

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

Научная статья

УДК 004.9:355.588; DOI: 10.61260/2218-13X-2025-3-13-29

АВТОМАТИЗИРОВАННАЯ ИНФОРМАЦИОННАЯ СИСТЕМА ПОДГОТОВКИ СПАСАТЕЛЕЙ И ПРОМЫШЛЕННОГО ПЕРСОНАЛА ДЕЙСТВИЯМ В ЭКСТРЕМАЛЬНЫХ СИТУАЦИЯХ

Тулупов Денис Юрьевич;

✉ Тютюнник Вячеслав Михайлович.

Тамбовский государственный технический университет, г. Тамбов, Россия

✉ vmtuyutunnik@gmail.com

Аннотация. Представлена автоматизированная информационная система для оценки физиологической готовности специалистов к выполнению задач в условиях ограниченного ресурса дыхательной смеси. Цель системы – повышение надёжности и безопасности действий персонала в экстремальных ситуациях за счёт персонализированного прогнозирования физиологических реакций. В системе реализована гибридная модель интеллектуального анализа данных, прогнозирующая временной ряд лёгочной вентиляции на основе характеристик маршрута, физической нагрузки и индивидуальных признаков пользователя. Модель основана на архитектуре sequence-to-sequence на базе long short-term memory и включает обучаемый спектрально-инерционный слой сглаживания выходного сигнала. Предложена модифицированная функция потерь с учётом асимметрии ошибок и временной актуальности данных, что повышает точность и надёжность прогноза. Система реализована в виде веб-приложения с интерфейсом для задания маршрутов, выбора пользователя и визуализации результатов. Экспериментальные испытания подтвердили высокую точность модели и устойчивость к индивидуальной вариативности, что демонстрирует эффективность предложенного подхода для подготовки и оценки готовности персонала.

Ключевые слова: автоматизированная информационная система, интеллектуальный анализ данных, информационные технологии, подготовка спасателей, подготовка промышленного персонала, изолирующие дыхательные аппараты, нейросетевые модели

Для цитирования: Тулупов Д.Ю., Тютюнник В.М. Автоматизированная информационная система подготовки спасателей и промышленного персонала действиям в экстремальных ситуациях // Науч.-аналит. журн. «Вестник С.-Петербург. ун-та ГПС МЧС России». 2025. № 3. С. 13–29. DOI: 10.61260/2218-13X-2025-3-13-29.

Scientific article

AUTOMATED INFORMATION SYSTEM FOR TRAINING RESCUERS AND INDUSTRIAL PERSONNEL TO ACT IN EXTREME SITUATIONS

Tulupov Denis Yu.;

✉ Tyutyunnik Vyacheslav M.

Tambov State Technical University, Tambov, Russia

✉ vmytyutynnik@gmail.com

Abstract. An automated information system for assessing the physiological readiness of specialists to perform tasks in conditions of limited breathing mixture resources is presented. The purpose of the system is to increase the reliability and safety of personnel actions in extreme situations through personalized prediction of physiological reactions. The system implements a hybrid model of intelligent data analysis that predicts the time series of pulmonary ventilation based on route characteristics, physical exertion, and individual user characteristics. The model is based on long short-term memory sequence-to-sequence architecture and includes a trainable spectral-inertial output signal smoothing layer. A modified loss function is proposed that takes into account error asymmetry and data timeliness, which improves the accuracy and reliability of the forecast. The system is implemented as a web application with an interface for setting routes, selecting users and visualizing results. Experimental tests have confirmed the high accuracy of the model and its resistance to individual variability, demonstrating the effectiveness of the proposed approach for training and assessing staff readiness.

Keywords: automated information system, data mining, information technology, training of rescuers, training of industrial personnel, insulating breathing apparatus, neural network models

For citation: Tulupov D.Yu., Tyutyunnik V.M. Automated information system for training rescuers and industrial personnel to act in extreme situations // Scientific and analytical journal «Vestnik Saint-Petersburg university of State fire service of EMERCOM of Russia». 2025. № 3. P. 13–29. DOI: 10.61260/2218-13X-2025-3-13-29.

Введение

Обеспечение безопасности и сохранности жизни специалистов, задействованных в условиях воздействия поражающих факторов (огонь, задымление, химическое или биологическое заражение, недостаток кислорода и пр.), является одной из ключевых задач в области промышленной и экологической безопасности. Особенно актуальна данная проблема при подготовке спасателей и промышленного персонала, работа которых сопряжена с потенциально опасными технологическими процессами. В экстренных ситуациях обычно используются изолирующие дыхательные аппараты на химически связанном кислороде (ИДА ХСК), обладающие строго ограниченным временем защитного действия, зависящим от интенсивности дыхания человека. Ошибки в оценке готовности специалиста или неверное распределение ресурсов ИДА ХСК при эвакуации могут привести к снижению эффективности спасательных мероприятий, риску потери сознания или летальному исходу.

Применение ИДА ХСК требует не только технической исправности средства защиты, но и высокой степени физиологической готовности персонала к физической нагрузке в условиях дефицита кислорода. Эффективность использования аппарата напрямую зависит от индивидуальных физиологических параметров пользователя, характера выполняемых действий, интенсивности маршрута передвижения и уровня физической подготовленности. Вместе с тем в существующих нормативных и методических подходах, как правило, не учитываются индивидуальные особенности пользователя и не предусматривается персонализированное прогнозирование остаточного ресурса дыхательного аппарата. Возникает необходимость в создании инструментов, способных на основе объективных данных прогнозировать параметры дыхания и оценивать готовность спасателя к действиям в экстремальных условиях.

В ряде работ авторов [1–3] такие инструменты созданы и опробованы, следующим шагом является автоматизация подготовки спасателей и персонала.

Постановка задачи и модель системы

Разработанная автоматизированная информационная система подготовки спасателей и промышленного персонала действиям в экстремальных ситуациях объединяет сбор, хранение и анализ физиологических данных, полученных с имитатора дыхательного аппарата. Система включает модуль обработки сигналов [3], блок прогнозирования на основе рекуррентной модели [4, 5], подсистему интегрального расчёта расхода кислорода и средства визуализации.

Целью прогнозирующего модуля является оценка временного ряда лёгочной вентиляции (ЛВ) $VE(t)$ в условиях заданного маршрута с переменной мощностью физической нагрузки $P(t)$. Модель учитывает не только обобщённые зависимости между мощностью нагрузки и ЛВ, но и индивидуальные особенности пользователя, включая антропометрические данные, физиологические показатели, данные окружающей среды, а также параметры, зафиксированные непосредственно перед началом тренировочной сессии. Это позволяет заранее оценить, сможет ли конкретный специалист пройти заданный маршрут с использованием ИДА ХСК, не исчерпав защитный ресурс аппарата.

В отличие от усреднённых нормативных подходов, предложенная система предоставляет инструменты для выявления слабых мест в подготовке персонала. Если прогноз демонстрирует риск преждевременного исчерпания запаса кислорода или неустойчивой физиологической реакции, инструктор получает возможность скорректировать подготовку: усилить физические тренировки, изменить маршрут или провести повторную проверку в симулированных условиях. Таким образом, система не только оценивает текущую готовность, но и направляет процесс индивидуализированной подготовки, улучшая её качество.

В качестве базового приближения ЛВ от мощности нагрузки используется зависимость:

$$VE_{base}(t) \approx 9 + 9 \cdot \left(\frac{P(t)}{25} \right) = 9 \cdot \left(1 + \frac{P(t)}{25} \right),$$

где P – мощность физической нагрузки (Вт) в момент времени t .

Эта зависимость отражает среднестатистическое увеличение ЛВ на 9 л/мин на каждые 25 Вт нагрузки при базовом уровне в покое, равном 9 л/мин. Значение $VE_{base}(t)$ используется как отправная точка, позволяющая системе выделять индивидуальные отклонения в дыхательном ответе пользователя.

Разработанные модели интеллектуального анализа данных прогнозируют временной ряд поправки ЛВ $\Delta VE(t)$ с максимально возможной точностью на всём интервале маршрута и последующем восстановлении полной величины ЛВ:

$$VE(t) = \Delta VE(t) + VE_{base}(t).$$

Такой подход позволяет анализировать поведение пользователя на разных участках нагрузки, учитывать индивидуальную дыхательную реакцию и предсказывать моменты потенциального истощения ресурса дыхательного аппарата. В частности, особое значение имеют локальные пики ЛВ, поскольку именно они в ряде сценариев определяют критическое время работы ИДА, превосходящее предсказания, основанные на усреднённых значениях.

После восстановления полного временного ряда $VE(t)$ производится интегральный расчёт общего объёма потреблённого кислорода за весь маршрут. Суммарный объём воздуха V_{total} , израсходованный в процессе движения, определяется интегрированием $VE(t)$ по времени:

$$V_{total} = \int_0^{T_{work}} \widehat{VE}(t) dt \approx \sum_{t=1}^{T_{work}} VE(t) \cdot \Delta t,$$

где T_{work} – продолжительность маршрута в секундах; Δt – шаг дискретизации временного ряда.

Тогда, чтобы узнать остаточное или перерасходованное время ИДА ХСК, сначала необходимо рассчитать номинальный объём воздуха V_{nom} , который может выдать аппарат за всё время:

$$V_{nom} = T_{nom} \times V_{Enom},$$

где T_{nom} – номинальное время работы ИДА ХСК в мин; V_{Enom} – номинальная ЛВ, принятая в паспорте ИДА.

Далее рассчитывается разница ΔV между V_{nom} и спрогнозированным V_{total} :

$$\Delta V = V_{nom} - V_{total}.$$

Если $\Delta V > 0$, модель прогнозирует остаток кислорода, достаточный для безопасного завершения маршрута. При $\Delta V < 0$, модуль оценивает дефицит и сигнализирует о риске преждевременного исчерпания ресурса.

Для формирования входных данных нейросетевой модели используется вектор признаков $x(t)$, включающий три группы параметров: статические, исходные физиологические, а также динамические переменные, изменяющиеся в ходе выполнения задания.

Статические признаки отражают индивидуальные характеристики пользователя: рост H , массу тела M , жизненную ёмкость лёгких VC , а также идентификатор UID , необходимый для учёта персональных закономерностей при обучении на множестве различных пользователей. Эти параметры коррелируют с метаболической нагрузкой и респираторным резервом и, как следствие, с величиной лёгочной вентиляции при физической активности.

Параметры тестирования системы

Исходные физиологические параметры фиксируются перед началом тренировки и характеризуют текущее состояние пользователя. К ним относятся: систолическое P_s и диастолическое P_d артериальное давление, частота сердечных сокращений в покое HR_{rest} , вариабельность ритма HRV , насыщение крови кислородом SpO_2 , температура тела T_b , а также условия окружающей среды – атмосферное давление P_{atm} и температура воздуха T_{amb} . Эти данные позволяют оценивать степень готовности сердечно-сосудистой и дыхательной систем к нагрузке и учитывать влияние внешних факторов.

Динамические признаки представляют собой временные ряды и включают мощность нагрузки $P(t)$, время прохождения участка Δt_i , а также тип сегмента маршрута Z . Расчёт мощности нагрузки осуществляется с использованием энергетического баланса:

$$P_i = \frac{E_i}{\Delta t_i},$$

где E_i – энергия, необходимая для преодоления i -го сегмента маршрута.

Для горизонтального движения:

$$E_{flat} = k_r \times M \times L_i,$$

где M – масса пользователя; k_r – эмпирический коэффициент сопротивления поверхности (по умолчанию 1 Дж/кг·м); L_i – длина сегмента в метрах.

Для участков с подъёмом добавляется гравитационная составляющая, соответствующая потенциальной энергии подъёма на высоту Δh_i :

$$E_{inc} = M \times g \times \Delta h_i + k_r \times M \times L_i,$$

$$\Delta h_i = L_i \times \sin(\alpha_i),$$

где g – ускорение свободного падения; α_i – угол наклона.

Для участков с наклонным спуском используется модифицированное выражение с коэффициентом $\eta < 1$, учитывающим пониженные энергозатраты и усилия на торможение:

$$E_{dec} = M \times g \times |\Delta h_i| \times \eta_{decline} + k_r \times M \times L_i.$$

Для передвижения по лестнице движение считается вертикальным, и энергия определяется только подъёмом:

$$E_{st} = M \times g \times L_i.$$

Для участков отдыха энергия E_{rest} считается равной нулю. В результате вектор признаков $x(t)$ принимает следующий вид:

$$x(t) = \begin{bmatrix} H, W, VC, UID, \\ P_s, P_d, HRV, SpO2, T_b, HR_{rest}, P_{atm}, T_{amb}, \\ P_i, \Delta t_i, Z \end{bmatrix}.$$

Формирование набора признаков реализовано с учётом прикладных ограничений – без привлечения медицинских параметров, требующих сложной диагностики. Это обеспечило практическую применимость модели в условиях спасательных отрядов и промышленных предприятий.

В разработанной системе применяется гибридная архитектура, сочетающая в себе априорную модель лёгочной вентиляции и обучаемую поправку, формируемую нейросетевой моделью.

Базовая компонента $VE_{base}(t)$ отражает физиологически обоснованную зависимость ЛВ от мощности нагрузки, а индивидуальные отклонения $\Delta VE(t)$ прогнозируются на основе входных признаков с помощью рекуррентной сети.

Такая структура позволяет использовать преимущества как физически интерпретируемой модели, так и гибкости методов машинного обучения.

Использование интеллектуального анализа и нейронной сети для прогноза лёгочной вентиляции

Для реализации прогноза поправки $\Delta VE(t)$ использована гибридная рекуррентная модель, основанная на архитектуре long short-term memory (LSTM), специально адаптированной для обработки физиологических временных рядов. Особенностью подхода является гибридная структура модели, включающая в себя как компонент обработки последовательностей, так и постобрабатывающий модуль сглаживания.

Ключевым элементом модели интеллектуального анализа является использование рекуррентной нейронной сети, обеспечивающей анализ и прогноз временного ряда поправки лёгочной вентиляции $\Delta VE(t)$ на основе входных физиологических и нагрузочных данных. Мы применили модификацию рекуррентной сети типа LSTM, обладающую способностью к сохранению и передаче информации на больших временных интервалах, что особенно важно при моделировании физиологических процессов, зависящих от предыдущих состояний организма и продолжительной физической активности.

В отличие от классической рекуррентной нейронной сети (RNN), подверженной эффекту исчезающих градиентов и неспособной к запоминанию значимых состояний на длительном горизонте, архитектура LSTM использует внутреннюю ячейку памяти C_t , состояние которой регулируется системой ворот: входные (i_t), выходные (o_t) и забывающие (f_t) ворота. Эти ворота управляют потоками информации и позволяют сети избирательно запоминать или забывать элементы входной последовательности. Уравнения для LSTM имеют следующий вид:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f),$$

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i),$$

$$\tilde{C}_t = \tanh(W_C \times [h_{t-1}, x_t] + b_C),$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t,$$

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o),$$

$$h_t = o_t \times \tanh(C_t),$$

где \tilde{C}_t – кандидат в новое состояние памяти; h_t – новое скрытое состояние (выход ячейки); W_f , W_i , W_o , W_C – матрицы весов для каждой части ячейки; b_f , b_i , b_o , b_C – векторы смещений (*biases*); σ – функция активации.

Такой механизм позволяет эффективно управлять потоком информации, исключая избыточные или устаревшие зависимости, и обеспечивает более точный и устойчивый прогноз индивидуальных реакций на физическую нагрузку. В задаче прогнозирования лёгочной вентиляции это особенно актуально при анализе маршрутов длительного времени действия, когда дыхательные реакции организма зависят не только от текущей нагрузки, но и от накопленного утомления и предыдущих этапов работы.

В ряде экспериментов дополнительно рассмотрена возможность применения упрощённой архитектуры GRU (Gated Recurrent Unit), обладающей меньшим числом параметров за счёт объединения механизмов обновления и забывания. Однако на реальных данных, содержащих сложные дыхательные траектории с высокой межиндивидуальной вариабельностью, модель LSTM показала более высокую точность и устойчивость прогноза. В связи с этим, именно LSTM легла в основу предлагаемой модели интеллектуального анализа.

Для организации прогноза поправки лёгочной вентиляции на всём интервале эвакуационного маршрута использована структура нейросетевой архитектуры типа sequence-to-sequence (seq2seq) с отображением «многие-ко-многим» [6]. Такая архитектура позволяет эффективно сопоставлять входной временной ряд признаков с выходным временным рядом прогнозируемых значений $\Delta VE(t)$ в условиях, когда объекты имеют переменную длину и зависят от предшествующего контекста.

В классической реализации seq2seq-модели применяются два основных компонента: энкодер и декодер, реализованные на основе LSTM. Энкодер принимает входной временной ряд признаков $x(t)$ и преобразует его в скрытое представление $h_e(t)$:

$$h_e(t) = f_{\text{enc}}(x(t), h_e(t-1); \theta_{\text{enc}}),$$

где $h_e(t) \in \mathbb{R}^k$ – скрытое состояние энкодера на шаге t ; f_{enc} – нелинейное отображение, реализуемое LSTM-ячейкой.

Сформированные скрытые состояния используются декодером, который на каждом шаге вычисляет собственное скрытое состояние:

$$h_d(t) = f_{\text{dec}}(h_e(t), h_d(t-1); \theta_{\text{dec}}),$$

где $h_d(t) \in \mathbb{R}^m$ – скрытое состояние декодера на шаге t ; θ_{enc} – обучаемые параметры декодера; и формирует соответствующее прогнозируемое значение:

$$\hat{y}(t) = g(h_d(t)),$$

где g – выходная функция.

Внутренняя структура LSTM позволяет удерживать и фильтровать релевантную информацию о временной структуре входных признаков и продолжительных процессах, влияющих на формирование выходной последовательности. Схема архитектуры отображена на рис. 1.

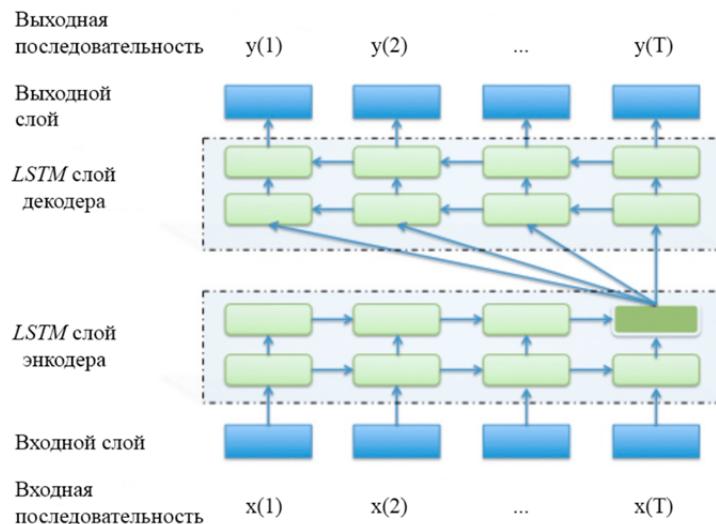


Рис. 1. Архитектура модели seq2seq на основе LSTM

Преимущество такой структуры заключается в том, что она позволяет учитывать всю историю предыдущих состояний и адаптировать прогноз на каждом шаге с учётом динамики признаков. Это особенно важно при работе с данными, характеризующими физиологические реакции, имеющие выраженные временные корреляции и инерционные эффекты.

Выходной временной ряд $\widehat{VE}(t)$, формируемый нейросетевой моделью, обладает высокой чувствительностью к микрофлуктуациям входных признаков, что может приводить к появлению нежелательных артефактов – кратковременных пиков, нерегулярных колебаний и высокочастотного шума. Такие осцилляции, не имеющие физиологического обоснования, искажают форму итогового временного ряда $\widehat{VE}(t)$, нарушают устойчивость расчёта объёма потреблённого воздуха и затрудняют принятие решений о готовности персонала.

Применение классических цифровых фильтров после этапа прогнозирования методологически нецелесообразно. Такие фильтры имеют фиксированные параметры (частота среза, порядок, фаза) и не адаптируются к структуре выходного сигнала. Это может привести либо к недостаточной фильтрации, либо к искажению информативных участков. Более того, внешняя фильтрация нарушает принцип сквозного обучения – градиенты ошибки не проходят через фильтр, что исключает его влияние на оптимизацию модели. Только встроенные обучаемые слои сглаживания, являющиеся дифференцируемыми и включёнными в вычислительный граф, обеспечивают согласованность выхода модели с её входами и устойчивость прогноза [7, 8].

Для решения этой задачи в модели реализован спектрально-инерционный слой, выполняющий сглаживание выходной последовательности $\hat{y}(t)$ в частотной и временной областях. Он включает два этапа: спектральную фильтрацию с обучаемой маской и инерционную стабилизацию.

Операция спектральной фильтрации выглядит так:

$$\begin{aligned} X(f) &= \mathcal{F}\{y(t)\}, \\ \hat{X}(f) &= X(f) \cdot m(f), \\ \hat{y}(t) &= \mathcal{F}^{-1}\{\hat{X}(f)\}, \end{aligned}$$

где $y(t)$ – исходная выходная последовательность RNN; $X(f)$ – её спектр; $m(f)$ – обучаемая спектральная маска; $\hat{y}(t)$ – сглаженный сигнал, подаваемый в качестве окончательного прогноза. В дальнейшем обозначения $y(t)$ и $\hat{y}(t)$ используются как соответственно истинные и предсказанные значения поправки ЛВ $\delta V(t)$, являющиеся целью модели машинного обучения.

Инициализация обучаемой спектральной маски $m(f)$, применяемой в процессе сглаживания выхода модели, осуществляется на основе оценки спектральной плотности мощности (Power Spectral Density, PSD) входного временного ряда дыхания, реализованной методом Уэлча [9]. Данный подход позволяет количественно определить диапазон частот, в котором сосредоточена основная энергия предсказываемой последовательности, и использовать эту информацию для обоснованного выбора частоты f_c – ключевого параметра при построении начальной формы маски.

Оценка PSD по методу Уэлча задаётся как:

$$\widehat{S_x^W}(\omega_k) = \frac{1}{K} \sum_{m=0}^{K-1} P_{x_m}(\omega_k),$$

где $\widehat{S_x^W}(\omega_k)$ – усреднённая PSD на частоте ω_k ; K – число перекрывающихся сегментов; $P_{x_m}(\omega_k)$ – периодограмма m -го сегмента.

Периодограмма для каждого сегмента определяется как:

$$P_{x_m}(\omega_k) = \frac{1}{M} \left| \sum_{n=0}^{M-1} w(n) \times x(n + m \times R) \times e^{-j2\pi nk/N} \right|^2,$$

где $x(n+m \times R)$ – отсчёты m -го сегмента длины M ; w – оконная функция длины M (окно Ханна); M – длина сегмента; R – шаг между сегментами (определяет степень перекрытия); N – длина быстрого преобразования Фурье; k – индекс частотного бина.

По полученному оценочному спектру $\widehat{S_x^W}(\omega_k)$ верхняя граничная частота f_c выбирается как первая частота, на которой уровень PSD опускается ниже заранее заданного порога, обычно равная 10 %:

$$P_{thresh} = 0.1 \times \max_{0 \leq k < K} \widehat{S_x^W}(\omega_k),$$

$$k_{cut} = \min(k),$$

$$\widehat{S_x^W}(\omega_k) < P_{thresh},$$

$$f_c = \omega_{k_{cut}}.$$

Именно это значение используется при инициализации спектральной маски согласно формуле:

$$m_k^{(0)} = \begin{cases} 1, & f_k \leq f_c \\ \alpha_f, & f_k > f_c \end{cases}$$

где $f_k = \frac{k}{T} f_s$ – частота, соответствующая k -му отсчёту; α_f – величина, задающая подавление высокочастотной части спектра.

Следующий компонент разработанного слоя – инерционный фильтр первого порядка, реализованный во временной области в виде разностного уравнения:

$$y_{out}(t) = \alpha \times \hat{y}(t) + (1 - \alpha) \times y_{out}(t - 1), \quad 0 < \alpha \leq 1,$$

где $\hat{y}(t)$ – сглаженная последовательность, полученная после спектральной фильтрации; α – коэффициент, регулирующий степень инерционности.

В отличие от внешних цифровых фильтров, не участвующих в обучении, представленный слой не требует ручной настройки частоты среза или порядка, не вносит фазовых искажений, так как работает внутри модели, поддерживает сквозное обучение, поскольку является дифференцируемым и сохраняет физиологическую интерпретируемость выходного временного ряда.

Для обучения нейросетевой модели прогнозирования поправки лёгочной вентиляции использовалась модифицированная функция потерь, учитывающая особенности задачи. В основу положена среднеквадратичная ошибка (MSE), дополненная двумя корректирующими механизмами: асимметричным штрафом за недооценку и временным взвешиванием наблюдений.

Асимметрия обоснована тем, что недооценка прогноза целевой величины может приводить к менее надёжным результатам, тогда как умеренная переоценка лишь снижает эффективность. Базовая ошибка прогнозирования определяется как:

$$e_t = y(t) - \hat{y}(t),$$

где y_t – истинное значение целевой переменной; $\hat{y}(t)$ – предсказанное моделью.

Для усиления штрафа при положительных e_t вводится непрерывная кусочно-линейная весовая функция:

$$w(e_t) = \begin{cases} 1, & \text{если } e_t < 0, \\ 1 + \frac{\alpha_{max} \times e_t}{\beta}, & \text{если } 0 \leq e_t \leq \beta, \\ 1 + \alpha_{max}, & \text{если } e_t > \beta, \end{cases}$$

где α_{max} – максимальное усиление штрафа; β – порог насыщения. На интервале $[0, \beta]$ вес растёт линейно, что обеспечивает дифференцируемость и устойчивость градиентного спуска.

Чтобы избежать искажения обучения на ранних этапах, параметр α_k вводится постепенно по сигмоидальной функции:

$$\alpha_k = \alpha_{max} \times \frac{1}{1 + e^{-\left(\frac{(k-\mu \times K)}{\gamma}\right)}},$$

где K – общее число эпох; $\mu \in (0,1)$ – точка активации, соответствующая доле обучения, после которой начинается рост асимметрии; $\gamma > 0$ – параметр, определяющий крутизну перехода. Это позволяет сперва обучаться по классической MSE, а затем плавно усиливать штраф за недооценку.

Дополнительно используется временное взвешивание обучающих примеров для адаптации модели к актуальному физиологическому состоянию пользователя. Вес каждого наблюдения зависит от времени его получения:

$$w_t(d) = e^{(-\lambda \cdot (T_{abs} - t_{abs}))},$$

где T_{abs} – момент последнего наблюдения в обучающей выборке; t – временная метка наблюдения (дата и время тренировочной сессии); λ – коэффициент затухания, определяющий скорость убывания значимости устаревших данных. Значение λ выбирается исходя из заданного горизонта τ , например, так, чтобы через τ вес снижался вдвое $\lambda = \frac{\ln 2}{\tau}$.

С учётом всех компонентов итоговая функция потерь принимает вид:

$$L(\theta) = \frac{1}{N} \sum_{t=1}^N w_t(d) \cdot w(e_t) \cdot e_t^2.$$

В такой функции потерь асимметричный весовой множитель усиливает наказание за недооценку ресурса, временные коэффициенты придают приоритет актуальным наблюдениям, а квадратичный штраф сохраняет чувствительность к крупным отклонениям.

Такой подход позволяет модели учитывать асимметрию ошибок и приоритет актуальных данных, обеспечивая стабильную сходимость и повышение точности прогноза в условиях изменяющегося состояния пользователя.

Программная реализация информационной системы

Разработанная модель прогнозирования лёгочной вентиляции интегрирована в состав автоматизированной информационной системы, реализованной в виде клиент-серверного веб-приложения. Программная реализация охватывает весь цикл работ: от загрузки тренировочных данных до визуализации результатов прогноза и формирования заключения о готовности пользователя.

Серверная часть реализована на языке Python с использованием стеков TensorFlow для построения и обучения нейросетевой модели, Flask для предоставления REST-интерфейсов и SQLite в качестве базы данных. Хранение физиологических параметров и маршрутов эвакуации осуществляется через объектно-реляционное отображение на базе библиотеки Pony. Клиентская часть представляет собой адаптивный веб-интерфейс на базе шаблонов Jinja 2 и библиотеки Bootstrap 5, поддерживающий взаимодействие с системой через браузер.

Пользовательский интерфейс включает несколько основных компонентов. После авторизации пользователю доступна основная панель (рис. 2), содержащая список ранее созданных маршрутов, с возможностью их редактирования или удаления.

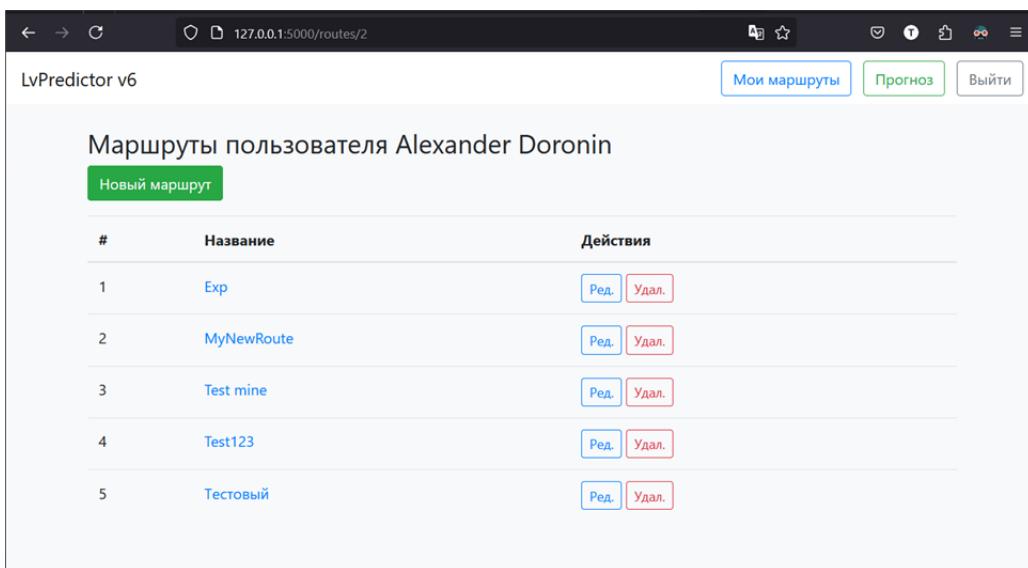


Рис. 2. Главное окно веб-приложения с перечнем маршрутов

Каждый маршрут состоит из последовательности участков, определяемых длиной, скоростью, углом наклона и типом движения. При формировании маршрута система автоматически рассчитывает физическую нагрузку на каждом этапе, а также продолжительность прохождения.

На этапе прогноза пользователь выбирает конкретного специалиста, тренировочную сессию, а также указывает параметры дыхательного аппарата. На основе ранее собранных физиологических данных и характеристик маршрута осуществляется прогноз лёгочной вентиляции (рис. 3) с последующим вычислением объёма потреблённого воздуха и формированием текстового заключения. Результаты представлены в виде графиков и таблиц с возможностью экспорта.



Рис. 3. Экран расчёта прогноза ЛВ и отображения результатов

Экспериментальная проверка информационной системы

С целью проверки эффективности предложенной модели и системы проведены экспериментальные исследования на выборке, полученной в ходе тренировок с участием пользователей [2], проходящих подготовку к действиям в экстремальных условиях. Каждая сессия включала запись физиологических параметров при различной нагрузке, сопровождавшейся измерением реального уровня ЛВ.

Для количественной оценки точности прогноза ЛВ использовался ряд метрик, отражающих как общую амплитуду ошибок, так и специфику задачи в условиях ограниченного ресурса дыхательного аппарата. Основной мерой служила среднеквадратичная ошибка (RMSE), позволяющая оценить типичную величину отклонения прогноза от фактического значения и обладающая высокой чувствительностью к крупным выбросам:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{y}(t) - y(t))^2},$$

где $\hat{y}(t)$ – прогноз модели; $y(t)$ – истинное значение вентиляции в момент времени t ; N – количество отсчётов.

Дополнительно рассчитана средняя абсолютная ошибка (MAE), менее подверженная влиянию единичных аномалий и дающая более устойчивую оценку средних отклонений:

$$\text{MAE} = \frac{1}{N} \sum_{t=1}^N |\hat{y}(t) - y(t)|.$$

Для анализа степени линейной зависимости между предсказанным и реальным временным рядом использован коэффициент корреляции Пирсона (R), отражающий согласованность формы сигналов независимо от масштаба:

$$R = \frac{\sum_{t=1}^N (\hat{y}(t) - \bar{\hat{y}}) \cdot (y(t) - \bar{y})}{\sqrt{\sum_{t=1}^N (\hat{y}(t) - \bar{\hat{y}})^2} \cdot \sqrt{\sum_{t=1}^N (y(t) - \bar{y})^2}},$$

где \bar{y} и $\bar{\hat{y}}$ – средние значения соответствующих рядов.

Дополнительно использована средняя относительная ошибка (E_{rel}), выражаемая в процентах и характеризующая долю отклонения прогноза по отношению к истинным значениям, что удобно для сопоставления результатов между разными пользователями и условиями:

$$E_{rel} = \frac{100 \%}{N} \sum_{t=1}^N \left| \frac{\hat{y}(t) - y(t)}{y(t)} \right|.$$

Особое внимание уделено метрике UR (Underestimation Rate) – доле временных отсчётов, в которых модель недооценивает реальное значение целевого параметра:

$$UR = \frac{1}{N} \sum_{i=1}^N I(t),$$

$$I(t) = \begin{cases} 1, & \text{если } \hat{y}(t) < y(t), \\ 0, & \text{если } \hat{y}(t) \geq y(t). \end{cases}$$

Эта метрика критически важна для задач, связанных с прогнозированием остаточного ресурса ИДА ХСК, так как недооценка может привести к ошибочным решениям о достаточности запаса дыхательной смеси и создать угрозу для жизни специалиста.

Экспериментальное тестирование модели проведено на основе данных, собранных от двух участников, каждый из которых прошёл серию идентичных тренировочных сессий с использованием имитатора ИДА ХСК. Все сессии включали прохождение заранее заданного маршрута, разбитого на участки с различной скоростью движения, углом наклона и типом активности (ходьба по горизонтальной поверхности, ходьба с уклоном вверх, спуск, подъем по лестнице, отдых), при этом конфигурация маршрута и параметры нагрузки были одинаковыми для обоих испытуемых.

Для оценки точности и устойчивости прогноза использованы данные 16 тренировочных проходов. Из них 14 имели полностью совпадающие маршруты и условия и применялись для обучения модели. Сессия 15 использована для интерполяционного тестирования – её характеристики лежали в пределах диапазона признаков обучающей выборки. Сессия 16 отличалась увеличенной нагрузкой и частично изменённым маршрутом, выходящим за рамки обучающих данных, и применена для оценки экстраполяционной способности модели.

Данные второго участника применялись для проверки воспроизводимости результатов и устойчивости модели к индивидуальным различиям в физиологических реакциях при идентичных условиях нагрузки. Это позволило получить предварительные данные о переносимости модели и возможности её использования для прогнозирования физиологических параметров у пользователей, не включённых в обучающую выборку, без необходимости специальной персонализации.

Полученные результаты демонстрируют высокую точность прогноза лёгочной вентиляции при использовании разработанной модели. На интерполяционной сессии (15-й тренировке), параметры которой находились в пределах диапазона признаков обучающей выборки, модель обеспечивала близкое совпадение формы предсказанного временного ряда с реальными измерениями (рис. 4). RMSE составила 2,13 л/мин, коэффициент корреляции Пирсона достиг 0,99, а средняя относительная ошибка – 2,56 %. Доля временных отсчётов с недооценкой прогноза (UR) составила 41,61 %.

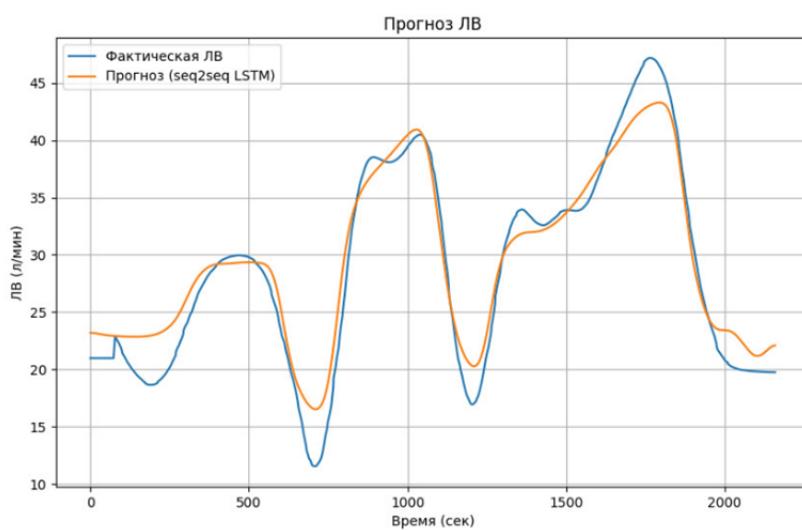


Рис. 4. Сопоставление фактических и прогнозируемых значений ЛВ на маршруте в пределах диапазона признаков обучающей выборки

На экстраполяционной сессии (16-я тренировка), при которой нагрузка и маршрут частично выходили за рамки обучающей выборки, модель сохранила высокую устойчивость прогноза (рис. 5). Несмотря на ожидаемое увеличение ошибок, показатели точности остались

на приемлемом уровне: RMSE составила 3,12 л/мин, MAE – 2,34 л/мин, а коэффициент корреляции Пирсона снизился лишь до 0,96. Средняя относительная ошибка при этом составила 2,3 %, а доля недооценок UR – 47,1 %. Такой уровень ошибок допустим для практического применения, особенно с учётом того, что модель использует только прогноз поправки ЛВ, а не абсолютных значений.

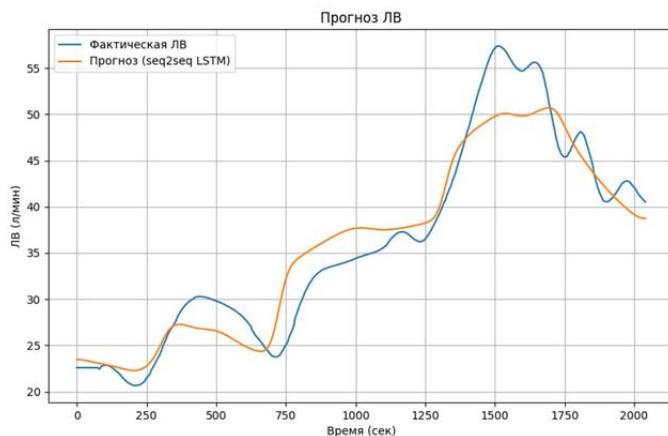


Рис. 5. Сопоставление фактических и прогнозируемых значений ЛВ на маршруте за пределами диапазона признаков обучающей выборки

Сравнительный анализ с альтернативными подходами показал значительное преимущество разработанной модели как по абсолютным ошибкам, так и по доле критических недооценок. Прогнозирование абсолютных значений вентиляции без поправочного механизма дало значительно худшие результаты: RMSE увеличилась до 6,07 л/мин, MAE – до 4,46 л/мин, а UR составила 69,98 %, что делает такой подход ненадёжным в условиях риска преждевременного истощения ресурса дыхательного аппарата.

Базовая эмпирическая модель, не использующая машинное обучение, показала ещё более низкое качество: RMSE достигла 10,2 л/мин, а UR – 95,4 %, что указывает на неспособность такой модели адаптироваться к индивидуальным или динамическим особенностям нагрузки. Модель случайного леса [10], использованная в качестве сравнительного алгоритма [11], обеспечила несколько лучшие результаты по сравнению с эмпирическим подходом (RMSE = 9,87 л/мин, MAE = 6,68 л/мин, R = 0,864), однако также уступила разработанной нейросетевой архитектуре по всем основным метрикам. Метрики результатов тестов сведены в таблицу.

Таблица

Метрики результатов тестирования

Тип теста	RMSE, л/мин	MAE, л/мин	Коэф. кор. R	E _{int} , л	E _{rel} , %	UR, %
Интерполяция с помощью разработанной модели	2,13	1,746	0,99	26,53	2,56	41,61
Экстраполяция с помощью разработанной модели	3,12	2,34	0,959	28,21	2,3	47,07
Экстраполяция с помощью разработанной модели при прогнозировании абсолютных значений	6,072	4,46	0,925	83,47	6,81	69,98
Интерполяция с помощью базовой эмпирической модели	10,198	8,792	0,804	306,79	29,61	95,36
Интерполяция с помощью модели случайного леса	9,874	6,678	0,864	98,98	9,58	46,25

Заключение

Разработанная система предназначена для повышения надёжности эвакуационных мероприятий и качества подготовки персонала за счёт индивидуализированной оценки физиологической готовности. Прогнозируя динамику ЛВ на основе данных тренировок и параметров маршрута, система позволяет заблаговременно выявить риск преждевременного исчерпания ресурса ИДА и своевременно скорректировать подготовку. Это обеспечивает обоснованный отбор и распределение задач между спасателями, снижая вероятность ошибок и повышая общую безопасность.

Таким образом, предложенная автоматизированная информационная система подготовки спасателей и промышленного персонала к действиям в экстремальных ситуациях обеспечивает персонализированную оценку физиологической готовности к действиям в экстремальных условиях на основе прогноза ЛВ. Основу системы составляет гибридная нейросетевая модель, сочетающая интерпретируемую физическую компоненту и обучаемую поправку, реализованную на архитектуре LSTM с последующим спектрально-инерционным сглаживанием выходного сигнала.

Предложена модифицированная функция потерь, включающая асимметричный штраф за недооценку и временное взвешивание примеров, что позволило повысить чувствительность модели к актуальному физиологическому состоянию пользователя и обеспечить безопасность применения прогноза в критических сценариях.

Результаты экспериментального тестирования на данных, полученных от двух пользователей, подтвердили высокую точность и устойчивость модели как в режиме интерполяции, так и при экстраполяции за пределы обучающей выборки. Разработанная модель превзошла по всем метрикам как традиционные эмпирические подходы, так и альтернативные алгоритмы машинного обучения, что делает её перспективной для практического использования в системах оценки готовности персонала, работающего с изолирующими дыхательными аппаратами.

Список источников

1. Тулупов Д.Ю., Тютюнник В.М. Обработка данных для информационной системы подготовки спасателей и промышленного персонала // Приборы и системы. Управление. 2025. № 7. С. 25–31. DOI: 10.25791/pribor.7.2025.1598.
2. Тулупов Д.Ю., Путин С.Б., Тютюнник В.М. Автоматизированная информационная система регистрации параметров работы индивидуальных средств защиты органов дыхания с применением беспроводных технологий передачи данных // Информационные ресурсы России. 2024. № 4 (199). С. 44–59. DOI: 10.52815/0204-3653_2024_4199_44.
3. Тулупов Д.Ю. Модели интеллектуального анализа данных и информационных технологий для подготовки спасателей и промышленного персонала // Информационные процессы, системы и технологии. 2025. Т. 6. № 2 (34). С. 12–22. DOI: 10.52529/27821617_2025_6_2_00.
4. Черкасов Д.Ю., Иванов В.В. Машинное обучение // Наука, техника и образование. 2018. № 5 (46). С. 63–66.
5. Арланова А.А., Нобатов А.М. Интеллектуальный анализ данных: виды и методы // Вестник науки. 2023. Т. 2. № 1 (58). С. 7–10.
6. Sutskever I., Vinyals O., Le Q.V. Sequence to sequence learning with neural networks // Advances in Neural Information Processing Systems. 2014. Vol. 27. P. 3104–3112.
7. Yemets K., Izonin I., Dronyuk I. Enhancing the FFT-LSTM Time-Series Forecasting Model via a Novel FFT-Based Feature Extraction–Extension Scheme // Big Data and Cognitive Computing. 2025. Vol. 9. № 2. P. 35. DOI: 10.3390/bdcc9020035.
8. Gopakumar V., Pamela S., Zanisi L. Fourier-RNNs for modelling noisy physics data // arXiv preprint arXiv:2302.06534. 2023. DOI: 10.48550/arXiv.2302.06534.

9. Welch P.D. The use of fast Fourier transforms for the estimation of power spectra: A method based on time averaging over short modified periodograms // IEEE Transactions on Audio and Electroacoustics. 1967. Vol. 15. P. 70–73. DOI: 10.1109/TAU.1967.1161901.
10. Chistyakov S.P. Random forests: a review // Proceedings of the KarSC RAS. 2013. № 1. P. 107–118.
11. Smyl S., Dudek G., Pełka P. ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting // IEEE Transactions on Neural Networks and Learning Systems. 2023. Vol. 35. № 8. P. 11346–11358.

References

1. Tulupov D.Yu., Tyutyunnik V.M. Obrabotka dannyh dlya informacionnoj sistemy podgotovki spasatelej i promyshlennogo personala // Pribory i sistemy. Upravlenie. 2025. № 7. S. 25–31. DOI: 10.25791/pribor.7.2025.1598.
2. Tulupov D.Yu., Putin S.B., Tyutyunnik V.M. Avtomatizirovannaya informacionnaya sistema registracii parametrov raboty individual'nyh sredstv zashchity organov dyhaniya s primeniem besprovodnyh tekhnologij peredachi dannyh // Informacionnye resursy Rossii. 2024. № 4 (199). S. 44–59. DOI: 10.52815/0204-3653_2024_4199_44.
3. Tulupov D.Yu. Modeli intellektual'nogo analiza dannyh i informacionnyh tekhnologij dlya podgotovki spasatelej i promyshlennogo personala // Informacionnye processy, sistemy i tekhnologii. 2025. T. 6. № 2 (34). S. 12–22. DOI: 10.52529/27821617_2025_6_2_00.
4. Cherkasov D.Yu., Ivanov V.V. Mashinnoe obuchenie // Nauka, tekhnika i obrazovanie. 2018. № 5 (46). S. 63–66.
5. Arlanova A.A., Nobatov A.M. Intellektual'nyj analiz dannyh: vidy i metody // Vestnik nauki. 2023. T. 2. № 1 (58). S. 7–10.
6. Sutskever I., Vinyals O., Le Q.V. Sequence to sequence learning with neural networks // Advances in Neural Information Processing Systems. 2014. Vol. 27. P. 3104–3112.
7. Yemets K., Izonin I., Dronyuk I. Enhancing the FFT-LSTM Time-Series Forecasting Model via a Novel FFT-Based Feature Extraction–Extension Scheme // Big Data and Cognitive Computing. 2025. Vol. 9. № 2. P. 35. DOI: 10.3390/bdcc9020035.
8. Gopakumar V., Pamela S., Zanisi L. Fourier-RNNs for modelling noisy physics data // arXiv preprint arXiv:2302.06534. 2023. DOI: 10.48550/arXiv.2302.06534.
9. Welch P.D. The use of fast Fourier transforms for the estimation of power spectra: A method based on time averaging over short modified periodograms // IEEE Transactions on Audio and Electroacoustics. 1967. Vol. 15. P. 70–73. DOI: 10.1109/TAU.1967.1161901.
10. Chistyakov S.P. Random forests: a review // Proceedings of the KarSC RAS. 2013. № 1. P. 107–118.
11. Smyl S., Dudek G., Pełka P. ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting // IEEE Transactions on Neural Networks and Learning Systems. 2023. Vol. 35. № 8. P. 11346–11358.

Информация о статье:

Статья поступила в редакцию: 03.08.2025; одобрена после рецензирования: 29.08.2025;
принята к публикации: 03.09.2025

Information about the article:

The article was submitted to the editorial office: 03.08.2025; approved after review: 29.08.2025;
accepted for publication: 03.09.2025

Сведения об авторах:

Тулупов Денис Юрьевич, аспирант кафедры конструирования радиоэлектронных и микропроцессорных систем Тамбовского государственного технического университета (392000, Тамбов, ул. Советская, д. 116), кандидат технических наук, e-mail: tulupovden@yandex.ru, <https://orcid.org/0009-0001-7830-339X>, SPIN-код: 3485-7210

Тютюнник Вячеслав Михайлович, профессор кафедры конструирования радиоэлектронных и микропроцессорных систем Тамбовского государственного технического университета (392000, Тамбов, ул. Советская, д. 116), доктор технических наук, e-mail: vmtutyunnik@gmail.com, <http://orcid.org/0000-0003-2099-5730>, SPIN-код: 1442-1686

Information about authors:

Tulupov Denis Yu., postgraduate student of the department of radioelectronic and microprocessor systems engineering at Tambov state technical university (392000, Tambov, Sovetskaya str., 116), candidate of technical sciences, e-mail: tulupovden@yandex.ru, <https://orcid.org/0009-0001-7830-339X>, SPIN: 3485-7210

Tytyunnik Vyacheslav M., professor of the department of radioelectronic and microprocessor systems engineering at Tambov state technical university (392000, Tambov, Sovetskaya str., 116), doctor of technical sciences, e-mail: vmtutyunnik@gmail.com, <http://orcid.org/0000-0003-2099-5730>, SPIN: 1442-1686