

**ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ,  
АВТОМАТИКА И ТЕЛЕКОММУНИКАЦИИ**

УДК 004.032.26 + 06

DOI 10.46973/0201-727X\_2024\_2\_15

*С. Л. Никитченко, К. Э. Зырянкина***ПРОГНОЗИРОВАНИЕ ПОТРЕБНОСТИ В ЗАПАСНЫХ ЧАСТЯХ ГИДРОСИСТЕМ МАШИН  
С ПРИМЕНЕНИЕМ НЕЙРОННОЙ СЕТИ**

**Аннотация.** Рассмотрена возможность применения искусственных нейронных сетей с целью прогнозирования потребности в запасных частях гидросистем машин. Проведен анализ распределения неисправностей применительно к наземным транспортно-технологическим средствам, а также представлены результаты анализа существующих традиционных методов резервирования. Предложен подход к обучению искусственной нейронной сети, основанный на модели многослойного персептрона. Представлена реализация варианта переобучения искусственной нейронной сети типа многослойный персептрон для прогнозирования потребности в запасных частях гидросистем машин на базе малых объемов входных данных за прошедшие годы с использованием современной технологии «Data Mining» на платформе «1С: Предприятие». Результаты исследования могут быть полезны для оптимизации запасов запасных частей и повышения эффективности работы гидросистем машин.

**Ключевые слова:** методы прогнозирования, методы резервирования, нейросетевые методы, гидросистемы машин, прогноз, алгоритм, отказ, нейронные сети, искусственный интеллект, обучающая выборка, многослойный персептрон, эффективность, ERP-решения, среднеквадратическая ошибка.

**Для цитирования:** Никитченко, С. Л. Прогнозирование потребности в запасных частях гидросистем машин с применением нейронной сети / С. Л. Никитченко, К. Э. Зырянкина // Вестник Ростовского государственного университета путей сообщения. – 2024. – № 2. – С. 15–24. – DOI 10.46973/0201-727X\_2024\_2\_15.

**Введение**

Бесперебойная работа технологического оборудования на предприятиях является одним из условий экономического успеха. Для выполнения данного условия важно не только правильно организовать эксплуатацию, качественный ремонт и техническое обслуживание машин, но и обеспечить некоторый резерв запасных частей на предприятии. Резервирование позволяет сократить простои машин по техническим причинам и увеличить их производительность. Применительно к наземным транспортно-технологическим средствам актуальным является вопрос резервирования запасных частей для гидравлических систем. По данным авторов [1] для элементов гидроприводов характерно следующее распределение неисправностей: гидронасосы – 11...20 %; гидрораспределители – 15...30 %; распределительные устройства – до 20 %; отказы элементов привода гидронасосов и других устройств – до 18 %. Наши исследования также показывают, что доля отказов гидравлических рукавов здесь может составлять 40–50 %. Важно, что частые отказы элементов гидросистем машин в основном приходятся на период работ, когда простои техники крайне нежелательны. Снижение простоев через резервирование запасных частей требует наличия соответствующего метода расчета величины резерва.

Анализ существующих традиционных методов резервирования показывает, что они в основном базируются на применении нормативов расхода запчастей или на теории статистики и требуют значительного числа наблюдений потребления запасных частей в прошлые периоды [2–4]. Также в последнее время распространены методы эволюционного моделирования, в том числе с применением генетических алгоритмов [5] и нейросетевые методы [6]. Последние два являются интеллектуальными методами. Сложность применения традиционных методов в том, что существующие нормативы расхода запасных частей устарели и не отражают реального потребления, а статистические методы требуют больших объемов исходных данных, которые в предприятиях получить не всегда возможно.

Одним из возможных современных решений данной проблемы является использование нейросетевых алгоритмов для прогнозирования потребности в запчастях. Нейронные сети обладают способностью обучения на основе исторических данных о потреблении конкретной запасной части со

склада в прошлые периоды. При этом малые выборки собственных данных предприятий здесь не являются существенным препятствием для выработки прогноза. Пример применения нейросетей в ERP-решениях реализован в виде отечественного программного обеспечения «1С: Предприятие» [7].

### **Основная часть**

Целью проводимого исследования выступает обоснование нейросетевого метода прогнозирования потребности в запчастях гидросистем машин, позволяющий вести прогноз на малых объемах данных за прошлые годы.

Научная новизна работы заключается в реализации варианта переобучения искусственной нейронной сети типа многослойный перцептрон для прогнозирования потребности в запасных частях гидросистем машин на базе малых объемов входных данных за прошедшие годы с использованием современной технологии «Data Mining» на платформе «1С: Предприятие» [8]. Использование нейросетей «1С: Предприятие» для программного обеспечения позволит интегрировать данный метод прогнозирования с существующими информационными системами, что упростит его внедрение и использование.

Для достижения поставленной цели был использован алгоритм интеллектуального метода прогнозирования потребности в запасных частях, основанный на модели многослойного перцептрона [9, 10]. При этом реализован метод прогнозирования для временных рядов, основанный на искусственных нейронных сетях. Это позволяет получить более точные прогнозы по сравнению с традиционными методами, например, такими, как линейная регрессия или простая описательная статистика.

В качестве метода оценки качества прогноза в рамках задачи прогнозирования было принято решение использовать метрику для регрессионных моделей – среднеквадратичную ошибку (MSE), которая измеряет разницу между предсказанными значениями и истинными значениями зависимой переменной. Показатель MSE полезен для симметричных ошибок, так как способен оценить среднее значение и колебания грубых ошибок, что упрощает разбивку и анализ демонстрации различных моделей. Также данная метрика эффективна для определения точек данных или выбросов, которые существенно влияют на производительность модели [11].

Нейросетевой метод осуществляет автоматическое прогнозирование спроса исходя из входных характеристик временного ряда потребления запасных частей за предыдущие годы. Предварительный этап прогнозирования включает восстановление спроса из ряда потребления запасных частей для гидросистем машин предприятия. В табл. 1 показаны временные ряды потребления с 2014 по 2022 годы для запасных частей гидросистем машин, отказ которых наиболее часто случается в период эксплуатации и приводит к продолжительным простоям техники.

*Таблица 1*

**Данные о потреблении запасных частей для гидросистем машин предприятия**

№ п/п	Наименование запасной части	Потребление по годам, ед.								
		2014	2015	2016	2017	2018	2019	2020	2021	2022
1	Насос шестеренный НШ-32А-3	4	2	5	3	5	1	0	4	2
2	Насос шестеренный НШ-10	6	3	2	4	5	2	2	1	4
3	Гидрораспределитель МР-80-4/4-222	3	1	5	4	1	2	4	2	3
4	Рукав 16×25-1,6, (м)	7,2	9,0	10,8	9,3	12,5	18,7	15,6	9	11
5	Рукав 20×1,5 L 810	3	2	6	2	4	2	4	8	5
6	Рукав 20×1,5 L-1210	9	8	10	11	4	9	12	16	11
7	Рукав 20×1,5L-1010	19	23	17	12	8	20	12	27	18
8	Клапан перепускной 41А-16с13	4	3	1	3	3	2	0	1	3
9	Привод 238АК-4611210 насоса НШ-32	3	1	5	4	4	2	1	0	3
10	Трубка 245-1104180-А1-Х	7	9	11	5	5	10	8	7	9

С целью повышения качества прогноза была разработана схема подготовки входной информации нейронной сети, которая является одним из важных этапов проведения исследований (рис. 1).




**Рис. 1. Схема подготовки входной информации и реализации прогноза с помощью искусственной нейронной сети**

Схема подготовки входной информации важна для корректной работы нейронной сети и обеспечения точных результатов прогнозирования. В отличие от многих других нейронных сетей, предлагаемое решение автоматизирует процесс расчета границ и обучения нейронной сети, которое занимает относительно небольшое количество времени даже при большом количестве итераций.

Разрабатываемая нейронная сеть будет строиться на основе многослойного персептрона, который в свою очередь имеет три слоя:

- 1) входной;
- 2) выходной;
- 3) скрытый.

Многослойный персептрон состоит из элементов с нелинейной функцией активации. Данный вид искусственной нейронной сети широко применяется для задач классификации и регрессии [12]. Математическая модель нейрона многослойного персептрона представляет собой расчет выхода  $k$ -нейрона слоя  $i + 1$  как взвешенной суммы всех его входов со слоя  $i$ , к которой, в свою очередь, применена функция активации, нормализующая выходной сигнал (рис. 2) [13].



**Рис. 2. Структурная схема многослойного персептрона**

Для персептрона используют функции активации – сигмоид или ReLu, что позволяет сети обучаться более сложным функциям и делать более точные предсказания. Обучение многослойного персептрона на наборе данных осуществляли с использованием алгоритма обучения с обратным распространением ошибки [14]. При этом сеть настраивает свои веса и смещения, чтобы минимизировать ошибку на обучающем множестве.

Для программной реализации нейросетевого метода прогнозирования было принято решение использовать технологическую платформу «1С: Предприятие». Данный программный продукт предусматривает собственный встроенный язык программирования, который обеспечивает гибкость для реализации решений задач, стоящих перед пользователями. На выбор среды разработки здесь повлияли следующие факторы:

- массовое распространение в отечественном бизнесе и вхождение в реестр отечественного ПО;
- легкость встраивания в решения и независимость от сторонних продуктов;
- простота понимания программного кода и механики работы;
- отсутствие высоких технических требований к рабочему месту для запуска информационной платформы.

В 1С-программировании реализацию многослойного персептрона можно осуществить с использованием сигмоида и библиотек нейронных сетей TensorFlow и Keras, являющихся внешними компонентами. Имея в наличии исходные данные о потреблении запасных частей за прошедшие годы и вводя их в нейронную сеть на прогнозируемый период, пользователь получит ожидаемый прогноз потребления запасных частей на будущий год.

При реализации процедуры обучения и прогнозирования данных сложность представляют процесс нормализации и масштабирования входных данных, а также интерпретация результата на выходе. Это вызвано тем, что сигмоид осуществляет работу в диапазоне от 0 до 1 как на входе, так и на выходе. В работе были нормализованы данные на входе и денормализованы на выходе, для чего был разработан соответствующий программный код.

Процесс обучения нейронной сети осуществляли по методу обратного распространения ошибки. Фрагмент кода для реализации процедуры обучения сети показан на рис. 3. Он позволяет настроить веса связей между нейронами таким образом, чтобы сеть выдавала правильный результат на выходе для заданного входного сигнала.

```

//создаем сеть
Сеть = ТОBJECT.СоздатьСеть (ОBJECT.КоличествоВходов, OBJECT.КоличествоНейроновСкрытогоСлоя, OBJECT.КоличествоВыходов);

Для n = 1 по OBJECT.КоличествоИтераций Цикл

    Для каждого стр из OBJECT.ВходнаяВыборка Цикл
        //вычисление на прямом проходе
        ТОBJECT.Feedforward(Сеть, стр);
        //обучение
        ТОBJECT.ОбратноеРаспространениеИОбучение(Сеть, стр);
    КонечЦикла;
КонечЦикла;

ИмяВременногоФайлаСеть = ПолучитьИмяВременногоФайла();
ИмяВременногоФайлаГраницы = ПолучитьИмяВременногоФайла();

ЗначениеВФайл(ИмяВременногоФайлаСеть, Сеть);
ЗначениеВФайл(ИмяВременногоФайлаГраницы, OBJECT.ГраницыИнтервалов.Выгрузить());

АдресФайлСети = ПоместитьВоВременноеХранилище(Новый ДвоичныеДанные(ИмяВременногоФайлаСеть), УникальныйИдентификатор);
АдресФайлГраницы = ПоместитьВоВременноеХранилище(Новый ДвоичныеДанные(ИмяВременногоФайлаГраницы), УникальныйИдентификатор);

```

**Рис. 3. Фрагмент кода обучения нейронной сети на основе метода обратного распространения ошибки**

Суть метода обратного распространения ошибки заключается в том, что сначала входной сигнал проходит через все слои нейронной сети, и на выходе получают некоторый результат. Затем сравнивают этот результат с тем, что хотели получить, и вычисляют ошибку. После этого идут в обратном направлении по слоям сети и корректируют веса связей таким образом, чтобы ошибка уменьшилась. Этот процесс повторяется до тех пор, пока ошибка не станет достаточно малой [15].

При выборе количества нейронов скрытого слоя руководствовались тем, что при их малом количестве искусственная нейронная сеть не будет способна выучить сложную зависимость, а при избыточном числе нейронов – велика вероятность «зазубривания» возможных результатов. Под поставленную нами задачу для обучения сети было определено: 4 входных слоя, нейроны скрытого слоя в количестве 15 и один ожидаемый выход.

Была определена последовательность действий для работы с разрабатываемой информационной системой:

- 1) указать локальные файлы, в которые будет производиться сохранение рассчитанных весов сети (синапсов) и границ интервалов;
- 2) определить параметры нейронной сети (количество входов, нейронов скрытого слоя, выходов) и количество необходимых итераций;
- 3) заполнить данными обучающую выборку;
- 4) заполнить границы интервалов;
- 5) выполнить обучение нейронной сети;
- 6) ввести данные для прогнозирования;
- 7) получить результат.

Обучение сети для решения задачи прогнозирования потребности в запасных частях на 2023 год выполнялось на основе данных временного ряда, представленных в табл. 1. Для обучения сети было определено количество итераций в размере 30 000.

После того, как искусственная нейронная сеть прошла процедуру обучения и записала в файлы рассчитанные синапсы и границы интервалов, проведено тестирование процедуры прогноза (рис. 4).

Вход1	Вход2	Вход3	Вход4	Вход5	Ожидаемый выход1	
Вход1 (норм.)	Вход2 (норм.)	Вход3 (норм.)	Вход4 (норм.)	Вход5(норм.)	Ожидаемый выход1 (норм.)	
5,00	1,00			4,00	2,00	<b>2,31660</b>
0,18182		-0,05263	0,20000	0,07407	0,08580	
5,00	2,00	2,00	1,00	4,00		<b>2,14407</b>
0,18182	0,04545	0,05263	0,05000	0,14815	0,07941	
1,00	2,00	4,00	2,00	3,00		<b>2,27934</b>
	0,04545	0,15789	0,10000	0,11111	0,08442	
8,00	20,00	12,00	27,00	18,00		<b>19,91628</b>
0,31818	0,86364	0,57895	1,35000	0,66667	0,73764	
3,00	2,00		1,00	3,00		<b>1,81440</b>
0,09091	0,04545	-0,05263	0,05000	0,11111	0,06720	
4,00	2,00	1,00		3,00		<b>1,60839</b>
0,13636	0,04545			0,11111	0,05957	
5,00	10,00	8,00	7,00	9,00		<b>9,93276</b>
0,18182	0,40909	0,36842	0,35000	0,33333	0,36788	

**Рис. 4. Фрагмент окна программы в процессе тестирования процедуры прогноза**

Предлагаемый нейросетевой метод прогнозирования потребности в запасных частях сравнивали с традиционно используемым методом прогноза по критерию – сумма модулей ошибок отклонений  $|\Delta_i|$ :

$$E = \sum_{i=1}^n |\Delta_i| = \sum_{i=1}^n |y_{\phi i} - y_{pi}|,$$

где  $y_{\phi i}$  – фактическое значение потребления  $i$ -й запасной части в планируемом году, шт.;

$y_{pi}$  – расчетное значение резерва для  $i$ -й запасной части на планируемый год, полученное по предлагаемому методу или традиционному методу расчета, шт.;

$n$  – количество наименований резервируемых запасных частей.

Более эффективным считали тот метод расчета, для которого критерий (см. формулу) имел наименьшее значение. В качестве традиционного метода расчета величины резерва рассматривали метод по определению среднего значения годового потребления запчастей за прошлые годы.

На рис. 5 показан график реального расхода запасных частей на примере гидрораспределителя МР-80-4/4-222 за последние 9 лет и результат нейросетевого прогноза потребности на 2023 год.



**Рис. 5. График фактического расхода запчастей «Гидрораспределитель МР-80-4/4-222» для 2014–2023 гг. и прогноза на 2023 г.**

При обучении нейронной сети для указанной запчастей удалось добиться минимального среднего расстояния  $|\Delta_i| = 1$  между прогнозируемыми значениями из модели и фактическими значениями в наборе данных «Функция» из среднеквадратичной ошибки MSE является оценкой качества прогноза. В нашем случае ошибка прогноза для наиболее нагруженных в потреблении запасных частей составляет 6–7 %, что допустимо.

Результаты определения величины резерва на 2023 год для каждой рассматриваемой запасной части по предлагаемому нейросетевому методу и по традиционному методу среднего годового потребления показаны в табл. 2. Здесь же представлены значения фактического потребления запасных частей в 2023 году и величины критерия  $E$  для обоих методов расчета.

Таблица 2

**Результаты прогнозирования потребности в запасных частях гидросистем машин на 2023 год по предлагаемому и традиционному методам**

№ п/п	Наименование запасной части	Фактическое потребление в 2023 г., шт.	Традиционный метод прогноза		Нейросетевой метод прогноза	
			Величина резерва, шт.	Модуль отклонения $ \Delta_i $	Величина резерва, шт.	Модуль отклонения $ \Delta_i $
1	Насос шестеренный НШ-32А-3	2	3	1	3	1

Окончание табл. 2

№ п/п	Наименование запасной части	Фактическое потребление в 2023 г., шт.	Традиционный метод прогноза		Нейросетевой метод прогноза	
			Величина резерва, шт.	Модуль отклонения $ \Delta_i $	Величина резерва, шт.	Модуль отклонения $ \Delta_i $
2	Насос шестеренный НШ-10	3	3	0	3	0
3	Гидрораспределитель МР-80-4/4-222	4	3	1	3	1
4	Рукав 16x25-1,6	11,5	11,4	0,1	11,4	0,1
5	Рукав 20x1,5 L 810	4	4	0	4	0
6	Рукав 20x1,5 L-1210	11	10	1	11,1	0,1
7	Рукав 20x1,5L-1010	20	17	3	20	0
8	Клапан перепускной 41А-16с13	2	2	0	2	0
9	Привод 238АК-4611210 насоса НШ-32	3	2	1	2	1
10	Трубка Трубка 245-1104180-А1-Х	8	9	1	10	2
Величина критерия $E = \sum_{i=1}^n  \Delta_i $			–	8,1	–	5,2

По данным табл. 2 видно, что результаты прогноза резерва запасных частей по предлагаемому нейросетевому методу максимально близки к значениям фактического потребления. При этом значение принятого оценочного критерия  $E = 5,2$  минимально для случая применения нейросетевого метода, что говорит о его более высокой точности прогноза.

### Выводы

В данной статье был рассмотрен метод прогнозирования потребности в запчастях для гидросистем машин с использованием нейросетевых технологий, который позволяет вести прогноз на малых объемах собственных данных предприятия за прошлые годы с допустимой ошибкой прогноза 6–7 %. Используемая нейросетевая архитектура основана на многослойном персептроне с функцией активации сигмоид, четырьмя входными слоями, 15 нейронами скрытого слоя и одним ожидаемым выходом. Был предложен метод подготовки данных, а также проведено обучение нейронной сети на основе собственных данных конкретного предприятия за прошлые девять лет. Реализация предлагаемых решений на платформе «1С: Предприятие» показывает, что использование нейросетевого подхода позволяет повысить точность прогнозирования потребности в запчастях по сравнению с традиционными методами. Это может способствовать снижению затрат на обслуживание гидросистем и снижению простоев машин по техническим причинам. Учитывая массовое распространение продуктов 1С, можно интегрировать предлагаемую методику прогноза потребности в запчастях с существующими информационными системами без дополнительных затрат для конечных пользователей.

Дальнейшее развитие этой темы предполагает повышение точности прогноза за счет совершенствования архитектуры нейронной сети.

### Список литературы

- 1 **Рылякин, Е. Г.** Влияние эксплуатационных факторов на изменение надежности гидроагрегатов мобильных машин / Е. Г. Рылякин, А. В. Курылев // Молодой ученый. – 2014. – № 4 (63). – С. 247–249. – ISSN 2072-0297.
- 2 **Филатов, М. И.** Формирование резерва запасных частей для ремонта транспортно-технологических машин / М. И. Филатов, О. В. Юсупова // Вестник Оренбургского государственного университета. – 2014. – № 10 (171). – С. 213–218. – ISSN 1814-6457.

### References

- 1 **Rylyakin, E. G.** Influence of operational factors on changes in the reliability of hydraulic units of mobile machines / E. G. Rylyakin, A. V. Kurylev // Young scientist. – 2014. – No. 4 (63). – P. 247–249. – ISSN 2072-0297.
- 2 **Filatov, M. I.** Formation of a reserve of spare parts for repair of transport technological machines / M. I. Filatov, O. V. Yusupova // Bulletin of the Orenburg State University. – 2014. – No. 10 (171). – P. 213–218. – ISSN 1814-6457.

3 **Верительник, Е. А.** Возможности определения потребности запасных частей для автотранспортных предприятий с использованием нейронной сети / Е. А. Верительник, А. В. Калинин // Вестник Луганского государственного университета имени Владимира Даля. – 2021. – № 12 (54). – С. 146–150. – ISSN 2522-4905.

4 Прогнозирование расходов запасных частей на автосервисных предприятиях с использованием корреляционно-регрессионного анализа / И. Ф. Воронина, Ф. М. Судак, А. С. Чернецкий, А. И. Матин // Вести Автомобильно-дорожного института. – 2019. – № 2 (29). – С. 27–34. – ISSN 1990-7796.

5 Оптимизация заказа запасных частей на автотранспортных / И. Ф. Воронина, Ф. М. Судак, В. С. Перов [и др.] // Вести автомобильно-дорожного института. – 2021. – № 1 (36). – С. 50–55. – ISSN 1990-7796.

6 **Никитченко, С. Л.** Совершенствование методов резервирования запасных частей для сельскохозяйственной техники на основе генетических алгоритмов / С. Л. Никитченко, Д. В. Гринченков // Агроинженерия. – 2022. – Т. 24, № 6. – С. 25–31. – DOI 10.26897/2687-1149-2022-6-25-31.

7 **Серебряков, Н. А.** Выбор оптимальной архитектуры и конфигурации нейросети в задачах краткосрочного прогнозирования электропотребления гарантирующего поставщика электроэнергии / Н. А. Серебряков // Вести высших учебных заведений Черноземья. – 2021. – № 2 (64). – С. 26–42. – DOI 10.53015/18159958\_2021\_2\_26.

8 **Шитова, Т. Ф.** 1С : ERP – эффективный инструмент развития цифровой экономики / Т. Ф. Шитова, С. Ф. Молодецкая // Муниципалитет : экономика и управление. – 2021. – № 3 (36). – С. 36–45. – DOI 10.22394/2304-3385-2021-3-36-45.

9 **Филяк, П. Ю.** Применение инструментальных средств для работы с Big Data и Data Mining в решении проблем обеспечения безопасности организации / П. Ю. Филяк, Э. Э. Байларли, В. И. Старченко // Информация и безопасность. – 2017. – Т. 20, № 1. – С. 133–136. – ISSN 1682-7813.

10 **Гейдаров, П. Ш.** Исследование устойчивости многослойного перцептрона с вычисляемыми весами синапсов к меньшим объемам обучающей выборки / П. Ш. Гейдаров // Информационно-управляющие системы. – 2023. – № 2 (123). – С. 2–14. – DOI 10.31799/1684-8853-2023-2-2-14.

3 **Veritelnik, E. A.** Possibility of determining the need for spare parts for motor transport enterprises using a neural network / E. A. Veritelnik, A. V. Kalinin // Bulletin of Lugansk State University named after Vladimir Dahl. – 2021. – No. 12 (54). – P. 146–150. – ISSN 2522-4905.

4 Prediction of spare parts consumption at service centers using correlation and regression analysis / I. F. Voronina, F. M. Sudak, A. S. Chernetsky, A. I. Matin // News of the Automobile and Highway Institute. – 2019. – No. 2 (29). – P. 27–34. – ISSN 1990-7796.

5 Optimization of the spare parts order at the motor transport enterprises / I. F. Voronina, F. M. Sudak, V. S. Perov [et. al.] // News of the Automobile and Highway Institute. – 2021. – No. 1 (36). – P. 50–55. – ISSN 1990-7796.

6 **Nikitchenko, S. L.** Possibilities of determining the demand of spare parts for transport enterprises using a neural network / S. L. Nikitchenko, D. V. Grinchenkov // Agroengineering. – 2022. – Vol. 24, No. 6. – P. 25–31. – DOI 10.26897/2687-1149-2022-6-25-31.

7 **Serebryakov, N. A.** The selection of the optimal architecture and configuration of the neural network for a short-term load forecasting of default provider / N. A. Serebryakov // News of higher educational institutions of the Chernozem region. – 2021. – No. 2 (64). – P. 26–42. – DOI 10.53015/18159958\_2021\_2\_26.

8 **Shitova, T. F.** 1С : ERP – an efficient tool of the digital economy development / T. F. Shitova, S. F. Molodetskaya // Municipality: economics and management. 2021. – No. 3 (36). – P. 36–45. – DOI 10.22394/2304-3385-2021-3-36-45.

9 **Filyak, P. Yu.** Application of tools for working with Big Data and Data Mining in solving problems of ensuring the security of an organization / P. Yu. Filyak, E. E. Baylarli, V. I. Starchenko // Information and Security. – 2017. – Vol. 20, No. 1. – P. 133–136. – ISSN 1682-7813.

10 **Heydarov, P. Sh.** Investigating stability of a multilayer perceptron with calculated synaptic weights to smaller training sample sizes / P. Sh. Heydarov // Information and control systems. – 2023. – No. 2 (123). – P. 2–14. – DOI 10.31799/1684-8853-2023-2-2-14.

11 **Пастухов, А. А.** Применение самоорганизующихся карт Кохонена для формирования представительской выборки при обучении многослойного перцептрона / А. А. Пастухов, А. А. Прокофьев // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Физико-математические науки. – 2016. – № 2 (242). – С. 95–107. – DOI 10.5862/JPM.242.11.

12 **Андриевская, Н. К.** Применение статистических методов, кластерного анализа и нейросетевых технологий при прогнозировании закупочных цен лекарств / Н. К. Андриевская, Т. В. Мартыненко, Т. А. Васяева // Проблемы искусственного интеллекта. – 2023. – № 4 (31). – С. 41–55. – DOI 10.34757/2413-7383.2023.31.4.005.

13 **Сивак, М. А.** Настройка робастных нейронных сетей для решения задачи классификации / М. А. Сивак, В. С. Тимофеев // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2021. – Т. 24, № 3. – С. 26–32. – DOI 10.21293/1818-0442-2021-24-3-26-32.

14 **Пономарев, Д. С.** Применение нейронных сетей на основе многослойного перцептрона с сигмоидальной функцией активации к решению проблем дезодорации воды / Д. С. Пономарев, В. Г. Исаков, М. М. Горохов // Информационные технологии в науке, промышленности и образовании : сборник трудов региональной научно-технической конференции, Ижевск, 31 мая 2018 года / ответственный редактор К. Ю. Петухов. – Ижевск : Ижевский государственный технический университет им. М. Т. Калашникова, 2018. – С. 19–24. – ISBN 978-5-7526-0812-4.

15 **Абрамова, Е. С.** Сравнение машины экстремального обучения и метода обратного распространения ошибки при решении задачи распознавания физической активности человека / Е. С. Абрамова // Известия Тульского государственного университета. Технические науки. – 2023. – № 2. – С. 117–124. – DOI 10.24412/2071-6168-2023-2-117-124.

16 **Ивановский, М. Н.** Применение метода обратного распространения ошибки для обучения нейронной сети / М. Н. Ивановский, О. П. Шафеева // Информационные технологии в науке и производстве : материалы V Всероссийской молодежной научно-технической конференции, Омск, 25–26 апреля 2018 года. – Омск : Омский государственный технический университет, 2018. – С. 39–43. – ISBN 978-5-8149-2624-1.

11 **Pastukhov, A. A.** Kohonen self-organizing map application to representative sample formation in the training of the multilayer perceptron / A. A. Pastukhov, A. A. Prokofiev // Scientific and technical bulletins of the Saint Petersburg State Polytechnic University. Physical and mathematical sciences. – 2016. – No. 2 (242). – P. 95–107. – DOI 10.5862/JPM.242.11.

12 **Andrievskaya, N. K.** Application of statistical methods, cluster analysis and neural network technologies in forecasting procurement prices for medicines / N. K. Andrievskaya, T. V. Martynenko, T. A. Vasyaeva // Problems of artificial intelligence. – 2023. – No. 4 (31). – P. 41–55. – DOI 10.34757/2413-7383.2023.31.4.005.

13 **Sivak, M. A.** Adjusting robust neural networks for solving the classification problem / M. A. Sivak, V. S. Timofeev // Reports of the Tomsk State University of Control Systems and Radioelectronics. – 2021. – Vol. 24, No. 3. – P. 26–32. – DOI 10.21293/1818-0442-2021-24-3-26-32.

14 **Ponomarev, D. S.** Substantiation of the use of a neural network based on a multilayer perceptron with sigmoidal activation function to solve the problem of water deodorization / D. S. Ponomarev, V. G. Isakov, M. M. Gorokhov // Information technologies in science and industry and education : Collection of proceedings of the regional scientific and technical conference, Izhevsk, May 31, 2018 / Executive editor K. Yu. Petukhov. – Izhevsk : Izhevsk State Technical University named after. M. T. Kalashnikova, 2018. – P. 19–24. – ISBN 978-5-7526-0812-4.

15 **Abramova, E. S.** Comparison of extreme learning machine and backpropagation method in the human activity recognition / E. S. Abramova // News of Tula State University. Technical science. – 2023. – No. 2. – P. 117–124. – DOI 10.24412/2071-6168-2023-2-117-124.

16 **Ivanovsky, M. N.** Application of the backpropagation method for training a neural network / M. N. Ivanovsky, O. P. Shafeeva // Information technologies in science and production : materials of the V All-Russian Youth Scientific and Technical Conference, Omsk, April 25–26, 2018. – Omsk : Omsk State Technical University, 2018. – P. 39–43. – ISBN 978-5-8149-2624-1.

*S. L. Nikitchenko, K. E. Zyryankina*

## FORECASTING THE NEED FOR SPARE PARTS OF MACHINE HYDRAULIC SYSTEMS USING A NEURAL NETWORK

**Abstract.** The paper considers the possibility of using artificial neural networks to predict the need for spare parts for machine hydraulic systems. The analysis of the distribution of faults is carried out in relation to ground transport and technological means, and the results of the analysis of existing traditional methods of reservation are presented. An approach to training an artificial neural network based on the multilayer perceptron model is proposed. The implementation of a variant of retraining an artificial neural network of the multilayer perceptron type for predicting the need for spare parts for machine hydraulic systems based on small volumes of input data for the past years using modern Data Mining technology on the 1C: Enterprise platform is presented. The results of the study can be useful for optimizing spare parts stocks and increasing the efficiency of machine hydraulic systems.

**Keywords:** forecasting methods, reservation methods, neural network methods, hydraulic systems of machines, forecast, algorithm, failure, neural networks, artificial intelligence, training sample, multilayer perceptron, efficiency, ERP solutions, mean square error.

**For citation:** Nikitchenko, S. L. Forecasting the need for spare parts of machine hydraulic systems using a neural network / S. L. Nikitchenko, K. E. Zyryankina // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2024. – No. 2. – P. 15–24. – DOI 10.46973/0201-727X\_2024\_2\_15.

### Сведения об авторах

#### **Никитченко Сергей Леонидович**

Ростовский государственный университет путей сообщения (РГУПС),  
кафедра «Вычислительная техника и автоматизированные системы управления»,  
кандидат технических наук, доцент,  
e-mail: binom\_a@rambler.ru

#### **Зырянкина Ксения Эдгаровна**

Ростовский государственный университет путей сообщения (РГУПС),  
кафедра «Вычислительная техника и автоматизированные системы управления»,  
ассистент,  
e-mail: kzyryankina@yandex.ru

### Information about the authors

#### **Nikitchenko Sergey Leonidovich**

Rostov State Transport University (RSTU),  
Chair «Computer Technology and Automated Control Systems»,  
Candidate of Engineering Sciences, Professor,  
e-mail: binom\_a@rambler.ru

#### **Zyryankina Ksenia Edgarovna**

Rostov State Transport University (RSTU),  
Chair «Computer Technology and Automated Control Systems»,  
Assistant,  
e-mail: kzyryankina@yandex.ru