделируемым показателем и параметрами технологического процесса, измеряемыми приборами непосредственно на технологической установке. Математические модели ВА подстраиваются на основе данных лабораторно-аналитического контроля. При поступлении по заводской сети из ЛИМС очередного значения лабораторного анализа система оценивает его статистическую состоятельность и целесообразность корректировки модели соответствующего ВА [1].

Основами моделей ВА могут быть регрессионная зависимость (в том числе в виде многомерного сплайна), нейронная сеть, генетиче-

ские алгоритмы. Часто применяемой моделью ВА является регрессия, т.е. поиск коэффициентов в заранее заданной функции. Это может быть полином, сплайн, нелинейная зависимость (экспонента, например) и т.д. Метод синтеза для регрессии – это метод наименьших квадратов (МНК) или точная интерполяция. Например, в работах [2–4] применяется линейная многофакторная модель ВА. В работе [5] приведены ВА, построенные на основе нейронной сети. В работе [6] предложены ВА, полученные с использованием оценок от наборов базовых альтернативных моделей.

В настоящее время на крупных нефтеперерабатывающих заводах (НПЗ) применяется технология виртуального мониторинга технологического процесса, например Yokogawa (система создания ВА RQE), Honeywell (Profit Sensor Pro), Aspen Technology (Aspen IQ), Emerson (Delta V Neural). Следует отметить, что перечисленные системы являются дорогостоящими для малых НПЗ [7].

Приведем вариант построения моделей ВА в виде авторегрессионных зависимостей показателей качества от технологических параметров процесса.

Как известно, авторегрессионные модели имеют вид [8]:

$$y(t_k) = a_0 + \sum_{i=1}^N a_i \cdot y(t_{k-i}), \quad (1)$$

где N – порядок модели.

По экспериментальным данным действующей нефтеперерабатывающей установки (оперативным листам и данным ХАЛ) получены математические модели для температур начала и конца температур кипения светлых нефтепродуктов атмосферного блока установки. В нашем случае в авторегрессионной зависимости кроме лагового значения показателя качества в виде факторной переменной содержатся технологические параметры.

Получены следующие авторегрессионные зависимости:

$$T_{\text{ККБ}}(t) = k_1 + k_2 \cdot T_{\text{ККБ}}(t-1) + k_3 \cdot F_6 - k_4 \cdot F_{\text{ОР}} + k_5 \cdot T_{\text{в}}, \quad (2a)$$

$$T_{\text{НКДТ}}(t) = k_6 + k_7 \cdot T_{\text{НКДТ}}(t-1) + k_8 \cdot F_{\text{ВПО}} - k_9 \cdot T_{13} + k_{10} \cdot F_{\text{с}}, \quad (2б)$$

$$T_{\text{ККДТ}}(t) = k_{11} + k_{12} \cdot T_{\text{ККДТ}}(t-1) - k_{13} \cdot F_{\text{ЦО}} - k_{14} \cdot F_{\text{ОР}} + k_{15} \cdot F_{\text{ДТ}} + k_{16} \cdot T_{13}, \quad (2в)$$

где $T_{\text{ККБ}}, T_{\text{НКДТ}}, T_{\text{ККДТ}}$ – температуры начала кипения, конца кипения бензиновой, дизельной фракции, °С; $F_6, F_{\text{ДГ}}, F_{\text{ВПО}}$ – расходы бензиновой, дизельной фракции, перегретого водяного пара в отпарную колонну, м³/ч; $F_{\text{ОР}}, F_{\text{ЦО}}$ – расход верхнего и циркуляционного орошений, м³/ч; F_c – расход сырья, м³/ч; T_v – температура верха колонны, °С; T_{13} – температура выхода дизельной фракции, °С; $k_1 - k_{16}$ – коэффициенты, определяемые методом наименьших квадратов (МНК); $T_{\text{ККБ}}(t-1), T_{\text{НКДТ}}(t-1), T_{\text{ККДТ}}(t-1)$ – температуры начала кипения, конца кипения бензиновой, дизельной фракции в предыдущий момент времени $(t-1)$, °С.

Коэффициенты $k_1 - k_{16}$ в (2а), (2б), (2в) определяются с использованием МНК:

$$S = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow \min, \quad (3)$$

где y_i – экспериментальное значение показателя качества; \hat{y}_i – значение показателя качества, определенное по модели; n – число экспериментальных точек.

Коэффициенты в (2а)–(2в) по условию (3) находились в MATLAB с помощью функций *mldivide* и *regress* [9]. Исходные данные формируются в Excel.

Получены следующие значения коэффициентов авторегрессионных зависимостей:

$$\begin{aligned} a_1 = 74,473\ 7; a_2 = 0,135\ 4; a_3 = 0,649\ 9; a_4 = -0,745\ 7; a_5 = 0,673\ 1; \\ a_6 = 292,878\ 8; a_7 = 0,246\ 1; a_8 = 0,472\ 5; a_9 = -0,829\ 8; a_{10} = 0,708\ 0; \\ a_{11} = 324,167\ 6; a_{12} = 0,180\ 8; a_{13} = -14,185\ 9; a_{14} = \\ = -1,861\ 6; a_{15} = 1,269\ 3; a_{16} = 3,141\ 0. \end{aligned}$$

Критерием адекватности моделей является скорректированный коэффициент детерминации [9]:

$$R^2 = 1 - \frac{Q_e}{Q_y} \cdot \frac{n-1}{n-m-1}, \quad Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad Q_y = \sum_{i=1}^n (y_i - y_{\text{cp}})^2, \quad (4)$$

где \hat{y}_i – значения показателя качества, определенные по модели; y_i – экспериментальные значения показателя качества; y_{cp} – среднее выбо-

рочное значение показателя качества; m – число факторных переменных; n – число экспериментальных точек.

Скорректированный коэффициент детерминации температуры конца кипения бензиновой фракции равен 0,882; температуры начала кипения дизельной фракции – 0,514, а температуры конца кипения дизельной фракции – 0,721.

Также рассчитываем среднюю относительную погрешность:

$$\xi = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \cdot 100\%. \quad (5)$$

Средняя относительная погрешность температуры конца кипения бензиновой фракции равна 0,25 %; температуры начала кипения дизельной фракции – 1,34 %, а температуры конца кипения дизельной фракции – 1,17 %.

Результаты вычислений средней относительной погрешности по формуле (5) для температур, определяемых по зависимостям (2), не превышают 2 %. Приведенные значения говорят об адекватности построенных моделей и их пригодности для прогнозирования.

Применение методов кластеризации для анализа ассортимента и выработки нефтепродуктов. С целью выяснения закономерностей изменения ассортимента и выработки продуктов нефтепереработки воспользуемся кластерным анализом.

Кластерный анализ представляет собой совокупность методов многомерной классификации, целью которой является образование групп (кластеров) схожих между собой объектов. Достоинство кластерного анализа состоит в том, что он позволяет проводить разбиение объектов не по одному параметру, а по целому набору. Также кластерный анализ не накладывает никаких ограничений на вид рассматриваемых объектов. К методам кластеризации относятся следующие: итеративные (k -средних), иерархическая кластеризация (агломеративные, дивизимные методы), байесовский подход без учителя, построенные на нечеткой логике и др.

Инструментом решения поставленной задачи выбран программный пакет MATLAB. Кластеризация методом k -средних реализуется с применением функции *kmeans*. Функция использует итерационный алгоритм минимизации внутрикластерной суммы расстояний объектов кластера до его центра по всем k кластерам. Результат работы

иерархических методов представляется в виде дендрограммы. Дендрограмма представляет собой вложенную группировку объектов, которая изменяется на различных уровнях иерархии. Для иерархической кластеризации в MATLAB применяются функции *linkage*, *dendrogram* и др. Подробно алгоритмы решения задач кластерного анализа приведены, например, в работах [10–12].

Для решения вышеприведенной задачи в качестве признаков, по которым выполняется кластеризация, выбраны выработка и доля в структуре производства основных видов нефтепродуктов, получаемых на российских нефтеперерабатывающих заводах (НПЗ): топливо реактивное керосинового типа, мазут топочный, кокс нефтяной, битумы нефтяные дорожные, бензин автомобильный, топливо дизельное. В качестве исходных данных использовалась статистическая информация официальных сайтов [13, 14] за 2017–2018 гг.

На основе составленной табл. 1 в MATLAB сформирована матрица, в которой строки соответствуют объектам, а столбцы – признакам. Объектами являются федеральные округа РФ.

Таблица 1

Исходные данные для кластеризации

Федеральный округ	ЦФО	СЗФО	ЮФО	ПФО	УФО	СФО	ДВО
Выработка топлива, тыс. т / доли							
Топливо реактивное керосинового типа	2943	1772	1119	2520	261	2265	515
	0,1005	0,0900	0,0493	0,0388	0,0940	0,0845	0,1109
Мазут топочный	10761	7521	9711	16532	19	6169	597
	0,3274	0,3529	0,3604	0,2278	0	0,2096	0,0836
Кокс нефтяной	0	0	325	2194	364	703	139
	0	0	0,0134	0,0332	0,0465	0,0252	0,0313
Битумы нефтяные	1956	191	479	2249	26	769	67
	0,0602	0,0195	0,0139	0,0308	0,0042	0,0289	0,0114
Бензин автомобильный	7588	1778	2822	16009	1389	7214	1225
	0,2290	0,1282	0,1207	0,2259	0,2705	0,2408	0,2419
Топливо дизельное	9003	7305	12877	29372	4008	11464	2819
	0,2828	0,4092	0,4420	0,4431	0,5846	0,4107	0,5206

Примечание: ЦФО – Центральный федеральный округ, СЗФО – Северо-Западный федеральный округ, ЮФО – Южный федеральный округ, ПФО – Приволжский федеральный округ, УФО – Уральский федеральный округ, СФО – Сибирский федеральный округ, ДВО – Дальневосточный федеральный округ.

Методом k -средних по признаку «выработка» выполнено разбиение объектов на 3 кластера. Полученные результаты приведены в табл. 2.

Таблица 2

Результаты классификации выработки методом k -средних

Клас-тер	Объекты	Центроид (по 6 признакам)
1	Центральный федеральный округ, Северо-Западный федеральный округ, Южный федеральный округ, Сибирский федеральный округ	2025 8540 257 849 4850 10162
2	Уральский федеральный округ, Дальневосточный федеральный округ	388 308 251 47 1307 3414
3	Приволжский федеральный округ	2520 16532 2194 2249 16009 29372

Как видно из табл. 2, Приволжский федеральный округ выделен в отдельный кластер и по всем 6 признакам имеет высокие значения. Мощность НПЗ по ПФО составляет 118,64 млн т (42,1 %) от мощности крупных НПЗ РФ (281,4 т). За 2018 г. изменений в составе кластеров не произошло. Крупных нефтеперерабатывающих установок за этот период в эксплуатацию не введено.

Для анализа ассортимента выпускаемых топлив в качестве признака кластеризации выберем долю производства вышеперечисленных видов нефтепродуктов в общей структуре. Полученные результаты показаны в табл. 3.

Таблица 3

Результаты классификации ассортимента методом k -средних

Клас-тер	Объекты	Центроид (по 6 признакам)
1	Северо-Западный федеральный округ, Южный федеральный округ	0,0682 0,3802 0,0059 0,0139 0,0995 0,4323
2	Уральский федеральный округ, Дальневосточный федеральный округ	0,0695 0,0572 0,0430 0,0084 0,2287 0,5932
3	Сибирский федеральный округ, Цент- ральный федеральный округ, При- волжский федеральный округ	0,0690 0,2632 0,0188 0,0401 0,2400 0,3689

Из табл. 3 видно, что для первого кластера характерно сравнительно большое отношение доли дизельного топлива к доле автомобильного бензина. По сравнению с другими кластерами объекты первого кластера отличаются высокой долей производства мазута и низкой долей светлых нефтепродуктов (автомобильного бензина и дизельного топлива) и нефтяного кокса. Объекты второго кластера отличаются низкой долей производства топочного мазута и дорожного битума и высокой долей дизельного топлива в общей структуре производства. Особенностью объектов третьего кластера является малое значение соотношения долей дизельного топлива и автомобильного бензина (1,537) по сравнению с объектами первого (4,3447) и второго (2,5937) кластеров. При проведении кластерного анализа за 2018 г. Центральный федеральный округ входит в состав первого кластера.

Моделирование и прогнозирование выработки нефтепродуктов. Для построения прогнозирующих моделей выработки (производства) нефтепродуктов применяются следующие методы: методы экстраполяции временных рядов (Хольта [15], ARIMA (Autoregressive Integrated Moving Average) [16]), нейронные сети [17], метод экспертных оценок [18], гибридные методы [19, 20] и др.

При анализе статистических данных сайта Единой межведомственной информационно-статистической системы (ЕМИСС) <https://www.fedstat.ru/indicators> [14] в динамических рядах по выработке различных видов нефтепродуктов можно выделить сезонную составляющую. Предлагается прогнозировать выработку нефтепродуктов с применением моделей с сезонной составляющей.

Тренд-сезонный временной ряд можно представить в аддитивной или мультипликативной форме. На выбор аддитивной или мультипликативной модели влияет характер изменения амплитуды сезонных колебаний. Для аддитивной модели характерна примерно постоянная амплитуда, для мультипликативной – возрастающая или убывающая пропорционально тренду. В сложных случаях (например, тренд убывает, а амплитуда сезонной волны, наоборот, возрастает) для получения адекватной модели бывает недостаточно описания ряда с помощью простой мультипликативной или аддитивной модели с постоянной сезонной составляющей, тогда требуется сезонная корректировка.

Приведем последовательность построения математической модели временного ряда выработки светлых нефтепродуктов на примере

автомобильного бензина К5, выпускаемого в РФ. При наблюдении динамики выработки бензина за период 2013–2018 гг. по данным ЕМИСС можно выделить наличие сезонной компоненты с непостоянным размахом сезонной составляющей. Поэтому аппроксимируем исходные данные мультипликативной моделью.

Построение модели состоит из следующих основных шагов:

- выравнивание исходного временного ряда, например методом скользящей средней;
- определение сезонной составляющей;
- удаление сезонной компоненты из исходного ряда;
- определение вида тренда и расчет коэффициентов в выбранном уравнении тренда;
- расчет значений по построенной модели, определение остатков;
- выбор критериев и оценка качества полученной модели;
- постпрогноз и оценка качества постпрогноза.

Предлагается применять мультипликативную модель следующего вида:

$$\hat{Q} = \hat{T}_i \cdot S \cdot \varepsilon, \tag{6}$$

где \hat{T}_i – тренд; S – индексы сезонности; ε – остатки.

Сначала определим центрированную скользящую среднюю для исходного временного ряда. Индексы сезонности S определяются на шаге 2 последовательности построения модели:

- нахождение отношения фактических значений уровней ряда к полученной центрированной скользящей средней;
- определение среднего индекса сезонности и медианы за каждый месяц;
- корректировка индекса путем умножения значения медианы на поправочный коэффициент.

Месяц	01	02	03	04	05	06	07	08	09	10	11	12
S	1,08	0,97	1,01	0,93	0,96	0,96	0,99	1,01	0,94	0,97	1,04	1,11

В качестве тренда на шаге 3 могут применяться различные зависимости, например линейный тренд, показательная, степенная и другие функции [6]. Для улучшения качества аппроксимации предлагается использовать в виде трендовой составляющей авторегрессионную модель AR (*AutoRegressive*) следующего вида:

$$\hat{T}(t_i) = a_0 + a_1 \cdot T_2(t_{i-1}) + a_2 \cdot T_2(t_{i-2}), \quad (7)$$

где T_i – выработка бензина без учета сезонности, тыс. т; a_j – коэффициенты; t – время.

Коэффициенты a_j в модели (7) определяем с помощью МНК. Задачу идентификации решаем в MATLAB. Для этого применяем функцию *MATLAB mldivide*. Для определения порядка в модели авторегрессии используем частную автокорреляционную функцию (ЧАКФ). Для полученной ЧАКФ есть выбросы на первых двух лагах, а следующие коэффициенты не выходят за интервал и статистически незначимы. Для авторегрессионной модели вида (7) выбираем второй порядок.

Рассчитаем модельные значения выработки по зависимостям (6), (7). Качество полученной модели определим по средней относительной погрешности, формула (5).

Результаты вычислений средней относительной погрешности составляют 3,45 %. Приведенные значения говорят о точности построенной модели и возможности ее применения для прогнозирования исследуемого показателя.

На рисунке приведен график выработки автомобильного бензина класса К5, определенной по моделям (6), (7) по 60 фактическим значениям за период 2013–2017 гг.

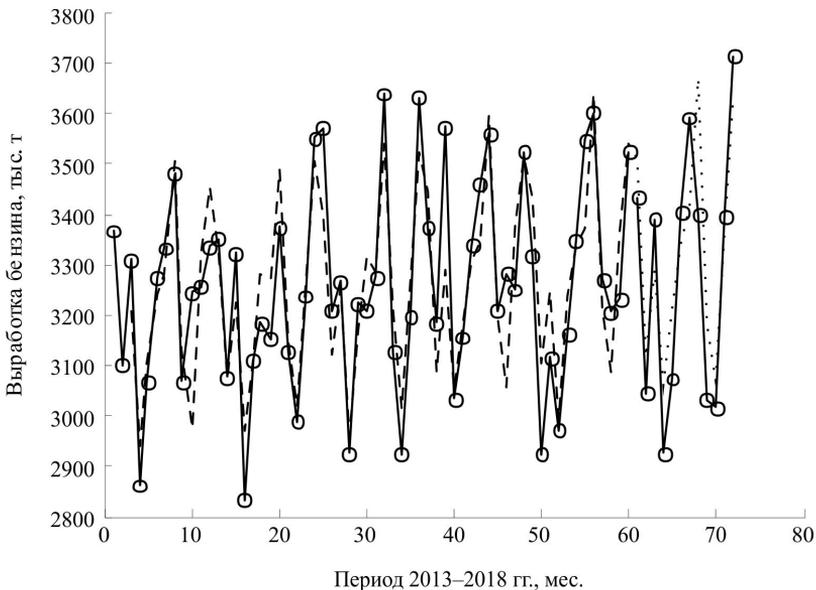


Рис. Выработка автомобильного бензина класса К5

Сплошной линией показаны исходные данные, пунктирной – модельные значения. Период 61–72 соответствует 2018 г. (12 значений), для которого выполнен постпрогноз со средней относительной погрешностью 4,81 %. Математические модели вида (6) получены также для федеральных округов. В этом случае средняя относительная погрешность моделирования не превышает 7 %, постпрогноза – не более 12 %.

Выводы. Получены математические модели показателей качества светлых нефтепродуктов (температур начала и конца кипения) в виде авторегрессионной модели с факторами – измеряемыми технологическими параметрами нефтеперерабатывающей установки. Предложено применение методов кластеризации для анализа ассортимента и выработки нефтепродуктов по федеральным округам РФ. По статистическим данным по выработке автомобильного бензина класса К5 за 5 лет в РФ и федеральным округам построена мультипликативная модель временного ряда с сезонной компонентой. Тренд представлен авторегрессионной моделью второго порядка. Выполнена оценка качества моделирования и постпрогноза с помощью полученной модели. Средняя относительная погрешность постпрогноза с горизонтом 1 год за 2018 г. по РФ составила 4,81 %, по федеральным округам – не превысила 12 %.

Список литературы

1. Усовершенствованное управление ТП: от контура регулирования до общезаводской оптимизации / П.Л. Логунов, М.В. Шаманин, Д.В. Кнеллер, С.П. Сетин, М.М. Шендерюк // Автоматизация в промышленности. – 2015. – № 4. – С. 4–14.
2. Жуков И.В., Харазов В.Г. Результаты поэтапной модернизации и эксплуатации усовершенствованной системы управления (АРС-системы) // Известия Санкт-Петербургского государственного технологического института (технического университета). – 2017. – № 41 (67). – С. 105–112.
3. Тугашова Л.Г. Прогнозирование показателей качества нефтепродуктов на установках первичной переработки нефти // Ученые записки Альметьевского государственного нефтяного института. – 2015. – Т. 14. – С. 99–103.
4. Хромов Д.А., Камалиев Т.С., Долганов А.В. Система усовершенствованного управления блока фракционирования установки гидрокрекинга // Вестник технологического университета. – 2018. – Т. 21, № 5. – С. 174–177.
5. Тугашова Л.Г. Виртуальные анализаторы показателей качества процесса ректификации // Электротехнические и информационные комплексы и системы. – 2013. – Т. 9, № 3. – С. 97–103.

6. Чинакал В.О. Проектирование виртуальных анализаторов с использованием альтернативных моделей // Системы проектирования, технологической подготовки производства и управления этапами жизненного цикла промышленного продукта (CAD/CAM/PDM – 2017): сб. тр. XVII междунар. науч.-практ. конф. – М.: Изд-во ИПУ РАН, 2017. – С. 364–367.

7. Затонский А.В., Тугашова Л.Г. Управление атмосферной колонной малого нефтеперерабатывающего завода с применением динамической модели // Наукоедение: интернет-журнал. – 2017. – Т. 9, № 1. – С. 71. – URL: <https://www.naukovedenie.ru/PDF/71TVN117.pdf> (дата обращения: 28.09.2019).

8. Ефимова М.Р. Статистика. – М.: ИНФРА-М, 2006. – 336 с.

9. Затонский А.В., Тугашова Л.Г. Моделирование объектов управления в MATLAB: учеб. пособие. – СПб.: Лань, 2019. – 144 с.

10. Fasulo D. An Analysis of Recent Work on Clustering Algorithms // Technical Report № 01-03-02 / University of Washington, Department of Computer Science and Engineering. – Seattle, 1999. – 23 p.

11. Григорьев Л.И., Санжаров В.В., Тупысев А.М. Интеллектуальный анализ данных: примеры нефтегазовой отрасли / РГУ нефти и газа им. И.М. Губкина. – М., 2015. – 121 с.

12. Zatonkiy A.V. Verification of Kolmogorov equation usability for reproduction and death processes // Вестник Южно-Уральского государственного университета. Сер.: Компьютерные технологии, управление, радиоэлектроника. – 2019. – Т. 19, № 3. – С. 60–67.

13. Единая межведомственная информационно-статистическая система (ЕМИСС) [Электронный ресурс]. – URL: <https://www.fedstat.ru/indicators> (дата обращения: 28.09.2019).

14. Федеральная служба государственной статистики РФ [Электронный ресурс]. – URL: <http://www.gks.ru> (дата обращения: 28.09.2019).

15. Кирхмеер Л.В., Бекеев Р.С. Моделирование и прогнозирование динамики производства нефтепродуктов в России // Молодой ученый. – 2015. – № 21. – С. 391–395.

16. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. OTexts, 2018. – 504 p. – URL: <https://otexts.com/fpp2> (accessed 28 September 2019).

17. Ba D., Shi G.R. Forecasting Petroleum Production Using the Time-Series Prediction of Artificial Neural Network // Advances in Petroleum Exploration and Development. – 2015. – Vol. 10, no. 2. – P. 1–6.

18. Тоткало Г.В., Хрипунова А.С. О некоторых подходах к прогнозированию спроса на рынке нефтепродуктов // Вестник университета. – 2015. – № 8. – С. 75–79.

19. ARIMA Model, Neural Networks and SSA in the Short Term Electric Load Forecast / K. Cassiano, M. Menezes, L.A. Junior, J. Pessanha, R. Souza, R. Souza // Economic Forecasting – Past, Present and Future, International Sympo-

sium of Forecasting ISF 2014, Rotterdam, Netherlands, 29 June – 2 July 2014. – 23 p. – URL: https://forecasters.org/wp-content/uploads/gravity_forms/7-2a51b93047891f1ec3608bdbc77ca58d/2014/07/Cassiano_Keila_ISF2014.pdf (accessed 28 September 2019).

20. Jabbarova K.I., Huseynov O.H. Forecasting petroleum production using chaos time series analysis and fuzzy clusterin // ICTACT Journal on Soft Computing. – 2014. – Vol. 4, iss. 4. – P. 791–795.

References

1. Logunov P.L., Shamanin M.V., Kneller D.V., Setin S.P., Shenderiuk M.M. Usovershenstvovannoe upravlenie TP: ot kontura regulirovaniia do obshchezavodskoi optimizatsii [Advanced process control: from control loop to plant-wide optimization]. *Avtomatizatsiia v promyshlennosti*, 2015, no. 4, pp. 4-14.

2 Zhukov I.V., Kharazov V.G. Rezul'taty poetapnoi modernizatsii i ekspluatatsii usovershenstvovannoi sistemy upravleniia (APC-sistemy) [The results of the gradual upgrading and operation of the advanced control system (APC system)]. *Izvestiia Sankt-Peterburgskogo gosudarstvennogo tekhnologicheskogo instituta (tekhnicheskogo universiteta)*, 2017, no. 41 (67), pp. 105-112.

3. Tugashova L.G. Prognozirovanie pokazatelei kachestva nefteproduktov na ustanovkakh pervichnoi pererabotki nefi [Forecasting of indicators of quality petroleum products for the installation of primary oil processing]. *Uchenye zapiski Al'met'evskogo gosudarstvennogo neftianogo instituta*, 2015, vol. 14, pp. 99-103.

4. Khromov D.A., Kamaliev T.S., Dolganov A.V. Sistema usovershenstvovannogo upravleniia bloka fraktsionirovaniia ustanovki gidrokrekinga [Improved control system of hydrocracker fractionation unit]. *Vestnik tekhnologicheskogo universiteta*, 2018, vol. 21, no. 5, pp. 174-177.

5. Tugashova L.G. Virtual'nye analizatory pokazatelei kachestva protsessa rektifikatsii [Virtual analyzers indicators of the quality of the rectification process]. *Electrical and data processing facilities and systems*, 2013, vol. 9, no. 3, pp. 97-103.

6. Chinakal V.O. Proektirovanie virtual'nykh analizatorov s ispol'zovaniem al'ternativnykh modelei [Design of virtual analyzers based on alternative models]. *Sistemy proektirovaniia, tekhnologicheskoi podgotovki proizvodstva i upravleniia etapami zhiznennogo tsikla promyshlennogo produkta (CAD/CAM/PDM – 2017), sbornik trudov XVII mezhdunarodnoi nauchno-prakticheskoi konferentsii*. Moscow, Institut problem upravleniia im. V.A. Trapeznikova Rossiiskoi akademii nauk. 2017, pp. 364-367.

7. Zatonskii A.V., Tugashova L.G. Upravlenie atmosfernoii kolonnoi malogo neftepererabatyvaiushchego zavoda s primeneniem dinamicheskoi modeli [Management of an atmospheric column of small oil refinery with application of dynamic model]. *Naukovedenie: internet-zhurnal*, 2017, vol. 9, no. 1, 13 p. available at: <https://naukovedenie.ru/PDF/71TVN117.pdf>. (accessed 28 September 2019).

8. Efimova M.R. Statistika [Statistics]. Moscow, INFRA-M, 2006, 336 p.
9. Zatonskii A.V., Tugashova L.G. Modelirovanie ob"ektov upravleniia v MATLAB [Modeling of the controlled object in the MATLAB]. Saint Petersburg, Lan', 2019, 144 p.
10. Fasulo D. An Analysis of Recent Work on Clustering Algorithms. Technical Report# 01-03-02, Department of Computer Science and Engineering, University of Washington, Seattle. 1999, 23 p
11. Grigor'ev L.I., Sanzharov V.V., Tupysev A.M. Intellekturnyi analiz dannykh: primery neftegazovoi otrasli [Data mining: examples of the oil and gas industry]. Moscow, Izdatel'skii tsentr Rossiiskogo gosudarstvennogo universiteta nefti i gaza imeni I.M. Gubkina, 2015, 121 p.
12. Zatonskiy A.V. Verification of Kolmogorov equation usability for reproduction and death processes. *Bulletin of the South Ural State University. Series Computer Technology, Automatic Control, Radio Electronics*. 2019, vol. 19, no. 3, pp. 60-67.
13. Edinaia mezhdovedomstvennaia informatsionno-statisticheskaia sistema (EMISS). available at: <https://www.fedstat.ru/indicators> (accessed 28 September 2019).
14. Federal'naiia sluzhba gosudarstvennoi statistiki. available at: <http://www.gks.ru> (accessed 28 September 2019).
15. Kirkhmeer L.V., Bekeev R.S. Modelirovanie i prognozirovanie dinamiki proizvodstva nefteproduktov v Rossii [Modeling and forecasting of the oil products production dynamics in Russia]. *Molodoi uchenyi*, 2015, no. 21, pp. 391-395.
16. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice. Australia, Melbourne, OTexts. 2018, 504 p. available at: <https://otexts.com/fpp2>. (accessed 28 September 2019).
17. Ba D., Shi G.R. Forecasting Petroleum Production Using the Time-Series Prediction of Artificial Neural Network. *Advances in Petroleum Exploration and Development*, 2015, vol. 10, no. 2, pp. 1-6.
18. Totkalo G.V., Khripunova A.S. O nekotorykh podkhodakh k prognozirovaniiu sprosa na rynke nefteproduktov [Some approaches to oil products demand forecasting]. *Vestnik universiteta*, 2015, no. 8, pp. 75-79.
19. Cassiano K., Menezes M., Junior L.A., Pessanha J., Souza R., Souza R. ARIMA Model, Neural Networks and SSA in the Short Term Electric Load Forecast. International Symposium of Forecasting ISF 2014 Economic Forecasting – Past, Present and Future, Rotterdam, Netherlands, 29 June – 2 July 2014. 23 p. available at: https://forecasters.org/wp-content/uploads/gravity_forms/7-2a51b93047891f1ec3608bdbd77ca58d/2014/07/Cassiano_Keila_ISF2014.pdf (accessed 28 September 2019).

20. Jabbarova K.I., Huseynov O.H. Forecasting petroleum production using chaos time series analysis and fuzzy clusterin. *ICTACT Journal on Soft Computing*, 2014, vol. 4, iss. 4, pp. 791-795.

Получено 28.09.2019

Сведения об авторах

Затонский Андрей Владимирович (Березники, Россия) – д-р техн. наук, профессор кафедры «Автоматизация технологических процессов», Березниковский филиал Пермского национального исследовательского политехнического университета (618404, Березники, ул. Тельмана, 7, e-mail: zhenon@narod.ru).

Тугашова Лариса Геннадьевна (Альметьевск, Россия) – старший преподаватель кафедры «Автоматизация и информационные технологии», Альметьевский государственный нефтяной институт (423458, Россия, Республика Татарстан, Альметьевск, ул. Ленина, 2, e-mail: tugashowa.agni@yandex.ru).

About the authors

Andrey V. Zatonskiy (Berezniki, Russian Federation) – Dr. Habil in Engineering, Professor, Department of Automation of Technological Processes, Berezniki branch of Perm National Research Polytechnic University (618404, Perm region, Berezniki, Telman st., 7, e-mail: anaserg2008@mail.ru).

Larisa G. Tugashova (Almetyevsk, Russian Federation) – Senior Lecturer, Department of Information Technologies and Automation Systems, Almetyevsk State Oil Institute (423458, Republica Tatarstan, Almetyevsk, Lenin st., 2, e-mail: tugashowa.agni@yandex.ru).