

УДК 004.032.26

DOI 10.24412/2413-7383- 2025-3-38-148-156

А. А. Личман, О. Ю. Чередникова

Федеральное государственное бюджетное образовательное учреждение
высшего образования «Донецкий национальный технический университет»
283001, Донецкая Народная Республика, г. Донецк, ул. Артёма, 58

АЛГОРИТМ ИНТЕЛЛЕКТУАЛИЗАЦИИ ПРЕДУПРЕЖДЕНИЯ СБОЕВ АСУ НА ОСНОВЕ ПРЕДИКТИВНОЙ АНАЛИТИКИ

А. А. Lichman, O. Yu. Cherednikova

Federal State Budgetary Educational Institution of Higher Education
"Donetsk National Technical University"
283001, Donetsk People's Republic, Donetsk, st. Artyoma, 58

AN ALGORITHM FOR INTELLECTUALIZING AUTOMATED CONTROL SYSTEM FAILURE PREVENTION BASED ON PREDICTIVE ANALYTICS

Внедрение автоматизированных систем управления затронуло практически все ключевые отрасли экономики. С конца прошлого века и по сей день среда, в которой существуют производства постоянно меняется, и автоматизированные системы управления вынуждены меняться вместе с ней. Так, в последние десять лет частичная интеллектуализация производств позволяет оптимизировать расходы. Предиктивная(прогнозная) аналитика – один из самых эффективных инструментов оптимизации. В данной статье при помощи статистического метода ARIMA и алгоритма машинного обучения случайный лес был внедрен алгоритм интеллектуализации. Проанализированы результаты внедрения алгоритма.

Ключевые слова: ARIMA, АСУ, интеллектуализация, временные ряды, машинное обучение, оптимизация.

The introduction of automated control systems has affected almost all key sectors of the economy. From the end of the last century to the present day, the environment in which production facilities exist is constantly changing, and automated control systems are forced to change with it. For example, in the last ten years, partial intellectualization of production facilities has made it possible to optimize costs. Predictive analytics is one of the most effective optimization tools. In this article, an intellectualization algorithm was implemented using the statistical ARIMA method and the random forest machine learning algorithm. The results of the algorithm implementation are analyzed.

Key words: ARIMA, automated control system, intellectualization, time series, optimization.

Анализ проблемы

В автоматизированных системах управления (АСУ) часто возникают конфликты программного обеспечения (ПО). Причины этих конфликтов могут быть различными, и методы их своевременного предотвращения востребованы, так как их следствием являются простои на производстве.

Примерами, сигнализирующими о нарушении работы АСУ, могут быть ошибки базы данных, аномальные значения датчиков, сбой алгоритмов управления (долгие отклики на команды), задержка в обработке данных и т.д.

Целью данной статьи является поиск способов своевременного прогнозирования сбоев и сброс нежелательных изменений, приводящих к ним.

1 Анализ существующих решений

Общепринятыми средствами решения вышеописанных проблем являются нейросетевые модели. Они были внедрены еще в начале 2010-х и достаточно быстро сократили число ошибок в наборах данных, отчетах, аварийных протоколах. Сейчас их используют везде: в промышленности, в обработке видео, данных, текстов [2]. Недостатком подобного подхода является высокая требовательность к вычислительным ресурсам, которую не всегда возможно компенсировать в достаточной мере.

Параллельно с нейросетевыми [3] моделями были внедрены составные модели, состоящие из статистических моделей и методов машинного обучения, не включающих искусственный интеллект (ИИ). Именно этот вариант наиболее прост во внедрении и не так требователен к ресурсам, однако его эффективность меняется в зависимости от среды внедрения и метода [4].

2 Алгоритм интеллектуализации предупреждения сбоев

Нарушения можно распознать, анализируя протоколы работы АСУ. Исключая сетевые сбои, влияние извне и человеческий фактор, прочие нарушения можно спрогнозировать на основе анализа аномальных значений.

Для анализа протоколов предлагается предиктивный метод с использованием машинного обучения для оптимизации результатов.

Метод предполагает в начале сбор данных и построение статистической модели ARIMA (AutoRegressive Integrated Moving Average) [5], далее обучение алгоритма интеллектуализации на основе прогнозов ARIMA, которые можно использовать как признаки, с использованием метода машинного обучения Случайный лес. В конце система (или пользователь, на основе предсказаний системы) принимает решение об отмене последних изменений в системе, последствием которых является обнаруженный сбой.

Исходными данными для задачи прогнозирования сбоев являются протоколы, значения которых замеряются на протяжении определенного периода времени и имеют форму временного ряда (рис. 1).

Обработка данных значений является основой предиктивного метода, используемого алгоритмом интеллектуализации предупреждения сбоев АСУ. Анализ этих данных выполняется на основе статистической модели ARIMA. В общем случае ARIMA используется для анализа временных рядов, ее применение напрямую не предполагает методы машинного обучения, однако именно в совокупности с ними модель раскрывает свой потенциал в качестве инструмента интеллектуализации систем [6]. Реализация модели включает авторегрессию, дифференцирование временного ряда и расчет скользящего среднего.

```

2025-03-07 09:34:00 - Response Time: 205ms
2025-03-07 09:35:00 - Response Time: 210ms
2025-03-07 09:36:00 - Response Time: 215ms
2025-03-07 09:37:00 - Response Time: 220ms
2025-03-07 09:38:00 - Response Time: 225ms
2025-03-07 09:39:00 - Response Time: 230ms
2025-03-07 09:40:00 - Response Time: 235ms
2025-03-07 09:41:00 - Response Time: 240ms

```

Рисунок 1 - Пример протокола с данными отклика

Прежде всего необходимо выполнить проверку ряда на стационарность, то есть на наличие тренда или сезонности, долгосрочного отклонения данных от нормы или постоянных скачков значений соответственно.

Стационарность временного ряда — необходимое условие для его анализа, иначе непредсказуемые данные на выходе дадут некорректную статистическую модель. Чтобы определить стационарен ли временной ряд, необходимо понять, имеет ли он единичный корень. Единичный корень — это характеристика, которая описывает поведение временного ряда, когда его значения не возвращаются к среднему или не имеют стабильной тенденции. Если ряд имеет единичный корень, он может вырасти или упасть без возвращения к первоначальному состоянию, и эта тенденция может продолжаться в будущем. Следовательно, в случае с наличием единичного корня ряд можно считать не стационарным и не пригодным для построения модели.

Математически единичный корень связан с уравнением авторегрессии, первой частью ARIMA (AR). Модель ARIMA для прогнозирования будущих значений временного ряда использует следующую формулу:

$$y_t = \alpha + \beta y_{t-1} + \Omega_t,$$

где y_t — значение временного ряда y в момент времени t ;

α — константное значение, к которому стремится ряд;

β — коэффициент авторегрессии;

y_{t-1} — значение временного ряда в предыдущий момент времени;

Ω_t — ошибка или шум [7].

Если значение коэффициента авторегрессии равно единице ($\beta = 1$), это говорит о наличии единичного корня и необходимости дифференцирования. Дифференцирование (вторая часть ARIMA) — это процесс, при котором мы вычисляем разницу между значениями ряда в соседних точках, чтобы убрать тренд или сделать ряд стабильным:

$$\Delta y_t = y_t - y_{t-1}$$

Вычитание значение ряда в предыдущий момент времени из значения в текущий момент, дает Δy_t , разницу. Если ряд был, например, растущим, то после дифференцирования получатся изменения (положительные или отрицательные), а не сами значения ряда [8].

Из ряда значений в миллисекундах, 230, 235, 240, 245, 250, таким образом получается ряд 5, 5, 5, 5, и тренд роста из 230 в 250 исчезнет.

Когда данные подготовлены и первоначальные прогнозы составлены можно приступить к третьей части ARIMA — нахождение скользящего среднего (Moving Average). Этот этап предполагает сравнение прогноза статистической модели с реальными данными и его улучшение; выполняется в соответствии с формулой:

$$\Omega_{t+1} = \theta_1 \cdot \Omega_t + \theta_2 \cdot \Omega_{t-1},$$

где Ω_{t+1} — ошибка в следующем периоде;

Ω_t — ошибка в текущем периоде;

Ω_{t-1} — ошибка в прошлом периоде;

θ_1 и θ_2 — коэффициенты, определяющие то, как ошибки прошлых периодов влияют на текущие погрешности [9].

Коэффициенты можно найти при помощи OLS (Ordinary Least Squares) — это метод, который подбирает такие значения коэффициентов, при которых сумма квадратов ошибок прогноза минимальна [10].

Получив эти данные и улучшив прогнозы, можно говорить об улучшении работы, однако простую статистическую модель нельзя назвать алгоритмом интеллектуализации и применять таким образом. ARIMA не извлекает признаки из данных, а подгоняет параметры по фиксированным математическим формулам, приведенным выше.

Используем один из методов машинного обучения — случайный лес — для обучения модели на основе результатов ARIMA.

Данный метод используется в решении задач классификации и регрессии [11]. Он состоит из множества отдельных моделей, называемых деревьями решений (decision trees), и комбинирует их результаты для улучшения точности прогноза. Это называется ансамблевым методом, потому что несколько моделей (деревьев) работают вместе, чтобы сделать более точный прогноз, чем одна модель.

Мы классифицируем точки, где остатки модели ARIMA выходят за порог погрешности, как аномалии. Это создаёт бинарную метку: 1 для аномальных значений, 0 для нормальных.

Каждая ветвь решает отдельно, какую метку присвоить текущим значениям. В конечном итоге бинарная метка равна 0 или 1 зависит от выбора большинства «ветвей», этот процесс называется «голосование».

Итого, алгоритм интеллектуализации предполагает использование ARIMA для предсказания значений ряда и использование машинного обучения для адаптации модели в условиях изменений. Это дает лучшую гибкость и исключение ситуаций, когда предполагаемая ошибка является объективным следствием работы прибора или другого ПО.

Для машинного обучения можно использовать несколько типов данных. Основной источник — это сам временной ряд с последовательностью наблюдений. Кроме того, полезны остатки модели — разница между реальными значениями и прогнозами ARIMA, показывающая точность предсказаний. Также можно применять прогнозы ARIMA — предсказанные моделью значения для будущего. Информативными также оказываются параметры модели — коэффициенты авторегрессии и скользящего среднего, отражающие влияние прошлых значений на текущие результаты.

Описанный алгоритм интеллектуализации был реализован на языке python, который имеет множество библиотек для работы как с временными рядами (в частности, в нем реализована модель ARIMA), так и с алгоритмами машинного обучения.

На рис. 2 показана реализация модели алгоритма интеллектуализации.

```
from statsmodels.tsa.arima.model import ARIMA
...
model = ARIMA(time_series_data, order=(p, d, q))
model_fit = model.fit()
...
X = df[['arima_residuals']] # Признаки
y = df['response_time'] # Целевое значение
...
residuals = model_fit.resid
...
predictions = model_fit.fittedvalues
...
stargazer = RandomForestRegressor(n_estimators=100)
stargazer.fit(X, y)
```

Рисунок 2 – Подготовка модели машинного обучения в python

Для модели ARIMA требуется задать следующие параметры:

p – порядок авторегрессии, то есть сколько предыдущих значений используется;

d – количество операций дифференцирования;

q – порядок скользящего среднего, то есть сколько ошибок будет учитываться при нахождении скользящего среднего;

Функция `RandomForestRegressor` выполняет обучение модели методом Случайного леса и предполагает задание следующих параметров;

n_estimators – количество ветвей;

X – матрица признаков, которая представляет собой набор данных, на основе которых модель будет делать прогнозы; эта матрица получается, автоматически используя ARIMA, а Y – целевое значение, которое мы пытаемся предсказать.

Итогом реализации алгоритма является прогнозируемый результат целевого значения отклика, который сравнивается с реальным, и на основе его делается вывод о корректности или аномальности значений, в виде бинарной метки.

3 Результаты внедрения алгоритма в АСУТП

Алгоритм интеллектуализации предупреждения сбоев был внедрен в АСУТП широкого назначения, выполняющую функции сбора, анализа и обработки технической информации, с последующим формированием и хранением необходимой документации в сфере гидрогеологии.

Основной причиной сбоев в исследуемой системе являются конфликты между ПО. Как и в случае с многими другими сбоями, признаком являются аномальные значения в протоколах, в данном случае значения API (*Application Programming Interface*) отклика. Данный набор правил и протоколов позволяет различным программным системам взаимодействовать и высокий отклик может свидетельствовать о нарушении в совместной работе программ.

Рассмотрим характеристики исследуемой АСУ:

Надежность исходного кода. Эта характеристика описывается вероятностью безотказной работы за определенный промежуток времени и определяется экспоненциальным законом надежности.:

$$R(t) = e^{-\lambda t}, \quad (1)$$

где $R(t)$ — вероятность того, что система будет работать без отказа в течение времени t ;
 λ — интенсивность отказов (среднее число отказов за единицу времени);
 t — время работы системы;
 e — математическая константа (примерно 2,718).

Модель предполагает, что сбои происходят независимо друг от друга и случаются с постоянной вероятностью во времени. Чтобы корректно использовать эту модель, следует воспринимать серию сбоев, вызванную одной первопричиной как один сбой [12].

В исследуемой АСУ было обнаружено 2 сбоя за неделю, следовательно, согласно (1), шанс того, что система будет работать без сбоев в течение недели составляет около 3 %.

Среднемесячное время простоя – 28 часов рабочего времени из них: 8 – запланированные часы технического обслуживания, в среднем 13,5 простои, связанные с техническими сбоями, и 6,5 с прочими причинами – отключение света, обстрелы и т.д.

Для объективного оценивания программной части АСУ существует намного больше характеристик, однако в рамках данного исследования этих величин будет достаточно [13].

В АСУ внедрен алгоритм интеллектуализации «Stargazer» на основе предиктивной аналитики временных рядов. В случае сбоев Stargazer осуществлял письменную рекомендацию отката ПО до последней работающей версии, и, если это давало результат – докладывал о несовместимости при помощи письменного отчета с указанием даты времени и причины неисправности. Далее в удобное для этого время специалистами устранялась несовместимость, которая могла вызвать аномальные значения. Коэффициент безотказной работы теперь стремится к 0, так как все сбои вызывали ни что иное как скорый откат системы к рабочему состоянию [14]. Однако, если рассматривать сбой и последующую реакцию на него системы в качестве сбоя, то в целом коэффициент не изменился и остался около 3 % [15].

Стоит отметить, что сократилось время простоя более чем в 3 раза, теперь простои по причине технических неисправностей составляют около часа в месяц, поскольку ПО откатывается до предыдущих значений при конфликте с оборудованием или другим программным обеспечением [16]. Из технических проблем остаются лишь сбои оборудования, на которые программно повлиять нельзя, однако даже тут сбор данных и критических значений оборудования помогает своевременно обнаружить и исправить поломку. И таким образом нивелируется стоимость простоя, уменьшив время простоя из-за технических неисправностей в 11 раз.

Заключение

Алгоритмы интеллектуализации являются универсальным инструментом для решения многих проблем с ПО в АСУ широкого назначения [17]. Для их эффективного использования необходимо понимать сферу внедрения. Внедренный на практике алгоритм в сумме дал незначительную экономию по времени, однако помог сэкономить человеческие усилия и значительно сэкономил производственный ресурс за счет ликвидации простоев из-за сбоев [18], и возможности планирования техобслуживания.

Следует отметить, что, к сожалению, сами технические сбои никуда не исчезают, то есть использование алгоритмов интеллектуализации чаще всего не устраняет сбой как явление, а лишь помогает справиться с их последствиями [19], тем самым улучшая параметры АСУ. Дальнейшее развитие нейронных сетей и алгоритмов машинного обучения позволит выполнять с их помощью значительное число задач [20].

Список литературы

1. Pikalyov YA.S. Obzor arhitektur sistem intellektual'noj obrabotki estestvenno-yazykovykh tekstov. *Problemy iskusstvennogo intellekta*. 2020. № 4 (19). S. 45-68.
2. Burlaeva E.I., Zori S.A. Sravnenie nekotorykh metodov mashinnogo obucheniya dlya analiza tekstovykh dokumentov. *Problemy iskusstvennogo intellekta*. 2019. № 1 (12). S. 42-51.
3. Ковальчук Ю. Н. Прогнозирование временных рядов с использованием комбинированных моделей ARIMA и машинного обучения / Ковальчук Ю. Н., Павлова Н. А. *Математическое моделирование*. 2021. Т. 33, № 4. С. 56-67.
4. Antsyferov S.S., Sigov A.S. Tekhnologicheskie osnovy postroeniya intellektual'nykh sistem. *Problemy iskusstvennogo intellekta*. 2016. № 1 (2). S. 34-44.
5. Бобровский А. Ю. *Прогнозирование временных рядов с использованием модели ARIMA* / Бобровский А. Ю. М.: Научный мир, 2015. 210 с.
6. Гусев В. В. *Машинное обучение для анализа данных: от линейных моделей до нейронных сетей* / Гусев В. В. СПб.: БХВ-Петербург, 2018. 256 с.
7. Гаврилов И. В. Методы машинного обучения в прогнозировании временных рядов / Гаврилов И. В. *Журнал вычислительной математики и математической физики*. 2019. Т. 59, № 6. С. 877- 886.
8. Иванов Д. М. *Введение в модели ARIMA для анализа временных рядов* / Иванов Д. М. М.: "Финансовый мир", 2017. 190 с.
9. Куликов А. В. *Алгоритмы и методы оптимизации для анализа больших данных* / Куликов А. В. СПб.: Наука, 2019. 180 с.
10. Яковлев И. И. *Методы анализа и предсказания временных рядов с использованием ARIMA и нейросетей* / Яковлев И. И. СПб.: Бизнес-пресс, 2018. 08 с.
11. Agafonova M.S. Development of the adaptation management mechanism of an industrial enterprise. *Successes of Modern Natural Science*, 2011. pp. 71-72.
12. Чувииков, Д.А. *Модели и алгоритмы реконструкции и экспертизы аварийных событий дорожно-транспортных происшествий*: дис. ... канд. технич. наук: 05.13.01 / М., 2017. 318 с.
13. Сайт информационного агентства РИА. [Электронный ресурс]. Режим доступа: <https://ria.ru/20221017/predprivatiya-1824081417.html>
14. Тельнов, Ю. Ф. Развитие архитектур цифровых предприятий. *Научные труды Вольного экономического общества России*. 2021. Т. 230, № 4. С. 230-235. DOI 10.38197/2072-2060-2021-230-4-230-235. EDN RVLEES.
15. Ромашенко, М.А., Васильченко, Д.В., Пухов, Д.А. Использование нейросетевых алгоритмов для визуального контроля топологии печатных плат. *Вестник ВГТУ*. 2022. № 3.
16. Коновалова Г.И. Концептуальные и методологические основы цифровой трансформации машиностроительного предприятия. *Организатор производства*. 2023. № 1.
17. Новикова, В. Д. *Большие данные в промышленности. Современная наука: актуальные вопросы и перспективы развития : материалы Международной (заочной) научно-практической конференции*, София, Болгария, 25 декабря 2019 года. София, Болгария: Научно-издательский центр "Мир науки" (ИП Вострецов Александр Ильич), 2019. С. 225-228. EDN PYARHB.
18. Айларова, З. К., Дзакоев, З. Л. Цифровая модернизация производственных систем предприятий. *Экономика и управление: проблемы, решения*. 2019. Т. 6, № 1. С. 128-132. EDN NXWCHB.
19. Тихонов, И.А. Интеллектуализация предприятий электронной промышленности и управление рисками // И.А. Тихонов, С.С. Анцыферов. *Проблемы искусственного интеллекта*. 2023. № 4 (31). 29-39. <http://search.rads-doi.org/project/14374/object/210540> doi: 10.34757/2413-7383.2023.31.4.004
20. Теплова, О.В. Принципы распознавания психоэмоционального состояния личности в автоматизированных системах управления // О.В. Теплова, О.А. Криводубский. *Проблемы искусственного интеллекта*. 2023. № 4 (31). 20-28. <http://search.rads-doi.org/project/14374/object/210539> doi: 10.34757/2413-7383.2023.31.4.003

References

1. Pikalyov YA.S. Obzor arhitektur sistem intellektual'noj obrabotki estestvenno-yazykovykh tekstov // *Problem iskusstvennogo intellekta*. 2020. № 4 (19). S. 45-68.
2. Burlaeva E.I., Zori S.A. Sravnenie nekotorykh metodov mashinnogo obucheniya dlya analiza tekstovykh dokumentov // *Problem iskusstvennogo intellekta*. 2019. No. 1 (12). S. 42-51.
3. Kovalchuk Yu. N. Forecasting time series using combined ARIMA and machine learning models / Kovalchuk Yu. N., Pavlova N. A. // *Mathematical modeling*. - 2021. – Vol. 33, No. 4. – pp. 56-67.
4. Antsyferov S.S., Sigov A.S. Tekhnologicheskie osnovy postroeniya intellektual'nykh sistem // *Problem iskusstvennogo intellekta*. 2016. № 1 (2). S. 34-44.

5. Bobrovsky A. Yu. Forecasting time series using the ARIMA model / Bobrovsky A. Yu. – M.: Scientific world, 2015. – 210 p.
6. Gusev V. V. Machine learning for data analysis: from linear models to neural networks / Gusev V. V. – St. Petersburg: BHV-Petersburg, 2018. 256 p.
7. Gavrilov I. V. Machine learning methods in time series forecasting / Gavrilov I. V. // Journal of Computational Mathematics and Mathematical Physics. 2019. Vol. 59, No. 6. pp. 877-886.
8. Ivanov D. M. Introduction to ARIMA models for time series analysis / Ivanov D. M. – M.: "Financial World", 2017. 190 p
9. Kulikov A.V. Algorithms and optimization methods for big data analysis / Kulikov A.V. – St. Petersburg: Nauka Publ., 2019, 180 p.
10. Yakovlev I. I. Methods of analysis and prediction of time series using ARIMA and neural networks / Yakovlev I. I. – St. Petersburg: Business Press, 2018. – 208 p.
11. Agafonova M.S. Development of the adaptation management mechanism of an industrial enterprise. // Successes of Modern Natural Science, 2011. pp. 71-72.
12. Chuvikov, D.A. Models and algorithms for reconstruction and examination of emergency events of road accidents: dis. ... Candidate of Technical Sciences: 05.13.01 / M., 2017. 318 p.
13. The website of the RIA news agency. [electronic resource]. Access mode: <https://ria.ru/20221017/predpriyatiya-1824081417.html>
14. Telnov, Yu. F. Development of architectures of digital enterprises. Scientific works of the Free Economic Society of Russia. 2021. Vol. 230, No. 4. pp. 230-235. DOI 10.38197/2072-2060-2021-230-4-230-235. EDN RVLEES.
15. Romashchenko, M.A., Vasilchenko, D.V., Pukhov, D.A. The use of neural network algorithms for visual control of the topology of printed circuit boards. Bulletin of VSTU. 2022. № 3.
16. Konovalova G.I. Conceptual and methodological foundations of the digital transformation of a machine-building enterprise. Production organizer. 2023. № 1.
17. Novikova, V. D. Big data in industry. Modern science: current issues and development prospects : proceedings of the International (correspondence) Scientific and Practical Conference, Sofia, Bulgaria, December 25, 2019. Sofia, Bulgaria: Mir Nauki Scientific Publishing Center (IP Vostretsov Alexander Ilyich), 2019. pp. 225-228. EDN PYARHB.
18. Aylarova, Z. K., Dzakojev, Z. L. Digital modernization of production systems of enterprises. Economics and management: problems, solutions. 2019. Vol. 6, No. 1. pp. 128-132. EDN NXWCHB.
19. Tikhonov, I.A. Intellectualization of electronic industry enterprises and risk management // I.A. Tikhonov, S.S. Antsyferov // Problems of artificial intelligence. - 2023. № 4 (31). - 29-39. - <http://search.rads-doi.org/project/14374/object/210540> doi: 10.34757/2413-7383.2023.31.4.004
20. Teplova, O.V. Principles Of Recognizing The Psycho-Emotional State Of A Person In Automated Control Systems // O.V. Teplova, O.A. Krivodubsky // Problems of artificial intelligence. - 2023. № 4 (31). - 20-28. - <http://search.rads-doi.org/project/14374/object/210539> doi: 10.34757/2413-7383.2023.31.4.003

RESUME

A. A. Lichman, O. Yu. Cherednikova

An algorithm for intellectualizing automated control system failure prevention based on predictive analytics

The article discusses an algorithm for the intellectualization of fault prevention in an automated control system. It involves using the ARIMA statistical model for predictive analytics of the system's protocols and the Random Forest machine learning method to optimize results. The result of the algorithm is the predicted result of the target response value, which is compared with the real one, and based on it, a conclusion is drawn about the correctness or anomaly of the values.

Although the algorithm as a whole improves many indicators of the system, it is noted that there are different priority values. Depending on the choice of the implementation goal, the result will also change. If it is necessary to achieve maximum reliability, you will have to sacrifice something else.

The results of the implementation of the intellectualization algorithm in automated control systems used in the field of hydrogeology are analyzed. Even considering the limited implementation of the algorithm, the results and statistics show the prospect of such manipulations.

РЕЗЮМЕ

А. А. Личман, О. Ю. Чередникова

*Алгоритм интеллектуализации предупреждения сбоев в АСУ
на основе предиктивной аналитики*

В статье рассматривается алгоритм интеллектуализации предупреждения сбоев в автоматизированной системе управления. Он предполагает использование статистической модели ARIMA для предиктивной аналитики протоколов работы системы и метода машинного обучения Случайный лес для оптимизации результатов. Итогом работы алгоритма является прогнозируемый результат целевого значения отклика, который сравнивается с реальным, и на основе его делается вывод о корректности или аномальности значений.

Хоть алгоритм в целом улучшает многие показатели системы отмечается, что существуют различные приоритетные значения. В зависимости от выбора цели внедрения будет меняться и результат. Если необходимо достичь максимальных показателей надежности, придется пожертвовать чем-либо другим.

Проанализированы результаты внедрения алгоритма интеллектуализации в АСУ, использующейся в сфере гидрогеологии. Даже рассматривая ограниченное внедрение алгоритма, результаты и статистика показывают перспективу подобных манипуляций.

Личман А.А. – аспирант, ассистент, ФГБОУ ВО ДонНТУ, кафедра компьютерной инженерии, 283001, Донецк, ул. Артема, 58 ,тел +7(949) 410-9658, anton.lichman@yandex.ru. *Область научных интересов:* алгоритмы интеллектуализации и автоматизации, компьютерное моделирование, нейронные сети

Чередникова О.Ю. – к.т.н., доцент, ФГБОУ ВО ДонНТУ, кафедра компьютерной инженерии, 283001, Донецк, ул. Артема, 58 ,тел +7(949) 376-3084, olachered@yandex.ru *Область научных интересов:* операционные сети, системное программирование, компьютерное моделирование, нейронные сети

Статья поступила в редакцию 05.03.2025.