

УДК 681.518.5

**В. В. Грачев, канд. техн. наук**

**А. В. Грищенко, д-р техн. наук**

**В. А. Кручек, д-р техн. наук**

**Ф. Ю. Базилевский, канд. техн. наук**

*Кафедра «Локомотивы и локомотивное хозяйство», Петербургский государственный университет путей сообщения Императора Александра I, Санкт-Петербург*

**М. А. Шварц, канд. техн. наук**

*Кафедра «Высшая математика», Петербургский государственный университет путей сообщения Императора Александра I, Санкт-Петербург*

**Ф. М. Шварц, аспирант**

*Кафедра «Инженерная химия и естествознание», Петербургский государственный университет путей сообщения Императора Александра I, Санкт-Петербург*

## МЕТОДИКА СИНТЕЗА НЕЙРОСЕТЕВЫХ ДИАГНОСТИЧЕСКИХ МОДЕЛЕЙ СЛОЖНЫХ ТЕХНИЧЕСКИХ ОБЪЕКТОВ

Несмотря на обширный опыт применения аппарата нейронных сетей для решения разнообразных задач машинного обучения, многочисленные попытки использования его в технической диагностике не приводят (за редким исключением) к законченным решениям. Причиной сложившейся ситуации являются особенности задач технической диагностики, отличающие их от традиционных задач машинного обучения. В результате анализа этих особенностей авторами предложен подход к диагностированию сложных технических объектов, ориентированный на применение в системах встроенной диагностики и основанный на использовании нейросетевых эталонных диагностических моделей функционально обособленных узлов и агрегатов. Описывается методика синтеза таких моделей, особенности их обучения на данных, полученных в результате мониторинга объекта диагностирования с использованием встроенных средств диагностирования, определения допустимых ошибок отклика и адаптации к текущему состоянию объекта. Предлагаемая в статье фаззификация результатов работы диагностической модели на диагностической выборке позволяет унифицировать подход к диагностированию сложных технических объектов различного назначения. Предложенное авторами применение следящего контрольного сигнала  $D$ . Тригга для контроля остатков регрессии в процессе обучения повышает качество обучения моделей и их обобщающую способность. Значение этого сигнала, определяемое в результате работы модели на диагностической выборке, представляет собой дополнительный информативный диагностический параметр, повышающий точность классификации состояния объекта диагностирования. Применение предложенной методики на стадии проектирования сложных технических объектов позволяет оптимизировать вектор контролируемых параметров икратно повысить эффективность использования диагностической информации, регистрируемой встроенными средствами диагностики и мониторинга.

Техническая диагностика, нейросетевая регрессионная модель, декомпозиция сложного объекта, обучающая выборка, ошибка отклика модели, вектор контролируемых параметров объекта, вектор диагностических параметров, алфавит классов состояния объекта, фаззификация, функция принадлежности

DOI: 10.20295/2412-9186-2020-6-4-466-483

## 1. Постановка задачи

В настоящее время практически все сложные технические системы оборудуются встроенными средствами мониторинга и диагностики (ВСМД), обеспечивающими непрерывный контроль и регистрацию значительных объемов измерительной информации в процессе эксплуатации. В связи с этим актуальными становятся вопросы использования этой информации для внедрения современных (предиктивных и прескриптивных) форм технического обслуживания сложных видов техники, обеспечивающих существенное снижение эксплуатационных расходов при одновременном повышении уровня надежности технических устройств.

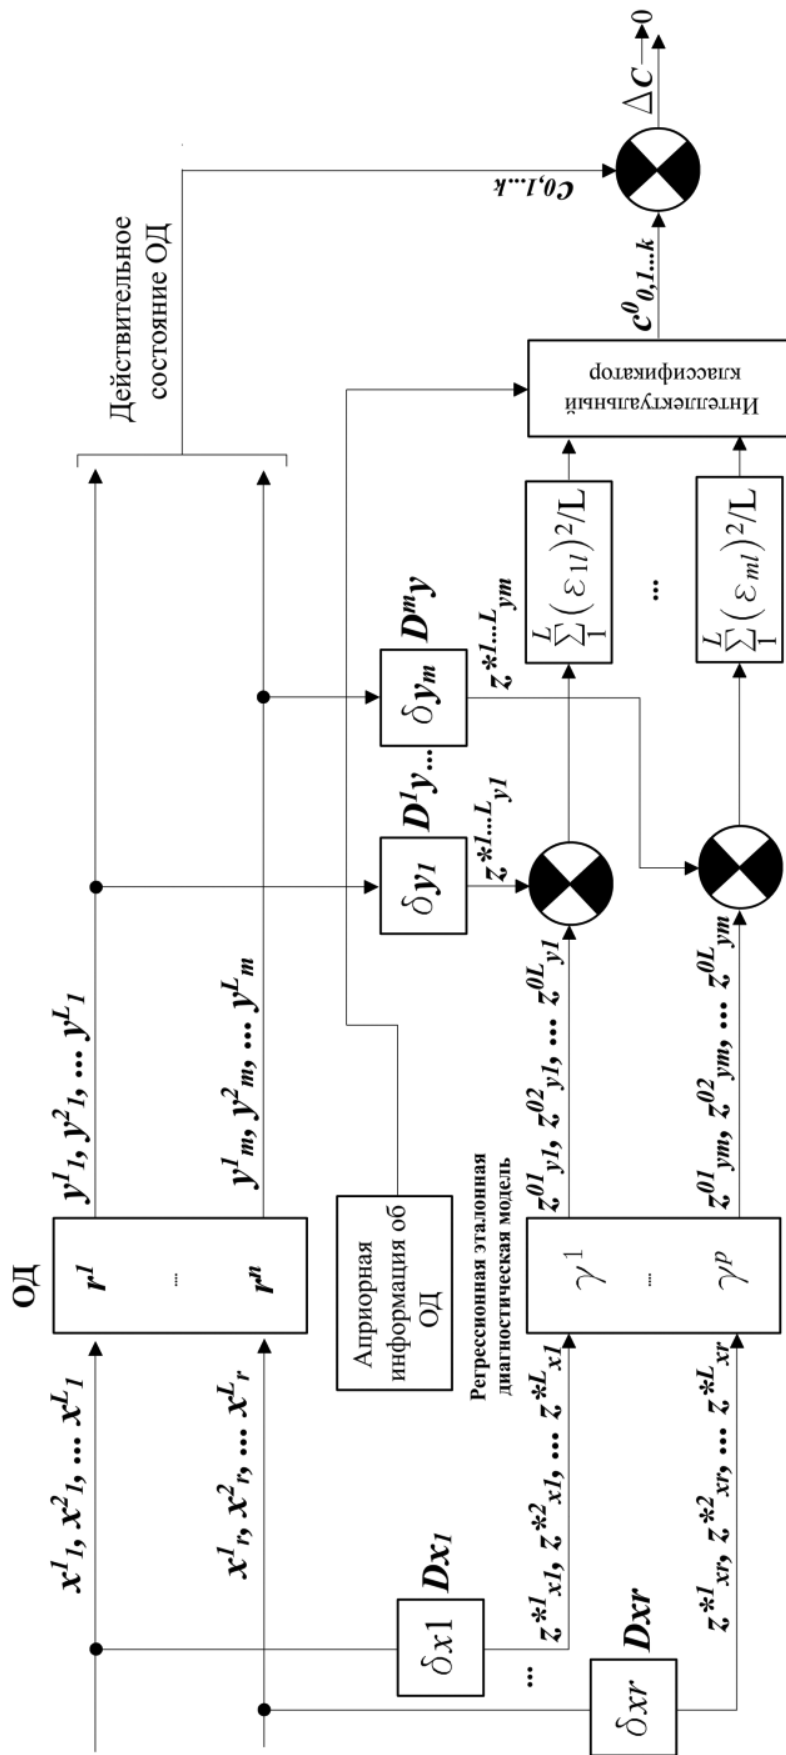
Использовать для этой цели средства и методы стационарной тестовой диагностики, как и опыт их применения, как правило, не удается, поскольку отсутствует возможность реализации тестовых режимов работы оборудования в условиях его эксплуатации.

Попытки прямого применения популярных технологий Data Mining и Big Data для обработки информации, регистрируемой подсистемами ВСМД, также не приводят к успеху — прежде всего из-за особенностей задач диагностирования сложных технических объектов и отличия их от задач, решаемых с использованием инструментария Data Mining и Big Data в других областях.

Первая из таких особенностей заключается в жесткой структурированности измерительной информации и заведомом отсутствии в ней каких-либо «скрытых знаний» или «скрытых закономерностей», на поиск которых ориентированы подходы Data Mining и Big Data [1–3]. Источником информации является ограниченное и неизменное количество измерительных каналов, осуществляющих периодическое измерение значений контролируемых параметров оборудования в процессе его эксплуатации. Результаты измерений представляют собой числовые данные, хранящиеся в табличной форме с числовыми (или преобразуемыми к таковым) типами полей на одном сервере. Принципы работы объектов диагностирования и их конструкция, перечень входных и выходных параметров хорошо известны, взаимосвязь между ними в отдельных (как правило, номинальном или близких к нему) режимах работы описывается характеристиками оборудования или даже аналитическими моделями.

Второй особенностью задач диагностирования сложных технических объектов является высокая надежность объектов диагностирования (ОД) и связанная с ней сложность формирования выборки параметров оборудования для каждого из классов его состояния (отказа) в объеме, необходимом для качественного обучения интеллектуального классификатора состояния.

Один из эффективных подходов к решению таких задач связан с использованием метода FDI (Fault Detection and Identification) [4] (рис. 1), в котором в качестве эталонной диагностической модели ОД применяется регрессионная модель с параметрами  $\{\gamma^1, \gamma^2, \dots, \gamma^P\}$ , определяемыми, исходя из условия мини-



**Рис. 1.** Модификация FDI-метода для систем бортовой диагностики локомотивов.  $(x^1_{1,r}, y^1_{1,m})$  – векторы входных и выходных признаков объекта диагностирования (ОД) с размерностью  $l$  и  $m$ ;  $z^{*1\dots L}_{x1,r}, z^{*1\dots L}_{y1,m}$  – векторы измеренных входных и выходных признаков;  $z^{01\dots L}_{x1,r}, z^{01\dots L}_{y1,m}$  – модельный вектор выходных признаков;  $\epsilon_{1,m,1\dots L}$  – ошибки отклика модели на объектах диагностической выборки;  $C_{0,1\dots k}$  – алфавит классов состояния ОД

мизации ошибки отклика модели, на обучающей выборке параметров ОД, который находится в состоянии, принимаемом за эталонное.

Выполненный анализ показал, что предпочтительный базис для построения таких моделей – аппарат искусственных нейронных сетей (ИНС) [5–7]. Его преимущества – высокая точность моделирования, удобство реализации в пользовательских приложениях, возможность дообучения моделей по мере накопления новых данных, инвариантность по отношению к особенностям функционирования и даже физической природе объекта диагностирования и размерности вектора его входных параметров, хорошая экстраполирующая способность.

Наличие практически неограниченного объема данных для объектов, находящихся в эталонном состоянии, позволяет эффективно обучать сети с любой структурой.

В связи с вышеизложенным актуальной становится задача разработки методики синтеза нейросетевых диагностических моделей оборудования сложных технических систем.

## **2. Синтез нейросетевых эталонных диагностических моделей сложных технических систем**

### **2.1. Определение структуры моделей**

Для реализации универсального подхода к диагностике сложных технических объектов на базе нейросетевых технологий предлагается концепция функционально прозрачных нейронных сетей [8], основанная на следующих основных аспектах формирования нейросетевой диагностической модели:

- декомпозиции сложного объекта на функционально обособленные относительно простые узлы и агрегаты, связанные друг с другом входными и выходными измеряемыми параметрами, совокупность которых образует вектор  $Z^*$ ;
- семантической адаптации функциональных зависимостей между входными и выходными параметрами узлов и агрегатов сложного объекта к физическому смыслу процессов их функционирования;
- функциональном сочетании расчетных и реальных характеристик.

Таким образом, в соответствии с концепцией функционально прозрачных нейронных сетей единая эталонная модель  $Z^0$  сложного технического ОД заменяется совокупностью (ансамблем) простых моделей  $\{Z_1^0, Z_2^0, Z_3^0, \dots, Z_m^0\}$  отдельных узлов и агрегатов, выделяемых в процессе декомпозиции ОД. Эти модели, как правило, имеют одномерный вектор  $Y$  выходных параметров и маломерный (3–5 параметров) вектор  $X$  входных параметров. При этом  $X, Y \in Z^*$ , где  $Z^*$  – вектор контролируемых параметров ОД.

Набор входных и выходных параметров для каждой из моделей  $Z_m^0$  определяется в процессе декомпозиции ОД, исходя из:



**Рис. 2.** Пример декомпозиции узла возбуждения тягового генератора тепловоза в соответствии с концепцией функционально прозрачных нейронных сетей:  $U_{бс}$  – напряжение бортовой сети;  $I_{втг}$  – ток возбуждения тягового генератора;  $I_{вв}$  – ток возбуждения возбудителя; напряжение возбудителя;  $n_d$  – частота вращения коленчатого вала дизеля; БВК – управляемый выпрямитель;  $\alpha_{тг}$  – угол управления тиристорами

- физических принципов функционирования отдельных узлов 1 ...  $m$  ОД и всего объекта в целом;
- располагаемого перечня регистрируемых (измеряемых) параметров (компонентов вектора  $Z^*$ ).

Этими же факторами определяется и глубина декомпозиции, если она выполняется для серийного объекта с уже известным фиксированным набором компонент вектора  $Z^*$ .


Пример декомпозиции узла возбуждения тягового генератора тепловоза приведен на рисунке 2 [9].

Как отмечалось выше, использование концепции ФПНС при синтезе эталонных моделей сложных объектов позволяет снизить размерность задач, решаемых моделями отдельных узлов. Это, в свою очередь, дает возможность упростить структуру НС моделей и снизить требования к ним в части скорости обучения и использования вычислительных ресурсов при реализации. При использовании данного подхода к выбору структуры моделей большинство практических задач диагностирования может успешно решаться с использованием простых многослойных полносвязных сетей прямого распространения (рис. 3).

## 2.2. Обучение нейросетевых моделей

Обучение моделей сводится к последовательной подаче на их входы векторов обучающей выборки, расчету ошибки отклика сети и коррекции синаптических весов с целью ее минимизации [5].

Поскольку структура моделей проста, для обучения может использоваться метод обратного распространения ошибки с любым способом оптимизации весов в ходе обучения [10]. Периодический контроль достигнутого уровня качества обучения осуществляется посредством определения стандартных метрик оценки качества регрессионных моделей [10–12]:



**Рис. 3.** Схема трехслойной полностью связанной сети прямого распространения ( $n-k_1-k_2-1$ )

– коэффициента детерминации

$$R^2 = \frac{\sum_{i=1}^N (\bar{y}_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}; \quad (1)$$

– среднеквадратичной ошибки отклика модели

$$\varepsilon = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N-1}}; \quad (2)$$

где  $y_i$  – измеренные значения выходной (зависимой) переменной модели;  $\hat{y}_i$  – расчетные (модельные) значения зависимой переменной.

Вычисление этих метрик осуществляется как на обучающей выборке, так и на тестовой, данные которой для обучения не используются.

Дополнительная информация о текущем состоянии ОД может быть получена в результате анализа параметров распределения ошибок отклика модели (регрессионных остатков) на диагностической выборке. Однако необходимым условием информативности такого распределения будет его контроль в процессе обучения диагностической модели и учет результатов контроля при оценке качества обучения, чего, как правило, не делается в задачах Big Data и Machine Learning.

В [13–15] обоснована возможность проверки адекватности регрессионных моделей с помощью следящего контрольного сигнала (СКС) Д. Тригга  $K_j$ , определяемого соотношением:



$$K_i = \frac{\widehat{\varepsilon}_i}{\varepsilon_i}, \quad (3)$$

где  $\widehat{\varepsilon}_i = \gamma \cdot \varepsilon_i + (1 - \gamma) \cdot \widehat{\varepsilon}_{i-1}$  — сглаженная ошибка отклика модели на  $i$ -м объекте обучающей выборки;  $\varepsilon_i = y_i - \theta \cdot y_i^*$ ,  $i = 1, 2, 3, \dots, n$  — сглаженная абсолютная ошибка отклика модели;  $\gamma$  — параметр сглаживания.

Если модель окажется настолько неадекватной изучаемому процессу, что все ошибки будут одного знака, то контрольный сигнал будет стремиться к  $+1$  или  $-1$  (выйти за эти пределы он не может). Если известно, что модель адекватна реальному процессу и полученные ошибки  $\varepsilon_i$  образуют нормально распределенную случайную последовательность с нулевым средним и стандартным отклонением  $\sigma$ , то для контрольного сигнала могут быть определены доверительные интервалы.

В [13] доказывается, что при малых  $\gamma$  ( $0.05 \dots 0.1$ ) и принятых допущениях относительно  $\varepsilon_i$  распределение  $K_i$  может быть аппроксимировано нормальным распределением. В этом случае статистический тест на адекватность модели имеет следующий вид:

гипотеза  $H_0$ : модель адекватна ( $M(\varepsilon_i) = 0$ ,  $M(\varepsilon_i \cdot \varepsilon_d) = 0$ ,  $d > 1$ ,  $\sigma = 1, 2 \cdot \widehat{\varepsilon}_i$  при  $\gamma \leq 0,1$  и  $t \rightarrow 0$ ) принимается на уровне значимости  $\alpha$ , если

$$|K_i| \leq 1,2 \cdot \Phi_{1-\frac{\alpha}{2}} \cdot \sqrt{\frac{\gamma}{2-\gamma}}, \quad (4)$$

где  $\Phi_{1-\frac{\alpha}{2}} = \Phi_{0,975} = 1,96$  при  $\alpha = 0,05$  — квантиль нормального распределения.

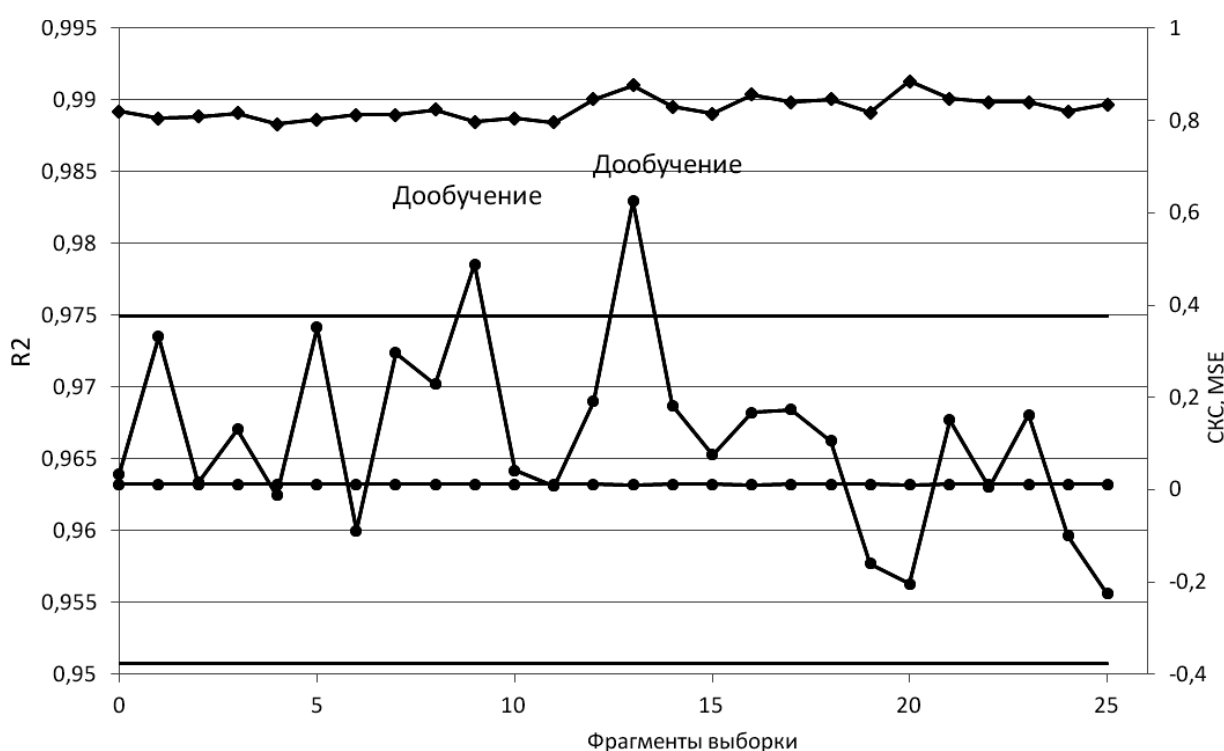
При  $\gamma = 0,05$  неравенство (4) имеет вид  $|K_i| < 0,3766$ .

Выполнение условия (4) является одним из критериев остановки процесса обучения.

На рисунке 4 представлено изменение следящего контрольного сигнала для ошибок отклика обученной модели тягового генератора на различных фрагментах исходной выборки, полученных ее ресемплированием.

### 2.3. Определение допустимой ошибки отклика обученной модели

Особенностью многих технических систем, в частности силовых установок транспортных средств, является принципиальная невозможность обеспечить полную репрезентативность обучающей выборки контролируемых параметров по отношению к их генеральной совокупности. Эта невозможность обусловлена, во-первых, широкими пределами изменения режимов работы установок в процессе эксплуатации, связанными с изменением внешних условий (профиля пути, загрузки, температуры и давления окружающей среды, погодных условий и др.). Во-вторых, она связана с ограниченной размерностью вектора контролируемых параметров и наличием неучтенных моделью влияющих факторов.



**Рис. 4.** Изменение сигнала SKC на фрагментах тестовой выборки модели тягового генератора

В силу этой особенности результаты работы даже хорошо обученной модели на выборках параметров ОД, не совпадающих с обучающей, отличаются от результатов, полученных при обучении.

Влияние указанных факторов может быть учтено назначением гибких допустимых пределов изменения ошибки отклика обученной модели по результатам ее работы на контрольных выборках параметров ОД, находящегося в эталонном состоянии, зафиксированных в различные периоды его эксплуатации.

Предельно допустимое значение среднеквадратичной ошибки отклика обученной модели на выборке объекта, находящегося в состоянии, которое определяется как эталонное, предлагается определять следующим образом [9]:

$$\Delta_{\text{пр}} = I_{0,95} + 3 \cdot \sigma_{\Delta}, \quad (5)$$

где  $I_{0,95} = m_{\Delta} + 1,96 \cdot \frac{\sigma_{\Delta}}{\sqrt{N}}$  – граница доверительного интервала математического

ожидания квадратичной ошибки отклика;  $m_{\Delta} = \sqrt{\frac{\sum_{i=1}^n |\varepsilon_i|^2}{N}}$  – математическое

ожидание среднеквадратичной ошибки отклика на выборке группы оборудования локомотива в эталонном состоянии при постоянном периоде измерения;



$\sigma_{\Delta} = \sqrt{\frac{\sum_{i=1}^n (\varepsilon_i - m_{\Delta})^2}{N-1}}$  – среднеквадратичное отклонение ошибки отклика на выборке группы оборудования локомотива в эталонном состоянии при постоянном периоде измерения;  $N$  – количество отсчетов выборки.

Математическое ожидание ошибки отклика  $m_{\Delta}^0$ , граница доверительного интервала  $I_{0,95}^0$  и допустимая ошибка отклика (5) определяются на контрольных выборках ОД после обучения обобщенной эталонной модели (табл. 1) и в дальнейшем используются для диагностирования данного объекта.

**Таблица 1.** Расчет допустимых ошибок отклика моделей узла возбуждения тягового генератора тепловоза

№ п/п	Метрика	Тяговый генератор	Возбудитель	БВК	Объем выборки
1	MSE	0,00730	0,00290	0,00844	999
	СКС	0,992	-0,378	0,957	
2	MSE	0,0100	0,00378	0,0129	499
	СКС	0,999	0,986	-0,994	
3	MSE	0,00639	0,00811	0,0102	1000
	СКС	1,0	-0,606	-1,0	
4	MSE	0,0115	0,00792	0,0104	1000
	СКС	0,9872	0,999	-0,999	
5	MSE	0,0106	0,00231	0,00594	1000
	СКС	0,618	0,262	0,929	
6	MSE	0,0172	0,00471	0,00607	1000
	СКС	0,999	-0,999	-0,990	
7	MSE	0,0144	0,00760	0,0140	380
	СКС	1,0	-0,83	-0,993	
8	MSE	0,0157	0,00258	0,00804	1000
	СКС	-0,998	0,894	-0,072	
9	MSE	0,00771	0,00249	0,0100	1000
	СКС	0,855	-0,967	0,999	
$\Sigma$	MV MSE	0,0110	0,00454	0,00899	7878
	STO MSE	0,00386	0,00249	0,00276	
	$I_{0,95}$	0,0135	0,00617	0,0108	
	$\Delta_{np}$	0,0251	0,0136	0,0191	

## 2.4. Адаптация обобщенной модели к характеристикам и эксплуатационному состоянию конкретного объекта

В реальной эксплуатации могут находиться (и часто находятся) технические объекты или системы, состояние которых, согласно действующим нормативным документам [16], должно определяться как «неработоспособное», поскольку они не в состоянии выполнять отдельные функции по причинам, зависящим от их состояния.

В то же время состояние этих объектов определяется как рабочее, поскольку большинство своих функций, востребованных в данных условиях эксплуатации, они выполнять могут. При этом задача восстановления полной работоспособности таких объектов эксплуатирующим предприятием может даже не ставиться, поскольку ее решение сопряжено с немалыми затратами ресурсов. С другой стороны, недоступные функции объекта не востребованы и не будут востребованы в дальнейшем в данных условиях эксплуатации.

Кроме того, эксплуатационные характеристики сложных технических объектов, находящихся в исправном состоянии, могут существенно отличаться, особенно в режимах работы, существенно отличных от номинального [17–18].

Таким образом, эталонные значения контролируемых параметров сложного ОД зависят от конкретных условий эксплуатации и могут многократно изменяться в течение его жизненного цикла.

Алгоритмическое обеспечение эффективной системы контроля технического состояния таких ОД должно предусматривать возможность адаптации диагностических моделей к состоянию ОД, принимаемому за эталонное в конкретных условиях эксплуатации.

Очевидным способом такой адаптации является дообучение модели на выборке параметров конкретного объекта. Однако данная операция плохо поддается автоматизации и требует значительных затрат времени.

В связи с этим может быть предложена следующая методика адаптации обобщенных нейросетевых диагностических моделей к характеристикам и эксплуатационному состоянию объекта диагностирования.

Во время первого сеанса диагностирования для каждой модели определяются среднеквадратичная ошибка отклика  $m_{\Delta}^1$ , ее среднеквадратичное отклонение  $\sigma_{\Delta}^1$ , граница доверительного интервала среднеквадратичного отклонения  $I_{0,95}^1$ , а также следящий контрольный сигнал  $K_1$  на диагностической выборке. Если выполняются неравенства:

$$I_{0,95}^1 \leq I_{0,95}^0, \quad |K_1| < 0,3766, \quad (6)$$

предельное значение среднеквадратичной ошибки отклика сохраняется неизменным и используется в дальнейших сеансах диагностирования.

В противном случае делается экспертный анализ текущего технического состояния объекта. Если оно признается рабочим и приемлемым для данных

условий эксплуатации, вычисляется коэффициент адаптации модели  $\theta$  по формуле:

$$\theta = 1 + \text{sign}(K_1) \cdot |m_{\Delta}^0 - m_{\Delta}^1|. \quad (7)$$

После этого выполняется повторное определение математического ожидания  $m_{\Delta}^1$  ошибки отклика модели и  $K_1$ , при этом на каждом шаге ошибка вычисляется с использованием зависимости:

$$\varepsilon_i = y_i - \theta \cdot y_i^*, \quad i = 1, 2, 3, \dots, n. \quad (8)$$

Если условие  $|K_1| < 0,3766$  не выполняется, то осуществляется поиск оптимального значения коэффициента адаптации  $\theta$  по условию  $|K_1| \rightarrow 0$ , после чего определяются значения  $m_{\Delta}^1$ ,  $\sigma_{\Delta}^1$ ,  $I_{0,95}^1$ , и для дальнейших сеансов диагностирования принимается:

$$\begin{aligned} m_{\Delta}^0 &= m_{\Delta}^1, \\ I_{0,95}^0 &= I_{0,95}^1, \\ \Delta_{\text{пр}}^0 &= \Delta_{\text{пр}}^1. \end{aligned} \quad (9)$$


## 2.5. Фаззификация результатов моделирования диагностической выборки

Если величина среднеквадратичной ошибки отклика  $m_{\Delta}^i$ , найденной в результате очередного  $i$ -го сеанса диагностирования, удовлетворяет неравенству  $m_{\Delta}^i \leq I_{0,95}^0$ , текущее состояние группы оборудования признается соответствующим эталонному. Напротив, выполнение неравенства  $m_{\Delta}^i > \Delta_{\text{пр}}^0$  свидетельствует о критическом отклонении текущего состояния группы оборудования от эталонного, в котором определялась величина  $\Delta_{\text{пр}}^0$ . Положение верхней границы  $\Delta_{\text{пр}}^0$ , достижение и тем более превышение которой позволяет классифицировать текущее состояние объекта как нерабочее или предельное, может быть уточнено по мере накопления статистики отказов.

Однако в случае  $I_{0,95}^0 < m_{\Delta}^i < \Delta_{\text{пр}}^0$  существует неопределенность, которая существенно затрудняет классификацию состояния оборудования.

Для ее количественной оценки решение о текущем состоянии агрегата может приниматься с использованием аппарата нечеткой логики [19].

Пусть  $C^1 = \{c_1, c_2, c_3, \dots, c_n\}$  – множество (алфавит) классов состояний ОД, объединяющее классы состояний, отличных от рабочего  $c_0$ , т. е. требующих изъятия оборудования из эксплуатации и проведения работ по восстановлению его рабочего состояния. Пусть  $E^* = \{m_{\Delta 1}^*, \zeta_1^*, m_{\Delta 2}^*, \zeta_2^*, m_{\Delta 3}^*, \zeta_3^*, \dots, m_{\Delta m}^*, \zeta_m^*\}$ , где



**Рис. 5.** Функции принадлежности диагностических параметров:  
а) функция отклика эталонной модели; б) КС

$m_{\Delta}^*, \zeta^* = |K_i|^*$  – четкий вектор результатов моделирования диагностической выборки контролируемых параметров обученной эталонной моделью агрегата, состоящей из  $m$  элементарных НС моделей.

В таком случае степень работоспособности агрегата может быть описана нечетким вектором, символьное описание которого имеет вид:

$$\left\{ \frac{\mu^{\varepsilon_1}(m_{\Delta 1}^*)}{m_{\Delta 1}^*}, \frac{\mu^{\varepsilon_1}(\zeta_1^*)}{\zeta_1^*}, \dots, \frac{\mu^{\varepsilon_m}(m_{\Delta m}^*)}{m_{\Delta m}^*}, \frac{\mu^{\varepsilon_m}(\zeta_m^*)}{\zeta_m^*} \right\}, \quad (10)$$

где  $\mu^{\varepsilon_m}(m_{\Delta m}^*)$  – функция принадлежности МО среднеквадратичной ошибки отклика  $m_{\Delta m}^*$  модели  $m$  на диагностической выборке одному из состояний  $C^1$  такая, что  $\mu^{\varepsilon_m} : m_{\Delta m}^* \rightarrow [0,1]$  [5, 19];  $\mu^{\varepsilon_m}(\zeta_m^*)$  – функция принадлежности значения следящего контрольного сигнала модели  $m$  на диагностической выборке одному из состояний  $C^1$  такая, что  $\mu^{\varepsilon_m} : \zeta_m^* \rightarrow [0,1]$ .

Вид функции  $\mu^{\varepsilon}$  определяется характером решаемой задачи. Поскольку каждая из  $m$  элементарных НС моделей осуществляет преобразование входного вектора контролируемых параметров  $X_m$  в среднеквадратичную ошибку  $m_{\Delta}^*$ , представляется целесообразным использовать функцию принадлежности класса  $\gamma$  [5] (рис. 5, а).

Как отмечалось выше, наряду с абсолютным значением МО среднеквадратичной ошибки отклика модели существенную диагностическую информацию, необходимую для локализации отказа, может дать анализ распределения ошибок отклика модели на диагностической выборке, для интегральной оценки которого было предложено использовать следящий контрольный сигнал Д. Тригга [13–15].

Результаты ряда экспериментов с различными наборами данных позволяют сделать следующие выводы:

основную часть информации о текущем состоянии объекта моделирования несет в себе знак следящего контрольного сигнала при условии  $|K_i| > 0,3766$ ; учет знака  $K_i$  для модельной кривой имеет смысл только при  $\mu^{e_m}(m_{\Delta m}^*)$ .

С учетом этих выводов для нечеткого описания результатов интегральной оценки остатков модельной регрессии удобно использовать пороговую функцию принадлежности (рис. 5, б), которая определяется согласно правилам:

$$\mu^e(\zeta^+) = \begin{cases} 0 & \text{при } (m_{\Delta} \leq I_{0,95}^0) \\ 1 & \text{при } (m_{\Delta} > I_{0,95}^0) \text{ и } (\zeta > 0,3766) \end{cases},$$

$$\mu^e(\zeta^-) = \begin{cases} 0 & \text{при } (m_{\Delta} \leq I_{0,95}^{\max}) \\ 1 & \text{при } (m_{\Delta} > I_{0,95}^{\max}) \text{ и } (\zeta < -0,3766) \end{cases}.$$

Таким образом, если эталонное состояние узла ОД описывается эталонной моделью с одномерным выходным вектором, его текущее состояние описывается трехмерным вектором диагностических признаков:

$$E^* = \{\mu^{e_m}(m_{\Delta m}^*), \mu^{e_m}(\zeta_m^{*+}), \mu^{e_m}(\zeta_m^{*-})\}. \quad (11)$$

Фаззификация результатов работы моделей на диагностической выборке открывает возможность создания унифицированных интеллектуальных классификаторов состояния сложных технических объектов на основе экспертных знаний [20].

## Заключение

В статье предложена методика синтеза регрессионных эталонных диагностических моделей сложных серийных технических объектов, учитывающая особенности их эксплуатации и технического обслуживания в условиях линейных транспортных предприятий.

Основные достоинства предлагаемой методики:

- относительная простота, хорошая интерпретируемость и высокое качество обучения моделей;
- унификация диагностического описания объектов с различными характеристиками и физическими принципами функционирования, что открывает возможность использования унифицированных классификаторов состояния и экспертных знаний для их построения;
- возможность использования обобщенных моделей для диагностирования однотипных объектов с разными эксплуатационными характеристиками без переобучения.

Предложенное авторами применение следящего контрольного сигнала Тригга для контроля остатков регрессии в процессе обучения улучшает качество обучения моделей и их обобщающую способность. Значение этого сигнала, определяемое в результате работы модели на диагностической выборке, представляет собой дополнительный информативный диагностический параметр, повышающий точность классификации состояния объекта диагностирования.

Применение предложенной методики на стадии проектирования сложных технических объектов позволяет оптимизировать вектор контролируемых параметров икратно увеличить эффективность использования диагностической информации, регистрируемой встроенными средствами диагностики и мониторинга.

### Библиографический список

1. *Майер-Шенбергер В.* Большие данные. Революция, которая изменит то, как мы живем, работаем и мыслим / В. Майер-Шенбергер, К. Кукьер. – М.: Манн, Иванов и Фербер, 2014. – 240 с.
2. *Shmueli G.* To Explain or to Predict? /G. Shmueli // *Statistical Science*. – 2010. – Vol. 25. – N 3. – P. 289–310. <https://doi.org/10.1214/10-STS330>
3. *Брендан Т.* Наука о данных: базовый курс / Т. Брендан, Д. Келлехер. – М.: Alpina Digital, 2020. – 220 с.
4. *Жернаков С. В.* Контроль и диагностика технического состояния масляной системы ГТД с использованием технологии нейронных сетей / С. В. Жернаков, Н. С. Иванова, Р. Ф. Равилов // *Вестник УГАТУ «Информатика и вычислительная техника»*. – 2012. – Т. 16. – № 2 (47). – С. 210–220.
5. *Рутковская Д.* Нейронные сети, генетические алгоритмы и нечеткие системы: учебное пособие / Д. Рутковская, М. Пилиньский, Л. Рутковский. – 2-е изд. – М.: Горячая линия-Телеком, 2013. – 452 с.
6. *Хайкин С.* Нейронные сети: полный курс / С. Хайкин. – 2-е изд. – М.: Издательский дом «Вильямс», 2006. – 1114 с.
7. *Vemhart M.* Artificial Neural Networks: Lecture Notes. – URL: <https://arxiv.org/pdf/1901.05639.pdf> (дата обращения: 05.06.2020).
8. *Добродеев И. П.* Повышение эффективности нейросетевых моделей в системах диагностики технического состояния газотурбинных двигателей на основе функциональной адаптации: дис. ... канд. техн. наук, специальность: 05.13.01 / И. П. Добродеев. – Рыбинск: РГАТУ им. П. А. Соловьева, 2010. – 218 с.
9. *Грачев В. В.* Научные основы применения методов интеллектуального анализа данных для контроля технического состояния локомотивов: дис. ... докт. техн. наук, специальность: 05.22.07 / В. В. Грачев. – СПб.: ПГУПС, 2020. – 434 с.
10. *Джулли А.* Библиотека Keras – инструмент глубокого обучения. Реализация нейронных сетей с помощью библиотек Theano и TensorFlow / А. Джулли, С. Пал. – М.: ДМК Press, 2018. – 294 с.
11. *Minaee S.* 20 Popular Machine Learning Metrics. Part 1: Classification & Regression Evaluation Metrics. – URL: <https://towardsdatascience.com/20-popular-machine-learning-metrics-part-1-classification-regression-evaluation-metrics-1ca3e282a2ce> (дата обращения: 05.06.2020).



12. *Tiwari S.* Complete Guide to Machine Learning Evaluation Metrics. – URL: <https://medium.com/analytics-vidhya/complete-guide-to-machine-learning-evaluation-metrics-615c2864d916> (дата обращения: 05.06.2020).
13. *Лукашин Ю. П.* Адаптивные методы краткосрочного прогнозирования временных рядов: учебное пособие / Ю. П. Лукашин. – М.: Финансы и статистика, 2003. – 416 с.
14. *Trigg D. W.* Monitoring a forecasting system / D. W. Trigg // *Operational Research Quarterly.* – 1964. – Vol. 15. – P. 271–274.
15. *Trigg D. W.* Exponential smoothing with an adaptive response rate / D. W. Trigg, A. G. Leach // *Operational Research Quarterly.* – 1967. – Vol. 18. – P. 53–59.
16. ГОСТ 27.002–2015. Надежность в технике. Термины и определения. – Введен 01.03.2017. – М.: Стандартинформ, 2017. – 23 с.
17. *Курилкин Д. Н.* Анализ основных причин, влияющих на неравномерное распределение токов и вращающих моментов между тяговыми двигателями / Д. Н. Курилкин, С. М. Алигаджиев и др. // *Локомотивы. Электрический транспорт XXI век: сб. материалов VI международной научно-практической конференции.* – СПб., 2018. – Т. 1. – С. 218–223.
18. *Перминов В. А.* Влияние технического состояния вспомогательного оборудования тепловозов на их энергоэффективность в эксплуатации / В. А. Перминов, В. В. Грачев, И. Э. Нестеров, Д. Н. Курилкин // *Вестник научно-исследовательского и конструкторско-технологического института подвижного состава.* – 2015. – Вып. 97. – С. 45–58.
19. *Terano T.* Fuzzy Systems. Theory and its applications / T. Terano, K. Asai // Academic Press. – 1972. – 264 p.
20. *Грачев В. В.* Использование нейро-нечетких диагностических моделей при оценке технического состояния электрооборудования тепловоза / В. В. Грачев, А. В. Агунов, А. В. Грищенко, В. А. Кручек // *Электротехника.* – 2017. – № 10. – С. 14–18.

**V.V. Grachev**

**A.V. Grishchenko**

**V.A. Kruchek**

**F. Yu. Bazilevsky**

*The department of "Locomotives and Locomotive Facilities"*

*Emperor Alexander I St. Petersburg State Transport University, Saint Petersburg*

**M. A. Schwartz**

*The department of "Higher Mathematics"*

*Emperor Alexander I St. Petersburg State Transport University, Saint Petersburg*

**F. M. Schwartz**

*The department of "Engineering Chemistry and Natural Science"*

*Emperor Alexander I St. Petersburg State Transport University, Saint Petersburg*

## **METHODOLOGY FOR SYNTHESIS OF NEURAL NETWORK DIAGNOSTIC MODELS OF COMPLEX TECHNICAL OBJECTS**

Despite the vast experience of using the neural networks for solving various machine learning problems, the numerous attempts to use them in technical diagnostics have not yet led to complete

solutions so far (with rare exceptions). The reason is the specific nature of technical diagnostics that distinguishes such tasks from traditional machine learning problems. Having analyzed these specific features, the authors propose an approach to diagnosing complex technical objects that is focused on the use in built-in diagnostics systems and is based on the neural network reference diagnostic models of functionally isolated nodes and assemblies. The article describes the methodology for the synthesis of such models, their training on the data obtained by monitoring the object being tested using built-in diagnostic tools, determining the permissible response errors, and adapting to the current status of the object. The fuzzification of the diagnostic model results using the test sample proposed in the article makes it possible to standardize the approach to diagnosing complex technical objects designed for various purposes. The use of D. Trigg's tracking control signal proposed by the authors to monitor regression residuals during the learning increases the training quality and generalization ability of models. The value of this signal determined by the model run on a test sample is an additional informative diagnostic parameter that increases the accuracy of classifying the status of the object under test. The proposed methodology applied at the complex technical object design stage allows optimizing the monitored parameters' array and multiplying the efficiency of the diagnostic information recorded by the built-in diagnostic and monitoring tools.

Technical diagnostics, neural network regression model, decomposition of a complex object, training sample, model response error, monitored parameters' array, diagnostic parameters' array, an alphabetic arrangement of object status classes, fuzzification, membership function

DOI: 10.20295/2412-9186-2020-6-4-466-483

## References

1. *Mayer-Schönberger V. & Cukier K. (2014) Bol'shiye dannyye. Revolyutsiya, kotoraya izmenit to, kak my zhivem, rabotayem i myslim [Big Data: A Revolution That Will Transform How We Live, Work, and Think]. Moscow, Mann, Ivanov and Ferber Publ., 240 p. (In Russian)*
2. *Shmueli G. (2010) To Explain or to Predict? *Statistical Science*, vol. 25, no. 3, pp. 289–310. <https://doi.org/10.1214/10-STS330>*
3. *Brendan T. & Kelleher D. (2020) Nauka o dannyykh: bazovyy kurs [Data Science: MIT Press Essential Knowledge series]. Moscow, Alpina Digital Publ., 220 p. (In Russian)*
4. *Zhernakov S. V., Ivanova N. S. & Ravilov R. F. (2012) Kontrol' i diagnostika tekhnicheskogo sostoyaniya maslyanoy sistemy GTD s ispol'zovaniyem tekhnologii neyronnykh setey [Monitoring and diagnostics of the gas turbine engine oil system technical condition using neural network technology]. *Bulletin of USATU (Ufa State Aviation Technical University), Informatics and Computer Science*, vol. 16, no. 2 (47), pp. 210–220. (In Russian)*
5. *Rutkovskaya D., Pilin'skiy M. & Rutkovskiy L. (2013) Neyronnyye seti, geneticheskiye algoritmy i nechetkiye sistemy: uchebnoye posobiye [Neural networks, genetic algorithms and fuzzy systems: Training manual]. Ed. 2. Moscow, Goryachaya liniya–Telekom Publ., 452 p. (In Russian)*
6. *Khaykin S. (2006) Neyronnyye seti: polnyy kurs [Neural networks: a complete book]. Ed. 2. Moscow, Williams Publishing House, 1114 p. (In Russian)*
7. *Bernhart M. *Artificial Neural Networks: Lecture Notes*. URL: <https://arxiv.org/pdf/1901.05639.pdf> (accessed: June 5, 2020).*
8. *Dobrodeyev I. P. (2010) Povysheniye effektivnosti neyrosetevykh modeley v sistemakh diagnostiki tekhnicheskogo sostoyaniya gazoturbinnnykh dvigateley na osnove funktsional'noy adaptatsii [Improving the efficiency of neural network models in gas turbine engine technical diagnostic systems based on functional adaptation]: dis. ... kand. tekhn. nauk, spetsial'nost': 05.13.01 [Thesis of PhD in Engineering, specialty: 05.13.01] Rybinsk, P. P. A. Solovyov RSATU (Rybinsk State Aviation Technical University) Publ., 218 p. (In Russian)*

9. Grachev V. V. (2020) Nauchnyye osnovy primeneniya metodov intellektual'nogo analiza danykh dlya kontrolya tekhnicheskogo sostoyaniya lokomotivov [Scientific foundations of the application of data mining methods for monitoring the technical condition of locomotives]: dis. ... dokt. tekhn. nauk, spetsial'nost': 05.22.07 [Thesis of Dr Sci in Engineering, specialty: 05.22.07]. St. Petersburg, PGUPS Publ., 434, pp. (In Russian)
10. Gulli A. & Pal S. (2018) Biblioteka Keras – instrument glubokogo obucheniya. Realizatsiya neyronnykh setey s pomoshch'yu bibliotek Theano i TensorFlow [Deep Learning with Keras. Implement neural networks with Keras on Theano and TensorFlow]. Moscow, DMK Press, 294 p. (In Russian)
11. Minaee S. 20 Popular Machine Learning Metrics. Part 1: Classification & Regression Evaluation Metrics. URL: <https://towardsdatascience.com/20-popular-machine-learning-metrics-part-1-classification-regression-evaluation-metrics-1ca3e282a2ce> (accessed: June 5, 2020).
12. Tiwari S. Complete Guide to Machine Learning Evaluation Metrics. URL: <https://medium.com/analytics-vidhya/complete-guide-to-machine-learning-evaluation-metrics-615-c2864d916> (accessed: June 5, 2020).
13. Lukashin Yu. P. (2003) Adaptivnyye metody kratkosrochnogo prognozirovaniya vremennykh ryadov: uchebnoye posobiye [Adaptive methods for short-term time series forecasting: Training manual]. Moscow, Finansy i Statistika Publ., 2003, 416 p. (In Russian)
14. Trigg D. W. (1964) Monitoring a forecasting system. *Operational Research Quarterly*, vol. 15, pp. 271–274.
15. Trigg D. W. & Leach A. G. (1967) Exponential smoothing with an adaptive response rate. *Operational Research Quarterly*, vol. 18, pp. 53–59.
16. (2017) GOST 27.002–2015. Nadezhnost' v tekhnike. Terminy i opredeleniya [Dependability in technics. Terms and definitions]. Introduced as of March 1, 2017. Moscow, Standartinform Publ., 23 p. (In Russian)
17. Kurilkin D. N., Aligadzhiev S. M. et al. (2018) Analiz osnovnykh prichin, vliyayushchikh na neravnomernoye raspredeleniye tokov i vrashchayushchikh momentov mezhdru tyagovymi dvigatelyami [Analysis of the main reasons affecting the uneven currents and torques distribution between traction motors]. *Lokomotivy. Elektricheskiy transport XXI vek: sb. materialov VI mezhdunarodnoy nauchno-prakticheskoy konferentsii [Locomotives. Electric transport in the XXI century: Proceedings of the VI International Scientific and Practical Conference]*. Saint Petersburg, vol. 1, pp. 218–223. (In Russian)
18. Perminov V. A., Grachev V. V., Nesterov I. E. & Kurilkin D. N. (2015) Vliyaniye tekhnicheskogo sostoyaniya vspomogatel'nogo oborudovaniya teplovozov na ikh energoeffektivnost' v ekspluatatsii [Influence of technical condition of diesel locomotives' auxiliary equipment on their energy efficiency in operation]. *Bulletin of Research, Design and Technology Institute of Rolling Stock*, iss. 97, pp. 45–58. (In Russian)
19. Terano T. & Asai K. (1972) Fuzzy Systems. Theory and its applications. *Academic Press*, 264 p.
20. Grachyov V. V., Agunov A. V., Grishchenko A. V. & Kruchek V. A. (2017) Ispol'zovaniye neyro-nechetkikh diagnosticheskikh modeley pri otsenke tekhnicheskogo sostoyaniya elektrooborudovaniya teplovoza [The use of neuro-fuzzy diagnostic models in assessing the technical condition of electrical equipment of a diesel locomotive]. *Elektrotekhnika [Electrical Engineering]*, no. 10, pp. 14–18. (In Russian)

Статья представлена к публикации членом редколлегии В. А. Ходаковским  
Поступила в редакцию 29.06.2020, принята к публикации 02.07.2020

*ГРАЧЕВ Владимир Васильевич* – кандидат технических наук, доцент кафедры «Локомотивы и локомотивное хозяйство» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: v\_grach@mail.ru

*ГРИЩЕНКО Александр Васильевич* – доктор технических наук, профессор кафедры «Локомотивы и локомотивное хозяйство» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: sanklok@mail.ru

*КРУЧЕК Виктор Александрович* – доктор технических наук, профессор кафедры «Локомотивы и локомотивное хозяйство» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: victor.kruchek@mail.ru

*БАЗИЛЕВСКИЙ Федор Юрьевич* – кандидат технических наук, доцент кафедры «Локомотивы и локомотивное хозяйство» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: f\_basilevski@mail.ru

*ШВАРЦ Михаил Александрович* – кандидат технических наук, доцент кафедры «Высшая математика» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: shvarts4545@mail.ru

*ШВАРЦ Филипп Михайлович* – аспирант кафедры «Инженерная химия и естествознание» Петербургского государственного университета путей сообщения Императора Александра I

e-mail: shvarts4545@mail.ru

© Грачев В. В., Грищенко А. В., Кручек В. А., Базилевский Ф. Ю., Шварц М. А., Шварц Ф. М., 2020