Вестник ВГУИТ/ Proceedings of VSUET ISSN 2226-910X E-ISSN 2310-1202
DOI: http://doi.org/10.20914/2310-1202-2026-3-20-30 Оригинальная статья/Research article
УДК 661.11+004.92 Open Access Available online at vestnik-vsuet.ru

Регрессионное прогнозирование периодических циклов химико-технологического производства для оценки технического состояния объектов топливно-энергетического комплекса

Лариса Г. Тугашова [1] tugashova@ya.ru 0000-0001-9331-3142
Андрей В. Затонский [2] zxenon@narod.ru 0000-0003-1863-2535

1 Альметьевский государственный технологический университет «Высшая школа нефти», ул. Советская, 186а, г. Альметьевск, 423462, Россия
2 Пермский национальный исследовательский политехнический университет, пр-т Комсомольский, 29, г. Пермь, 614990, Россия

Аннотация. Актуальность. Поставлена задача оперативного прогнозирования показателя производительности объектов топливно-энергетического комплекса на примере химико-технологического оборудования предприятия. Особенности каждой единицы оборудования возникают вследствие разброса характеристик в ходе периодического ремонта. В настоящее время для прогнозирования используется общая для всех единиц регрессионная зависимость, погрешность которой неудовлетворительная. Целью работы является снижение этой погрешности за счет разработки новых методов прогнозирования. Объект и методы. Исследована возможность применения для прогнозирования четырех регрессионных методов. Качество прогнозирования определялось методом постпрогноза на 3 и 6 отсчетов. Для каждого метода определены среднеквадратичная и среднемедианная погрешности в 50 случайно выбранных ситуациях на каждый горизонт постпрогноза. Ситуации выбирались таким образом, чтобы появилась возможность исследования зависимости погрешностей от начальной длины тренда, то есть количества месяцев работы прогнозируемого оборудования после последнего капитального ремонта. Для снижения трудозатрат использовались возможности оптимизации MS Excel. Результаты. Получены следующие рекомендации по использованию методов. Если оборудование выходит из ремонта или не проработало еще 3 месяца, наилучшим является копирование среднего тренда. В интервале 4-7 месяцев, наиболее сложном, наилучшим является предложенный автором метод. В интервале 7-30 месяцев конкурентными являются поиск кубической регрессии опорного тренда с уточнением в случае его недостаточной длины и копирование среднего тренда. Во всех случаях достигается примерно трехкратное снижение погрешности прогнозирования по сравнению с методом, используемым в настоящее время. При бóльшей длине опорного тренда ни один метод прогнозирования не обеспечивает существенного снижения погрешности. Заключение. Предлагаемый набор методов может использоваться для решения аналогичных задач в случаях, когда применение более совершенных методов, наподобие нейронных сетей, затруднено короткими рядами данных и их особенностями.

Ключевые слова: химико-технологическое производство, производительность, прогнозирование, моделирование.

Regression forecasting of periodic cycles of chemical engineering production for assessing the technical state of fuel and energy complex facilities

Larisa G. Tugashova [1] tugashova@ya.ru 0000-0001-9331-3142
Andrey V. Zatonskiy [2] zxenon@narod.ru 0000-0003-1863-2535

1 Almetyevsk State Technological University «Higher School of Petroleum», 186a, Sovetskaya st., Almetievsk, 423462, Russia
2 Perm national research polytechnic university, Komsomolsky avenue, 29, Perm, 614990, Russia

Abstract. Relevance. The task of operational forecasting of the productivity indicator of the chemical-technological equipment of the enterprise is set. The features of each piece of equipment arise due to the variation of characteristics during periodic repairs. Currently, a regression relationship common to all units is used for forecasting, the error of which is unsatisfactory. The aim of the work is to reduce this error by developing new forecasting methods. Object and methods. The possibility of using four regression methods for forecasting is investigated. The quality of forecasting was determined by the method of postprognosis for 3 and 6 counts. For each method, the root-mean-square and median errors were determined in 50 randomly selected situations for each post-forecast horizon. The situations were chosen in such a way that it was possible to study the dependence of errors on the initial length of the trend, that is, the number of months of operation of the predicted equipment after the last major overhaul. The optimization capabilities of MS Excel were used to reduce labor costs. Results. The following recommendations on the use of methods have been obtained. If the equipment is out of repair or has not worked for another 3 months, it is best to copy the average trend. In the interval of 4-7 months, the most difficult, the method proposed by the author is the best. In the range of 7-30 months, it is competitive to search for a cubic regression of the reference trend with refinement in case of insufficient length and copying the average trend. In all cases, an approximately threefold reduction in the prediction error is achieved compared to the method currently used. With a longer reference trend length, no forecasting method provides a significant reduction in error. Conclusions. The proposed set of methods can be used to solve similar problems in cases where the application of more advanced methods, such as neural networks, is hampered by short data series and their features.

Keywords: chemical and technological production, productivity, forecasting, modeling.

Для цитирования
Тугашова Л.Г., Затонский А.В. Регрессионное прогнозирование периодических циклов химико-технологического производства для оценки технического состояния объектов топливно-энергетического комплекса // Вестник ВГУИТ. 2026. Т. 88. № 3. С. 20–30. doi:10.20914/2310-1202-2026-3-20-30

For citation
Tugashova L.G., Zatonskiy A.V. Regression forecasting of periodic cycles of chemical engineering production for assessing the technical state of fuel and energy complex facilities. Vestnik VGUIT [Proceedings of VSUET]. 2026. vol. 88. no. 3. pp. 20–30. (in Russian). doi:10.20914/2310-1202-2026-3-20-30

© 2026, Тугашова Л.Г., Затонский А.В. / Tugashova L.G., Zatonskiy
This is an open access article distributed under the terms of the Creative Commons Attribution 4.0 International License

Введение

При управлении объектами топливно-энергетического комплекса (ТЭК) важным вопросом является оценка их технического состояния. Техническое состояние определяет способность оборудования работать в определенных диапазонах, обеспечивать заданную производительность. На производительность влияют различные факторы (температурный режим, периодичность ремонтов, сила тока и др.). Если не проводить своевременный ремонт и техническое обслуживание, могут возникать такие проблемы, как увеличение энергопотребления, риск аварий, нарушение теплового баланса из-за износа конструктивных элементов и др. В связи с этим для оценки влияния этих факторов возникает задача моделирования и прогнозирования технической готовности и энергоэффективности объектов ТЭК. С целью получения универсальных моделей, применимых для различных объектов ТЭК (в т. ч. электроэнергетических), исходные данные получены на одном из предприятий Госкорпорации «Росатом».

На предприятии имеется химико-технологическое оборудование, подлежащее периодическим ремонтам. В ходе каждого ремонта единица оборудования приобретает некоторые индивидуальные свойства (зазоры, толщины покрытий и т. д.), обусловленные особенностями технологического процесса. Кроме того, несмотря на однотипность оборудования, на его показатель влияет позиция оборудования в технологической цепочке: единицы оборудования сгруппированы по 12, и периодический отбор из них готового продукта зависит от этой позиции. Эти свойства влияют на производительность оборудования в момент начала эксплуатации после капитального ремонта, а также на динамику исчерпания ресурса. В процессе эксплуатации свойства оборудования ухудшаются и не могут быть восстановлены до следующего капитального ремонта. Нормативный межремонтный пробег составляет 36 месяцев, однако с учетом фактического состояния единица оборудования может быть выведена в ремонт раньше или позже.

На предприятии имеются помесячные данные о показателе производительности каждой из 72 единиц оборудования длиной 288 месяцев (отсчетов). Показатель исчисляется в процентах от некоторой максимальной теоретической величины. В среднем, он несколько первых месяцев улучшается, затем остается почти постоянным, затем начинает быстро ухудшаться. В настоящее время на предприятии для прогноза показателя используется общее для всего оборудования уравнение полиномиальной регрессии (рисунок 1), где X – номер месяца после ремонта. Обоснованность такого подхода сомнительна из-за индивидуальных особенностей, описанных выше. Кроме того, данные сильно зашумлены, то есть на значение показателя в каждом месяце влияют какие-то не известные случайные факторы, вызывающие существенное отклонение от приведенного выше «гладкого» графика. Для примера приведены тренды оборудований № 15 и № 62, выбранных случайно (рисунок 2, 3).

Предприятием поставлена задача прогнозирования технологического показателя для каждой единицы оборудования на некоторую перспективу вперед (1–12 месяцев) с целью обоснования поддержки управленческих решений по выводу в ремонт.

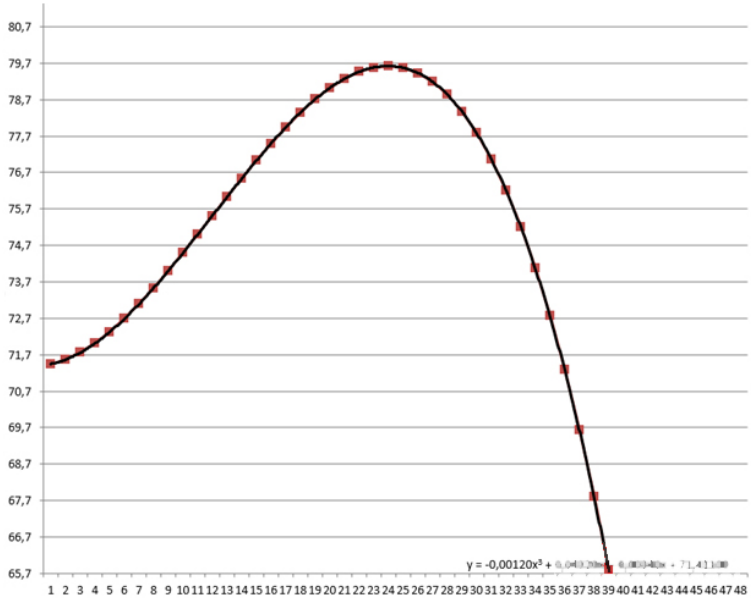


Рисунок 1. Используемый в настоящее время метод прогнозирования (получено с предприятия)

Figure 1. The forecasting method is currently used (got from the plant)

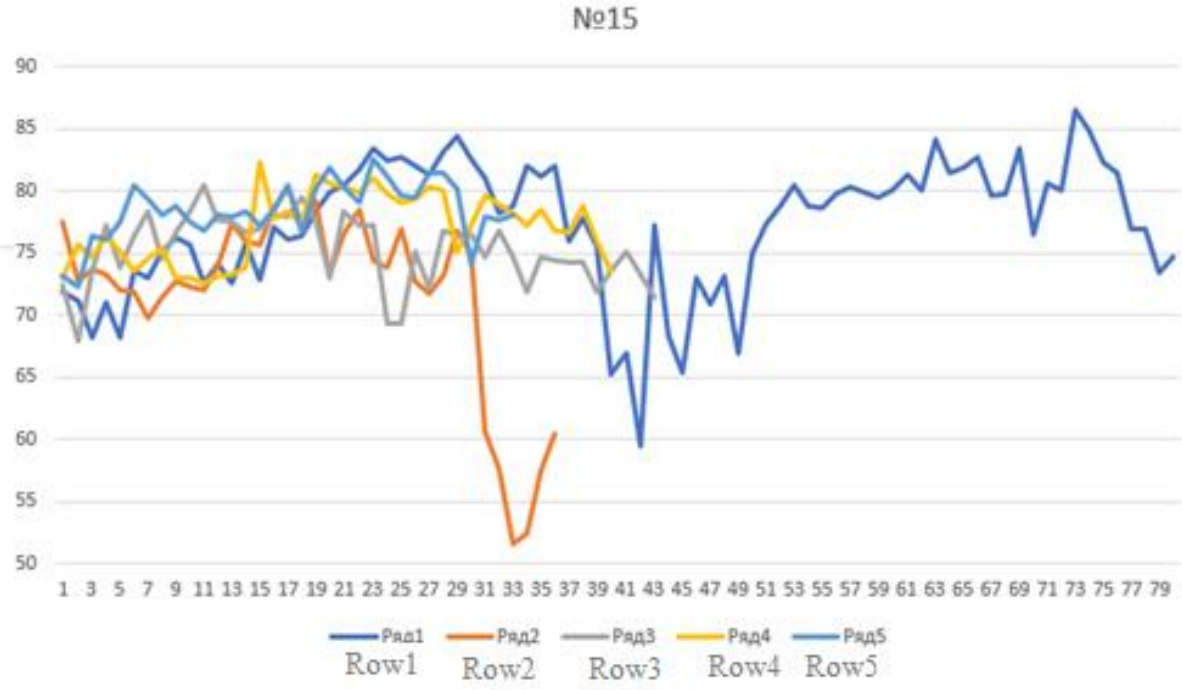


Рисунок 2. Пример трендов показателя оборудования № 15 (номер ряда – номер рабочего периода после очередного ремонта)

Figure 2. The example of equipment № 15 trends (row number – a number of working period after a major repair)

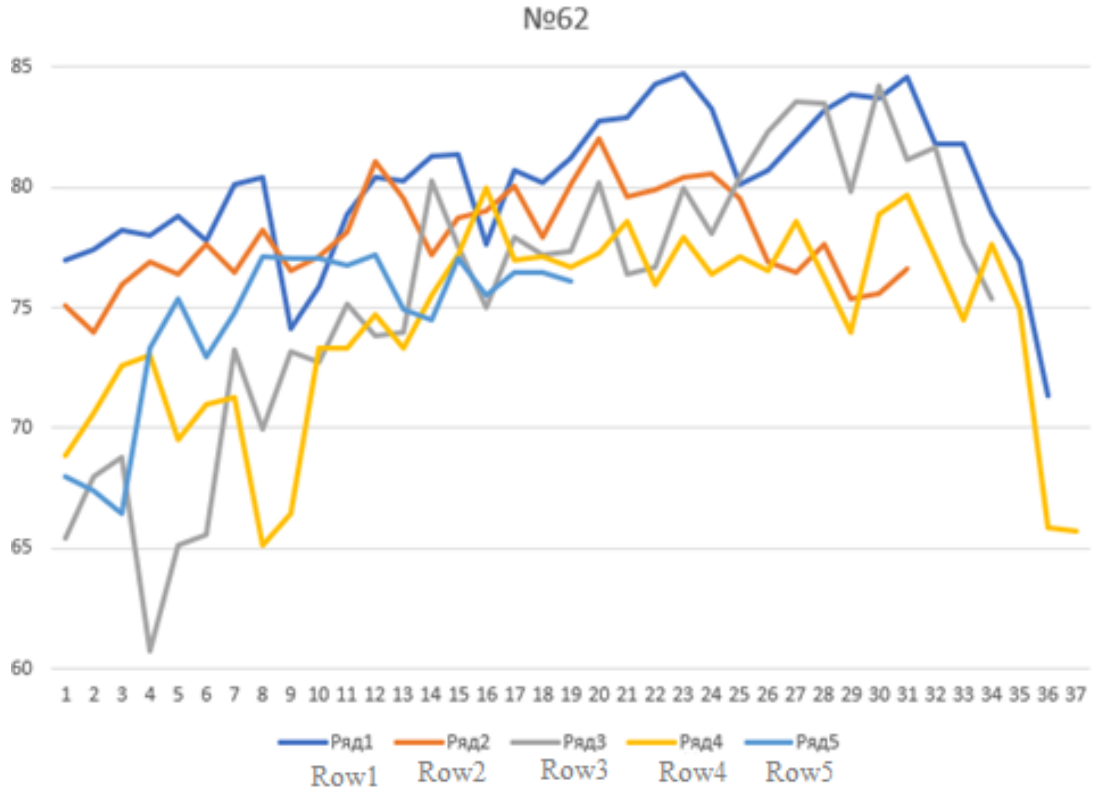


Рисунок 3. Пример трендов оборудования № 62 (номер ряда – номер рабочего периода после очередного ремонта)

Figure 3. The example of equipment № 62 trends (row number – a number of working period after a major repair)

Коэффициент корреляции любого из приведенных рядов с кубическим полиномом невелик и практически нигде не достигает значения 0,9. На рисунок 4 приведены примеры кубических аппроксимаций для двух рядов.

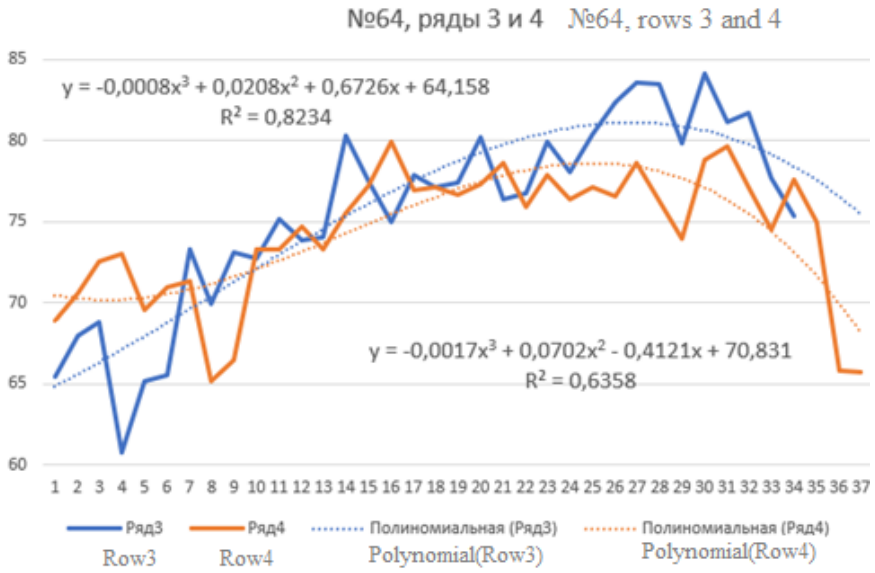


Рисунок 4. Корреляция некоторых трендов с кубической регрессией
Figure 4. Cubic regression correlation of come trends

Во всех случаях вариация (отношение стандартного отклонения к среднему значению) находится в пределах 2–7%. Следует ожидать, что никакие методы прогноза не смогут дать более точные значения (то есть с погрешностью ниже 2–7%), пока не будут построены факторные модели зависимости показателя от индивидуальных особенностей. В настоящее время данных для этого на предприятии нет, поэтому стоит вопрос о построении бесфакторной прогнозной модели, позволяющей улучшить существующий метод прогнозирования. Решение этой проблемы являются целью данной работы.

Прогнозированию состояния оборудования (производительности, технической готовности и прочим показателям) посвящено множество исследований, и выбор вида модели в данном случае весьма широк. Есть сведения об успешном применении как простейших алгоритмических моделей [1, 2], так и более сложных методов вплоть до нейронных сетей [3, 4]. Последние в данном случае сложно применить из-за малой длины трендов, с использованием которых будет происходить обучение или тестирование, а также их большой вариативности вследствие технологических особенностей. Тем не менее, вероятно, обоснованный ответ на вопрос об использовании искусственного интеллекта для решения данной задачи требует дополнительных исследований.

Следует отметить, что достаточно часто авторами в целях повышения качества прогнозирования предлагается не метод или алгоритм, а новый комплексный критерий, расчет которого более обеспечен исходными данными или более прост [5, 6], включая оптимизацию синтеза данного критерия [7], то есть решение совсем другой задачи, не связанной с производительностью завода. Проблемы существенной зашумленности исходных данных решаются обычно их предобработкой, основанной на слепой или неслепой фильтрации [8, 9]. Однако в данном случае приведенные методы не могут быть применены непосредственно из-за ограничений по доступности данным, а комплексирование критерия, очевидно, не требуется согласно поставленной задаче.

Единственный вопрос, который надо решить для выбора вида модели, это вопрос о значимости времени как существенного или несущественного фактора. То есть будет ли модель, как это сейчас принято на предприятии, учитывать номер месяца после пуска в эксплуатацию или же она будет авторегрессионной. Последний класс моделей имеет несомненное преимущество в тех случаях, когда явной связи между номером отсчета и показателем нет и не может быть. Например [10], когда предполагаемый срок службы оборудования после ремонта теоретически бесконечен, или при прогнозировании любых социально-экономических показателей [11], развитие которых ничем не ограничено во времени. Однако в данном случае априорно нет уверенности в том, что номер отсчета сам по себе не влияет на показатель, то есть этот вопрос требует отдельного исследования.

Материалы и методы

Предлагается использовать для прогнозирования какой-то из существующих уже трендов этого же оборудования, так как особенности конкретного оборудования не похожи на особенности другого. Например, на рисунок 3 видно, что оборудование на трендах 1 и 4 ведет

себя очень «похоже» – и там, и там возникает «провал» в какие-то месяцы. Хотя формально коэффициенты корреляции между этими трендами невысокие. В случайно выбранных 30 парах трендов (каждая пара относится к одной и той же единице оборудования) корреляция между ними находится в пределах 0–75%, среднемедианное значение находится в районе 18% (рисунок 5).



Рисунок 5. Упорядоченные значения случайно выбранных корреляций между рядами данных

Figure 5. Ordered values of randomly selected correlations between trends

Высокий уровень «шума» предлагается снизить традиционным пятиточечным сглаживанием, достаточно эффективным [12] для обработки данных, полученных с химико-технологического оборудования:

$$y_i = \frac{y_{i-2} + y_{i-1} + y_i + y_{i+1} + y_{i+2}}{5},$$

где i – номер отсчета, y_i – исходные значения. Сглаживание является обоснованным подходом, так как позволяет снизить ошибку, возникающую из-за неизвестных случайных факторов. При этом крайние точки тренда не сглаживаются, предкрайние – по аналогичному трехточечному алгоритму [13]. Все дальнейшие действия производятся только со сглаженными данными.

На момент начала прогнозирования каждая единица оборудования может находиться в трех состояниях, существенно различных с точки зрения прогнозирования:

1. В ремонте;
2. Только что вышло из ремонта и отработало 1 месяц;
3. Вышло из ремонта ранее и отработало несколько месяцев.

Напрашивается использование какой-то разновидности сценарного подхода [14, 15], так как очевидно, что в каждой из данных ситуаций необходим свой метод прогнозирования. Например, в ситуациях 1 и 2 принципиально невозможно использовать регрессионное или авторегрессионное продолжение тренда из-за недостатка исходных данных.

Для целей прогнозирования будем предполагать, что, если оборудование находится в ремонте (состояние № 1), то в момент начала прогнозирования оно выходит из ремонта. Если это не так, пользователь-прогнозист сам его «отключит». В состоянии № 1 предлагается моделировать прогнозный период по среднему значению, полученному из всех записанных ранее трендов. Ведь неизвестно, с каким качеством произведен ремонт, какие именно особенности получило оборудование в результате. Поэтому наиболее обоснованным представляется просто использование формирование начала прогнозного тренда по усредненным показателям того же оборудования.

Если оборудование вышло из ремонта и отработало ровно 1 месяц (состояние № 2), можно попробовать найти такой тренд, начальная точка которого наиболее близка к полученному в этот месяц значению. За критерий рассогласования берется квадрат разности между первыми значениями всех трендов $y_{1,i}$ и значением $y_{1,j}$, полученным в первый месяц последнего тренда [16]:

$$k = \arg\min_{i=1,\,j-1} \left(y_{1,j} - y_{1,i} \right)^2,$$

где j – номер начавшегося тренда, в котором есть только одно значение. После этого из k-го столбца сглаженных данных выбирается массив данных прогноза.

Для оборудования, находящегося в состоянии № 3, будем искать тренд из числа предыдущих, коэффициент корреляции которого с текущим трендом максимальный. Такой подход основан на простом предположении, что в ходе ремонта сейчас и какого-то из ремонтов, выполненных ранее, оборудование может получить схожие особенности, определяющие характер тренда. Рассчитав коэффициент корреляции по общеизвестным формулам [17], выберем тот сглаженный тренд, квадрат коэффициента корреляции которого с последним трендом наибольший. Однако если начать механически переносить данные выбранного тренда в качестве прогнозных, может возникнуть «ступенчатая» погрешность в момент начала прогноза, вызванная расхождением трендов. Ведь коэффициент корреляции, в отличие от критерия (2), характеризует не минимальное расстояние между рядами, а возможность воспроизвести данные одного ряда через данные другого. Иначе говоря, если у рядов $y_{k,i}$ и $y_{k,j}$ высокий коэффициент взаимной корреляции, то можно найти такие константы A и B, которые на протяжении всего ряда позволят вычислить

$$y_{k,j} = A + B \cdot y_{k,i}$$

или наоборот. То есть «зигзаги» одного ряда повторяют зигзаги другого, при этом между ними может быть какое-то постоянное смещение (A), и может быть некоторый коэффициент отношения одного ряда к другому (B). Поскольку наши данные имеют нелинейный характер по времени (отсчету), логично предположить, что и коэффициент отношения В может изменяться по времени. Поэтому для корректировки значений i-го ряда (будем называть его опорным) и получений на его основе прогнозных значений j-го ряда выполним следующие действия, составляющие один из предлагаемых методов прогнозирования:

1. Найдем для всех k известных значений обоих рядов значения $B_k = y_{k,j} / y_{k,i}$.

2. Предположив, что B_k имеет линейную зависимость от номера отсчета, найдем коэффициенты этой зависимости и рассчитаем значения B_k для отсчетов, в которых требуется построить прогноз.

3. Найдем в этих отсчетах прогнозные значения $y_{k,j}$ из известных значений опорного сглаженного ряда $y_{k,i}$: $y_{k,j} = B_k \cdot y_{k,i}$. Если опорный ряд закончился, вместо значения опорного ряда возьмем значение усредненного ряда.

Однако длина опорного ряда может быть недостаточной для того, чтобы по нему можно было рассчитать прогнозные значения. В этом случае можно либо выбирать следующие по убыванию коэффициента корреляции ряды до тех пор, пока их длина не окажется достаточной, либо заменить значения опорного ряда на усредненные. В данной работе принят второй подход.

Описанный алгоритм, по сути, является субъективным, или волюнтаристским. Он предложен «как есть», а не научным методом-то есть путем сравнения с разными другими методами прогнозирования. Однако это не мешает определить его эффективность, за которую будем принимать уменьшение погрешности прогнозирования по сравнению с прогнозами с использованием полиномиальной регрессии. Так как неизвестны ни случайные воздействия на оборудование, ни случайные характеристики, полученные в результате ремонта, ни их влияние на целевой показатель, нет возможности точно воспроизводить колебания значений. Именно по этому будем оценивать только снижение погрешности по сравнению с существующим методом.

Технически воспользуемся приемом, называемым «постпрогноз» [18]:

1. Произвольно «обрежем» данные по какому-то месяцу, то есть будем использовать для моделирования только данные до него (но так, чтобы известными остались несколько цельных трендов рабочих циклов).

2. Найдем прогноз с использованием полиномиальной модели по исходным данным одного этого же, последнего тренда. Рассчитаем его фактическую погрешность путем сравнения с известными значениями. Ведь, на самом деле, за месяцем «обрезки» значения целевого показателя тоже известны, только не использовались для построения модели, поэтому вполне можно найти действительную абсолютную или относительную погрешность.

3. Найдем прогноз с использованием полиномиальной модели по исходным данным сглаженного усредненного тренда за известный период (до месяца обрезки). Последний тренд может быть значительно короче усредненного, коэффициенты кубического полинома методом наименьших квадратов можно найти только, если в нем не менее 5 значений. Однако именно он отражает особенности, полученные оборудованием в ходе последнего ремонта. Усредненный тренд имеет длину 30–40 отсчетов вне зависимости от соотношения последнего тренда и месяца «обрезки».

4. Найдем прогноз на тот же период, просто скопировав значения сглаженного усредненного тренда, как это делали выше в ситуации № 2. Его значений всегда не меньше, чем у расчетного тренда.

5. Найдем прогноз на тот же период вышеописанным методом, вычислим погрешность.

6. Сравним погрешности (2), (3), (4) и (5).

«Горизонтом» постпрогноза [19] назовем количество отсчетов, на которое будет строиться постпрогноз (после месяца «обрезки» данных).

Чтобы не решать системы уравнений при поиске коэффициентов полиномиальной (п. 2 и п. 3) модели, технически это сделано путем программного использования мастера «Поиск решения» MS Excel [20] на отдельном листе, куда копируется столбец усредненных данных (рисунок 6).

На рисунке хорошо видно, что расчетный ряд данных и ряд, полученный путем добавления тренда, совпадают. Совпадают также коэффициенты, разумеется, отличаясь точностью представления.

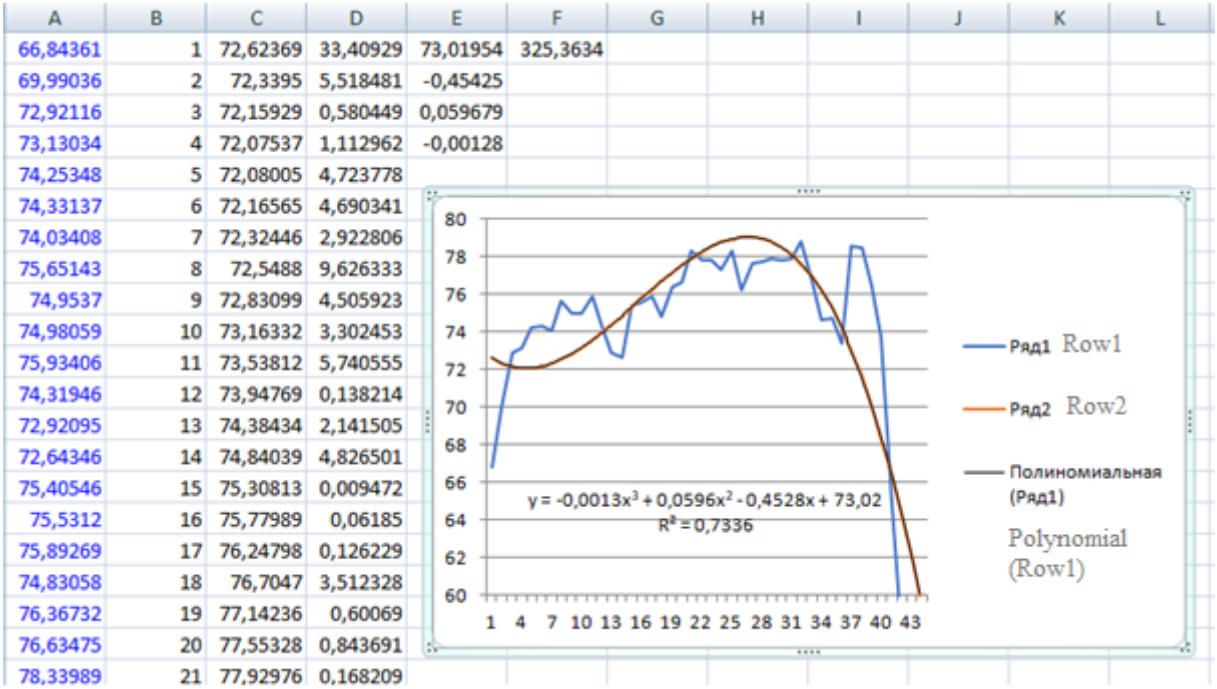


Рисунок 6. Лист поиска коэффициентов кубического полинома

Figure 6. Cubic polynomial coefficient search worksheet

Исследование качества постпрогноза выполнено при горизонтах прогноза 3 отсчета и 6 отсчетов. В каждом случае рассчитано по 10 единиц оборудования на каждый «обрезанный» отсчет, отличающихся длиной последнего тренда. Оборудование выбиралось таким образом, чтобы его фактический тренд не прерывался в течение горизонта постпрогноза. Всего получено по 50 результатов на каждом горизонте.

Результаты и обсуждение

Качество постпрогноза оценивалось по сумме квадратичных отклонений от фактического значения на всех отсчетах постпрогноза (чем меньше – тем лучше). Отмечу, что при указанной выше вариации в ±7% на 3 отсчетах совершенно несущественными можно считать суммарное среднеквадратичное отклонение $1.14^3 = 1.48$, на 6 отсчетах $1.14^6 = 2.19$.

Проведенные эксперименты позволяют сделать следующие выводы (таблица 1).

Таблица 1.

Сводные результаты моделирования

Table 1.

Final results of the simulation

Метод Method	Результат Result	Точек Points		Среднеквадратичная погрешность Root-Mean-Square Error		Медиана Median		Исходная погрешность Initial error	
		3	6	3	6	3	6	3	6
2	Лучший Best	19	5	1,78	18,55	10,65	19,04	5,34	55,65
	Худший Worst	7	17	2758,86	16311,98	80,04	226,77		
3	Лучший Best	12	12	1,23	12,75	7,64	20,61	3,69	25,50
	Худший Worst	10	10	212,17	243,26	56,26	80,19		
4	Лучший Best	11	17	1,95	5,73	9,62	18,26	1,95	11,47
	Худший Worst	12	5	767,54	507,40	64,32	125,12		
5	Лучший Best	7	16	2,79	9,41	8,89	33,00	5,58	28,23
	Худший Worst	20	18	1379,89	63253,64	47,35	263,65		

В таблице 1 для каждого метода (2–5) приведены случаи, в которых он оказался наилучшим и наихудшим с точки зрения погрешности постпрогноза на 3 или 6 отсчетов. В колонке «Точек» приведено количество раз (из 50), когда метод оказывался наилучшим или наихудшим. Далее указаны достигнутая среднеквадратичная погрешность и её медианное значение, а также исходная погрешность прогнозирования, полученная по формуле, приведенной на рисунок 1.

При постпрогнозе на 3 отсчета алгоритм (5) выглядит хуже других методов. Он меньше раз оказался лучшим и больше – худшим. Однако его медианные значения сопоставимы с другими и даже лучше. Это означает, что более чем в половине случаев он будет давать более достоверный результат, чем другие. Отношение погрешности алгоритма (5) к погрешности лучшего (в каждом конкретном случае) метода приведено на рисунок 7. Видно, что метод (5) редко хуже, чем лучший метод, в 10 и более раз.

При постпрогнозе на 6 отсчетов картина меняется. Несмотря на то, что статистически метод (5) становится лучше других, его медианная погрешность растет. На рисунок 8 видно, что теперь она редко превышает лучшую более, чем в 20 раз.

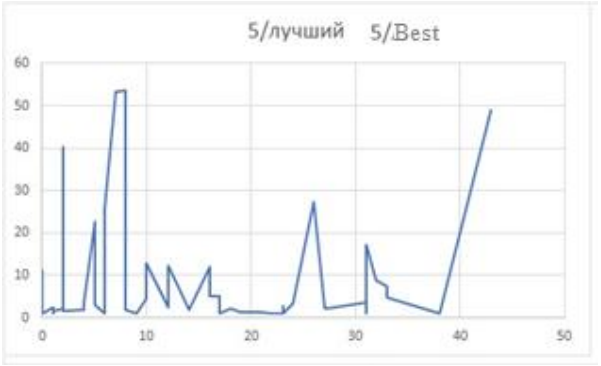


Рисунок 7. Отношение погрешности алгоритма (5) к погрешности лучшего алгоритма при прогнозировании на 3 отсчета

Figure 7. The ratio of the error of algorithm (5) to the error of the best algorithm when predicting for 3 samples



Рисунок 8. Отношение погрешности алгоритма (5) к погрешности лучшего алгоритма при прогнозировании на 6 отсчетов

Figure 8. The ratio of the error of algorithm (5) to the error of the best algorithm when predicting for 6 samples

Общие рекомендации по прогнозированию следующие.

Метод (2), аналогичный используемому теперь на предприятии (поиск кубической зависимости по остатку текущего тренда) применять не рекомендуется вовсе. Даже при прогнозировании на 3 отсчета (рисунок 9) его средняя погрешность весьма высока.

Методы (3) и (4) (рисунок 9, 10 соответственно) можно рекомендовать применять в интервалах 7–23 и 7–30 отсчетов. Напомню, что метод (3) это поиск кубической аппроксимации по среднему тренду и выборка из него подходящих значений, а (4) – просто копирование точек среднего тренда.

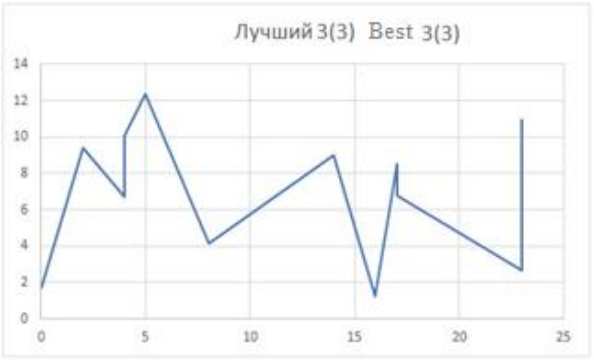


Рисунок 9. Погрешность метода (3) при прогнозировании на 3 отсчета

Figure 9. Error of method (3) when forecasting for 3 samples



Рисунок 10. Погрешность метода (4) при прогнозировании на 3 отсчета

Figure 10. Error of method (4) when forecasting for 3 samples

Так как технически метод (4) проще, при краткосрочном прогнозировании он, в целом, предпочтительнее других методов. Это говорит о том, что индивидуальные особенности ремонта, сборки, наладки оборудования проявляются мало. В целом, от ремонта к ремонту одна и та же единица оборудования проявляет похожие характеристики.

При прогнозировании на 6 отсчетов для «старта» тренда остановленного ранее оборудования или в случае, если оборудование проработало 1–3 месяца, лучше выбирать алгоритм (5). То есть подбирать наименее отличающийся по первой точке сглаженный тренд и пытаться его воспроизвести. Другие алгоритмы никогда не оказывались лучшими в этой ситуации. Однако погрешность алгоритма (5) при поиске наиболее похожего в первых значениях тренда весьма высока. То есть всё же лучше искать наиболее близкий тренд, а не похожий по начальным колебаниям (рисунок 11).



Рисунок 11. Погрешность метода (5) при прогнозировании на 6 отсчетов

Figure 11. Error of method (5) when forecasting for 6 samples

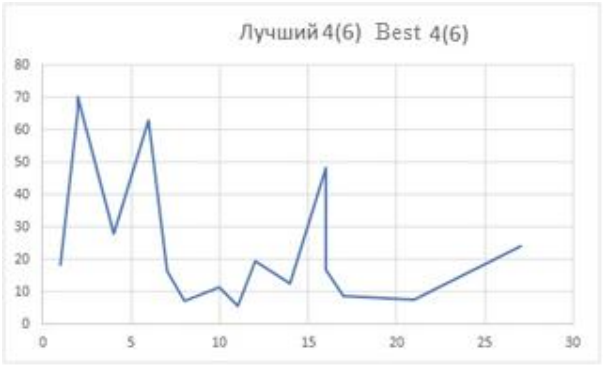


Рисунок 12. Погрешность метода (4) при прогнозировании на 6 отсчетов

Figure 12. Error of method (4) when forecasting for 6 samples

При наличии 7–20–25 отсчетов метод (4) снова становится лучшим (рисунок 12). Дальше у всех методов, кроме (5), быстро растет погрешность.

Следует понимать, что ни один метод прогнозирования никогда точно не воспроизведет будущие колебания. Он может в среднем быть лучше или хуже другого метода, но на практике от прогноза обязательно будут отклонения, превышающие примерно ±7%. Для иллюстрации приведу случай, когда прогноз по методу (5) оказался лучше, чем (4) (рисунок 13).

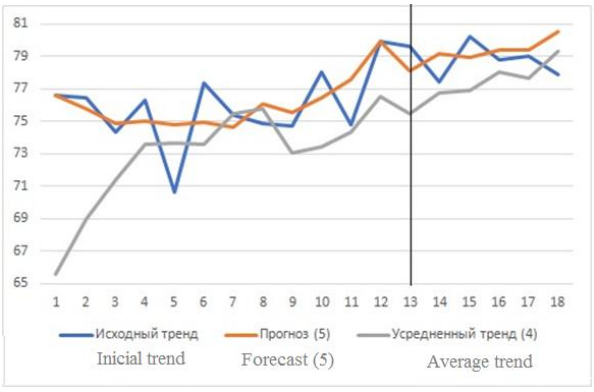


Рисунок 13. Постпрогноз (последние 6 отсчетов) методами (4) и (5) по сравнению с фактическим трендом

Figure 13. Postforecast (last 6 samples) by methods (4) and (5) compared to the actual trend

Заключение

Предложенный набор простых регрессионных методов прогнозирования, в отличие от используемого на предприятии сейчас, учитывает особенности оборудования, приобретенные в ходе капитального ремонта, за счет использования в качестве исходных данных трендов только той же единицы оборудования, что моделируется. За счет этого удалось снизить погрешность моделирования примерно втрое. Однако задача точного предсказания колебаний показателя вокруг среднего предсказанного значения навряд ли может быть решена с применением регрессионных бесфакторных моделей. Возможность её решения при помощи нейронных сетей также представляется спорной, поскольку исходные ряды данных достаточно короткие и «шумные» для качественного обучения сети.

Тем не менее, достигнутое существенное уточнение прогнозной модели, бесспорно, приведет к положительным изменениям в системе поддержки принятия решений предприятия по эксплуатации каждой единицы технологического оборудования.

Благодарности

Работа выполнена за счет средств гранта, предоставленного Академией наук Республики Татарстан образовательным организациям высшего образования, научным и иным организациям на поддержку планов развития кадрового потенциала в части стимулирования их научных и научно-педагогических работников к защите докторских диссертаций и выполнению научно-исследовательских работ (Соглашение № 9/2025 ПД-ВШН).

Литература

1 Soldatov E.S. Information Processing Algorithms in Tasks of Monitoring and Predicting the State of Cryogenic Equipment // Journal of Computational and Engineering Mathematics. 2023. V. 10. № 4. P. 60–67. doi: 10.14529/jcem230405

2 Егурцов С.А., Иванов Ю.В., Ерехинский Б.А., Тимошенко И.С. Совершенствование системы прогнозирования технического состояния и ресурса устьевого оборудования скважин // Инженер-нефтяник. 2017. № 2. С. 54–59.

3 Мустафина С.И., Жиляков С.А. Применение нейронных сетей для диагностики и прогнозирования технического состояния оборудования // Автоматизация и информатизация ТЭК. 2023. № 7 (600). С. 13–21. doi: 10.33285/2782-604X-2023-7(600)-3-21

4 Lazarevska M., Cvetkovska M., Knezevic M. Neural Network Prognostic Model for Predicting the Fire Resistance of Eccentrically Loaded RC Columns // Applied Mechanics and Materials. 2014. V. 627. P. 276–282. doi: 10.4028/www.scientific.net/AMM.627.276

5 Герике П.Б., Герике Б.Л. Прогнозирование ресурса горного оборудования с использованием единого диагностического критерия его технического состояния // Техника и технология горного дела. 2022. № 3 (18). С. 4–22. doi: 10.26730/2618-7434-2022-3-4-24

6 Nemtinov V., Egorov S., Nemtinova Y., Kalach F. Information support for decision-making in emergency situations // Journal of Physics: Conference Series. 2021. V. 1902. P. 012080. doi: 10.1088/1742-6596/1902/1/012080

7 Новикова Т.А., Ляпунцова Е.В. Разработка инструмента прогнозирования состояния оборудования с учетом выбора оптимальной функции надежности // Контроль. Диагностика. 2025. Т. 28. № 6 (324). С. 46–51. doi: 10.14489/td.2025.06.pp.046-051

8 Костенко Д.А., Олейников В.С., Хохловский В.Н. Предобработка зашумленных данных перед нейросетевым анализом // Сборник трудов конференции. СПб.: ПОЛИТЕХ-ПРЕСС, 2024. С. 230–237. doi: 10.18720/SPBPU/2/id24-168

9 Володина Ю.И., Затонский А.В., Рахимова О.В., Середкина О.В. Прогнозная модель процесса флокуляции на основе нейронной сети // Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника. 2017. Т. 17. № 2. С. 42–50. doi: 10.14529/ctcr170204

10 Тугашова Л.Г., Затонский А.В. Моделирование и прогнозирование производства нефтепродуктов с учетом сезонности на основе авторегрессионных моделей // Известия Томского политехнического университета. Инжиниринг георесурсов. 2020. Т. 331. № 5. С. 109–119. doi: 10.18799/24131830/2020/5/2641

11 Арженовский С.В. Прогнозирование динамики цены и оценка риска инвестиций в золото // Экономический анализ: теория и практика. 2015. № 20 (419). С. 50–56.

12 Бильфельд Н.В., Володина Ю.И. Формирование кривой разгона объекта управления по импульсной динамической характеристике // Автоматизация. Современные технологии. 2019. Т. 73. № 11. С. 505–509.

13 Bilfeld N.V. Identification of Control Objects in Some Estimation Tools // European Journal of Computer Science. 2016. V. 1. № 2. P. 4–14. doi: 10.13187/ejcs.2016.2.4

14 Наумов И.В., Никулина Н.Л. Сценарное моделирование и прогнозирование степени износа основных фондов предприятий обрабатывающей промышленности в регионах России // Экономические и социальные перемены: факты, тенденции, прогноз. 2022. Т. 15. № 4. С. 155–171. doi: 10.15838/esc.2022.4.82.10

15 Zhukovskiy Y., Koshenkova A., Vorobeva V. et al. Assessment of the Impact of Technological Development and Scenario Forecasting of the Sustainable Development of the Fuel and Energy Complex // Energies. 2023. V. 16. P. 3185. doi: 10.3390/en16073185

16 Hong Y.Y., Chan Y.H. Short-term electric load forecasting using particle swarm optimization-based convolutional neural network // Engineering Applications of Artificial Intelligence. 2023. V. 126. P. 106773. doi: 10.1016/j.engappai.2023.106773

17 Пчелинцева С.В., Никаноров М.С., Малыха Е.Ф., Сергеева Н.В. Применение методов машинного обучения для оптимизации режимов добычи полезных ископаемых // Известия Тульского государственного университета. Науки о Земле. 2025. № 4. С. 361–366.

18 Григалашвили А.С., Кокшарова Л.Ф., Зуева И.О. О применимости корреляционного анализа для исключения факторов в регрессионно-дифференциальных моделях // Вестник Тамбовского ГТУ. 2016. Т. 22. № 1. С. 35–44. doi: 10.17277/vestnik.2016.01.pp.035-044

19 Zatonskiy A., Sirotina N., Bazhenov R. Finite-differential models used as a basis for IT support in problem-solving // IOP Conference Series: Materials Science and Engineering. 2020. V. 1047. P. 012040. doi: 10.1088/1757-899X/1047/1/012040

20 Кириллова Д.А. Использование электронных таблиц при обучении математике студентов инженерных направлений // Вестник Приамурского государственного университета им. Шолом-Алейхема. 2022. № 1 (46). С. 100–110.

References

1 Soldatov E.S. Information Processing Algorithms in Tasks of Monitoring and Predicting the State of Cryogenic Equipment. Journal of Computational and Engineering Mathematics. 2023. vol. 10. no. 4. pp. 60–67. doi: 10.14529/jcem230405.

2 Egurtsov S.A., Ivanov Yu.V., Erekhinsky B.A., Timoshenko I.S. Improvement of the system for forecasting the technical condition and service life of wellhead equipment. Petroleum Engineer. 2017. no. 2. pp. 54–59. (in Russian).

3 Mustafina S.I., Zhilyakov S.A. Application of neural networks for diagnostics and forecasting of equipment technical condition. Automation and Informatization of the Fuel and Energy Complex. 2023. no. 7 (600). pp. 13–21. doi: 10.33285/2782-604X-2023-7(600)-3-21 (in Russian).

4 Lazarevska M., Cvetkovska M., Knezevic M. Neural Network Prognostic Model for Predicting the Fire Resistance of Eccentrically Loaded RC Columns. Applied Mechanics and Materials. 2014. vol. 627. pp. 276–282. doi: 10.4028/www.scientific.net/AMM.627.276.

5 Gerike P.B., Gerike B.L. Forecasting the service life of mining equipment using a unified diagnostic criterion of its technical condition. Technique and Technology of Mining. 2022. no. 3 (18). pp. 4–22. doi: 10.26730/2618-7434-2022-3-4-24 (in Russian).

6 Nemtinov V., Egorov S., Nemtinova Y., Kalach F. Information support for decision-making in emergency situations. Journal of Physics: Conference Series. 2021. vol. 1902. article 012080. doi: 10.1088/1742-6596/1902/1/012080.

7 Novikova T.A., Lyapuntsova E.V. Development of a tool for forecasting equipment condition taking into account the choice of the optimal reliability function. Control. Diagnostics. 2025. vol. 28. no. 6 (324). pp. 46–51. doi: 10.14489/td.2025.06.pp.046-051 (in Russian).

8 Kostenko D.A., Oleinikov V.S., Khokhlovsky V.N. Preprocessing of noisy data before neural network analysis. In: Conference Proceedings. Saint Petersburg: POLYTECH-PRESS, 2024. pp. 230–237. doi: 10.18720/SPBPU/2/id24-168 (in Russian).

9 Volodina Yu.I., Zatonsky A.V., Rakhimova O.V., Seredkina O.V. Predictive model of the flocculation process based on a neural network. Bulletin of SUSU. Series: Computer Technologies, Control, Radio Electronics. 2017. vol. 17. no. 2. pp. 42–50. doi: 10.14529/ctcr170204 (in Russian).

10 Tugashova L.G., Zatonsky A.V. Modeling and forecasting of oil products production taking into account seasonality based on autoregressive models. Bulletin of Tomsk Polytechnic University. Geo Assets Engineering. 2020. vol. 331. no. 5. pp. 109–119. doi: 10.18799/24131830/2020/5/2641 (in Russian).

11 Arzhenovsky S.V. Forecasting price dynamics and assessing investment risk in gold. Economic Analysis: Theory and Practice. 2015. no. 20 (419). pp. 50–56. (in Russian).

12 Bilfeld N.V., Volodina Yu.I. Formation of the acceleration curve of a control object based on pulse dynamic characteristics. Automation. Modern Technologies. 2019. vol. 73. no. 11. pp. 505–509. (in Russian).

13 Bilfeld N.V. Identification of Control Objects in Some Estimation Tools. European Journal of Computer Science. 2016. vol. 1. no. 2. pp. 4–14. doi: 10.13187/ejcs.2016.2.4.

14 Naumov I.V., Nikulina N.L. Scenario modeling and forecasting of the degree of depreciation of fixed assets of manufacturing enterprises in the regions of Russia. Economic and Social Changes: Facts, Trends, Forecast. 2022. vol. 15. no. 4. pp. 155–171. doi: 10.15838/esc.2022.4.82.10 (in Russian).

15 Zhukovskiy Y., Koshenkova A., Vorobeva V. et al. Assessment of the Impact of Technological Development and Scenario Forecasting of the Sustainable Development of the Fuel and Energy Complex. Energies. 2023. vol. 16. article 3185. doi: 10.3390/en16073185.

16 Hong Y.Y., Chan Y.H. Short-term electric load forecasting using particle swarm optimization-based convolutional neural network. Engineering Applications of Artificial Intelligence. 2023. vol. 126. article 106773. doi: 10.1016/j.engappai.2023.106773.

17 Pchelintseva S.V., Nikanorov M.S., Malykha E.F., Sergeeva N.V. Application of machine learning methods for optimizing mineral extraction modes. Bulletin of Tula State University. Earth Sciences. 2025. no. 4. pp. 361–366. (in Russian).

18 Grigalashvili A.S., Koksharova L.F., Zueva I.O. On the applicability of correlation analysis for excluding factors in regression-differential models. Bulletin of Tambov State Technical University. 2016. vol. 22. no. 1. pp. 35–44. doi: 10.17277/vestnik.2016.01.pp.035-044 (in Russian).

19 Zatonskiy A., Sirotina N., Bazhenov R. Finite-differential models used as a basis for IT support in problem-solving. IOP Conference Series: Materials Science and Engineering. 2020. vol. 1047. article 012040. doi: 10.1088/1757-899X/1047/1/012040.

20 Kirillova D.A. The use of spreadsheets in teaching mathematics to engineering students. Bulletin of Sholom-Aleichem Priamursky State University. 2022. no. 1 (46). pp. 100–110. (in Russian).

Сведения об авторах

Лариса Г. Тугашова к.т.н., доцент, Школа цифрового инжиниринга, Альметьевский государственный технологический университет «Высшая школа нефти», ул. Советская, 186а, г. Альметьевск, 423462, Россия, tugashova@ya.ru
https://orcid.org/0000-0001-9331-3142

Андрей В. Затонский д.т.н., профессор, кафедра автоматизации технологических процессов, Березниковский филиал Пермского национального исследовательского политехнического университета, пр-т Комсомольский, 29, г. Пермь, 614990, Россия, zxenon@narod.ru
https://orcid.org/0000-0003-1863-2535

Information about authors

Larisa G. Tugashova Cand. Sci. (Engin.), associate professor, School of digital engineering, Almetyevsk State Technological University «Higher School of Petroleum», Sovetskaya st., 186a, Almetievsk, 423462, Russia, tugashova@ya.ru
https://orcid.org/0000-0001-9331-3142

Andrey V. Zatonskiy Dr. Sci. (Engin.), professor, automation of technological processes department, Perm National Research Polytechnic University Berezniki Branch, Komsomolsky avenue, 29, Perm, 614990, Russia, zxenon@narod.ru
https://orcid.org/0000-0003-1863-2535

Вклад авторов

Лариса Г. Тугашова написание и корректировка рукописи
Андрей В. Затонский написание и корректировка рукописи

Contribution

Larisa G. Tugashova manuscript preparation and editing
Andrey V. Zatonskiy manuscript preparation and editing

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Поступила 01/07/2026	**После редакции** 18/07/2026	**Принята в печать** 20/08/2026

Received 01/07/2026	**Accepted in revised** 18/07/2026	**Accepted** 20/08/2026