

**АНАЛИЗ ДАННЫХ И НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ В ДИАГНОСТИКЕ  
ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЖЕЛЕЗНОДОРОЖНОГО ПУТИ**Доктор физ.-мат. наук, профессор **Дружинина О.В.**

(Федеральный исследовательский центр «Информатика и управление» Российской академии наук. ФИЦ ИУ РАН),

аспирант **Людаговская М.А.**

(Российский университет транспорта. РУТ(МИИТ))

**DATA ANALYSIS AND NEURAL NETWORK MODELLING IN DIAGNOSTICS  
OF RAILWAY TECHNICAL CONDITION****O.V. Druzhinina**, Doctor (Physics & Math.), Professor

(FRC “Computer Science and Control” of the Russian Academy of Sciences),

**M.A. Liudagovskaya**, Postgraduate Student

(Russian University of Transport. RUT (MIIT))

**Аннотация.** Рассмотрены вопросы анализа данных и нейросетевого моделирования в диагностике технического состояния железнодорожного пути. Охарактеризованы особенности современных компьютеризированных технических средств диагностики железнодорожного пути с учетом ключевых аспектов мониторинга объектов путевого хозяйства. Дан анализ некоторых актуальных проблем управления большими данными (Big Data) в информационных транспортных системах. Предложен алгоритм синтеза эталонной нейросетевой диагностической модели для оценки состояния железнодорожного пути. Описаны перспективы применения средств программной реализации интеллектуальных алгоритмов.

**Abstract.** The issues of data analysis and neural network modeling in diagnostics of railway track technical state are considered. The features of modern computerized rail diagnostic vehicles, taking into account the key aspects of monitoring track facilities. The analysis of some actual problems of Big Data control in information transport systems is given. An algorithm for the synthesis of a reference neural network diagnostic model for assessing the condition of a railway track is proposed. The prospects of using software implementation of intelligent algorithms are described.

**Ключевые слова:** цифровая железная дорога, анализ данных, автоматизация управления, средства диагностики железнодорожного пути, нейросетевые модели и алгоритмы, машинное обучение

**Keywords:** Railway track, data analysis, automation control systems, computerized railway diagnostics vehicles, neural network models and algorithms, machine learning

**1. Введение.**

Развитие железных дорог России сопровождается повышением интенсивности движения поездов, увеличением их массы и скорости и значительными повышением сложности транспортной инфраструктуры. Стратегией развития железнодорожного транспорта в Российской Федерации до 2030 г. предусмотрен ряд направлений, нуждающихся в разработке и внедрении новых технологий и бизнес-подходов, направленных на обеспечение безопасного и бесперебойного движения поездов в условиях постоянного роста грузонапряженности и увеличения скорости движения при ограниченной численности персонала.

Одним из таких направлений является диагностика транспортной инфраструктуры. Согласно концепции развития систем диагностики и мониторинга объектов путевого хозяйства на период до 2025 г., в целевом состоянии все технические средства диагностики пути должны быть интегрированы с единой корпоративной автоматизированной системой управления инфраструктурой (ЕК АСУИ) для формирования комплексной оценки состояния объектов железнодорожной инфраструктуры на основе методики оценки рисков в системе

«Управление ресурсами, рисками и анализ надежности» (УРРАН) [1].

Согласно приложению ТР ТС 003/2011 «О безопасности инфраструктуры железнодорожного транспорта», в состав подсистемы инфраструктуры железнодорожного транспорта входят: 1) верхнее строение пути; 2) земляное полотно; 3) водоотводные, и укрепительные сооружения земляного полотна; 4) искусственные сооружения.

Диагностика пути, как наиболее затратная область управления путевым хозяйством, с подавляющим большинством эксплуатационных расходов приходящихся на путеизмерение и дефектоскопию рельсов, является основным объектом разработки оптимизационных решений. Оптимизация диагностики инфраструктуры проводится как в количественном, так и качественном отношении и направлена на сокращение доли ручного труда в путеизмерении и дефектоскопии, поиск путей обеспечения регулярного контроля технического состояния пути в условиях постоянного движения поездов, а также на совершенствование системы прогнозирования состояния объектов путевого хозяйства.

## 2. Информационное обеспечение современных технических средств диагностики железнодорожного пути.

В настоящее время на железных дорогах России применяется, в зависимости от экономических и технических условий содержания пути, достаточно широкий спектр различных технических средств диагностики. Диагностические средства можно условно подразделить на автономные, ручные (или съемные) и мобильные диагностические комплексы.

Ручные и съемные средства диагностики позволяют проводить оперативный мониторинг участков пути, требующих особенно тщательного контроля, а также эффективен в использовании при проведении ремонтных работ и позволяет контролировать качество вновь уложенного пути или качество ремонта сразу же после завершения работ или даже непосредственно в процессе их выполнения. К ним относятся: ручные автоматизированные путеизмерители, путеизмерительные тележки, шаблоны пути, профилографы поперечного профиля пути и стрелочных переводов, дефектоскопные тележки, однониточные дефектоскопы, ручные комплексы контроля габарита приближения строений и самоходные дрезины.

Мобильные диагностические комплексы могут представлять собой либо вагоны-лаборатории, либо самоходные комплексы на базе локомотивов. Вагоны для измерения контактной сети, вагоны-лаборатории автоматики, вагоны-измерители и вагоны-дефектоскопы применяются для контроля определенных объектов транспортной инфраструктуры, а также объединяются в универсальные диагностические комплексы («ЭРА», «ИНТЕГРАЛ»). Преимуществом многофункциональных диагностических комплексов является возможность существенно сократить затраты на диагностику, в сравнении с аналогичными затратами узкоспециализированных средств и обеспечить мониторинг наиболее широкого спектра параметров технического состояния объектов путевого хозяйства силами минимального состава экипажа [2].

Целью разработки самоходной путеизмерительной лаборатории СПЛ-ЧС200 (на базе переоборудованного электровоза ЧС200-08) и самоходной многофункциональной диагностической лаборатории СМДЛ (на базе локомотива 2ТЭ116) является возможность осуществлять автоматизированный контроль состояния железнодорожного пути под локомотивной нагрузкой на путь в 23,7-19,5 т на рабочих скоростях до 100-200 км/ч. Диагностика пути в таких условиях важна для тяжеловесных направлений движения, таких как Байкало-Амурская и Транссибирская магистрали. Результаты измерений самоходных лабораторий приводятся к стандартному формату вагона-путеизмерителя и оцениваются в соответствии с действующей нормативной документацией, что позволяет совмещать данные самоходных лабораторий и вагонов-путеизмерителей, полученные под различными нагрузками на путь, для выявления ослабленных мест верхнего строения пути. Важным преимуществом лаборатории СМДЛ является возможность работать как электрифицированных, так и на не электрифицированных участках пути.

Важным направлением в диагностике пути является совмещение процессов перевозок и технического мониторинга, позволяющее существенно повысить частоту проверок участков пути, не выделяя в расписании поез-

дов «окно» для работы персонала и прохода мобильных комплексов. Датчики и поисковые системы, устанавливаемые на ходовые тележки или кузов вагона, совершенствуются и получают все большее распространение. В настоящее время компанией НПЦ ИНФОТРАНС также разрабатываются автономные диагностические комплексы на базе поездов «Сапсан» и «Ласточка», не нуждающиеся в обслуживающем экипаже. Информационно-измерительная система таких диагностических комплексов работает в автономном режиме, хранит полученные данные и пересылает наиболее важные из них по выделенному радиоканалу в режиме реального времени.

Современные компьютеризированные технические средства диагностики железнодорожного пути оснащены информационно-измерительными системами, контролирующими процесс диагностики и осуществляющими сбор и документацию информации об отклонениях технических параметров пути от нормы. Бортовые информационные системы также выполняют первичную структуризацию информации (к примеру, выявление основных и дополнительных геометрических параметров рельсовой колеи, сбор дополнительных данных о скорости и времени движения, о стрелочных переводах), привязку к пространственным координатам и проводят первичный качественный и количественный анализ отклонений.

## 3. Проблемы управления большими данными (Big Data) в информационных транспортных системах.

Собранная различными диагностическими системами информация представляется в виде километровых диаграмм, выходных сводных таблиц или в графическом виде. Эта информация может быть сопоставлена с данными, собранными в результате других проверок, и агрегирована в комплексной автоматизированной системе учета, контроля и устранения отказов технических средств и анализа их надежности (КАСАНТ) [3].

Система КАСАНТ обеспечивает единство в ведении учета и анализа отказов технических средств на всех железных дорогах России и предоставляет возможность применять комплексные методы оценки эффективности управления транспортной инфраструктурой на базе единой общесетевой базы данных учета отказов технических средств.

К настоящему времени выполнена интеграция КАСАНТ с ЕК АСУИ, осуществляющей информационную поддержку принятия решений по текущему содержанию и ремонту пути. Общее число пользователей, полагающихся в своей работе на данные системы КАСАНТ превышает 50 тыс., а число оповещений, поданных системой – 1400 в сутки [4].

Процесс дальнейшей агрегации и комплексной структуризации данных, полученных различными диагностическими средствами, непрерывно продолжается, однако в настоящий момент он еще далек от завершения в связи с имеющимися между бортовыми АСУ различиями в детализации информации, классификаторах и формате данных, а также в разной периодичности сбора информации.

Стратегия развития железнодорожного транспорта Российской Федерации до 2030 г. предполагает интеграцию всех транспортных АСУ в единую информационно-управляющую транспортную систему на основе

технологии системы УРРАН. Процесс интеграции отраслевых АСУ влечет за собой постоянное повышение интенсивности взаимодействия подсистем управления безопасностью с большим числом прочих подсистем единой информационно-управляющей транспортной системы. Параллельно с этим происходит процесс целевого увеличения интенсивности мониторинга объектов путевого хозяйства. В связи с этим, возникает острая проблема обработки громадных массивов слабо структурированных данных. Схема обмена информации между информационными системами управления состоянием путевого хозяйства представлена на рис. 1.

В условиях большого количества накопленной и ежедневно увеличивающейся в объеме информации, все больше процессов анализа данных нуждаются в автоматизации. В целевом развитии проекта «Цифровая

железная дорога», задачи принятия решений и прогнозирования рисков в значительной степени предполагается осуществлять посредством компьютерной обработки, а в хранение и обработку данных производить на базе технологии Big Data. Big Data представляет собой альтернативу традиционным системам управления базами данных и разработана в целях эффективной обработки огромных и быстро прирастающих объемов данных, разнообразных по степени структуризации. Информация, накапливаемая в ядре платформы УРРАН, позволяет делать выводы о реальности построения технологии УРРАН и единой информационно-управляющей системы российских железных дорог на базе Big Data [5].

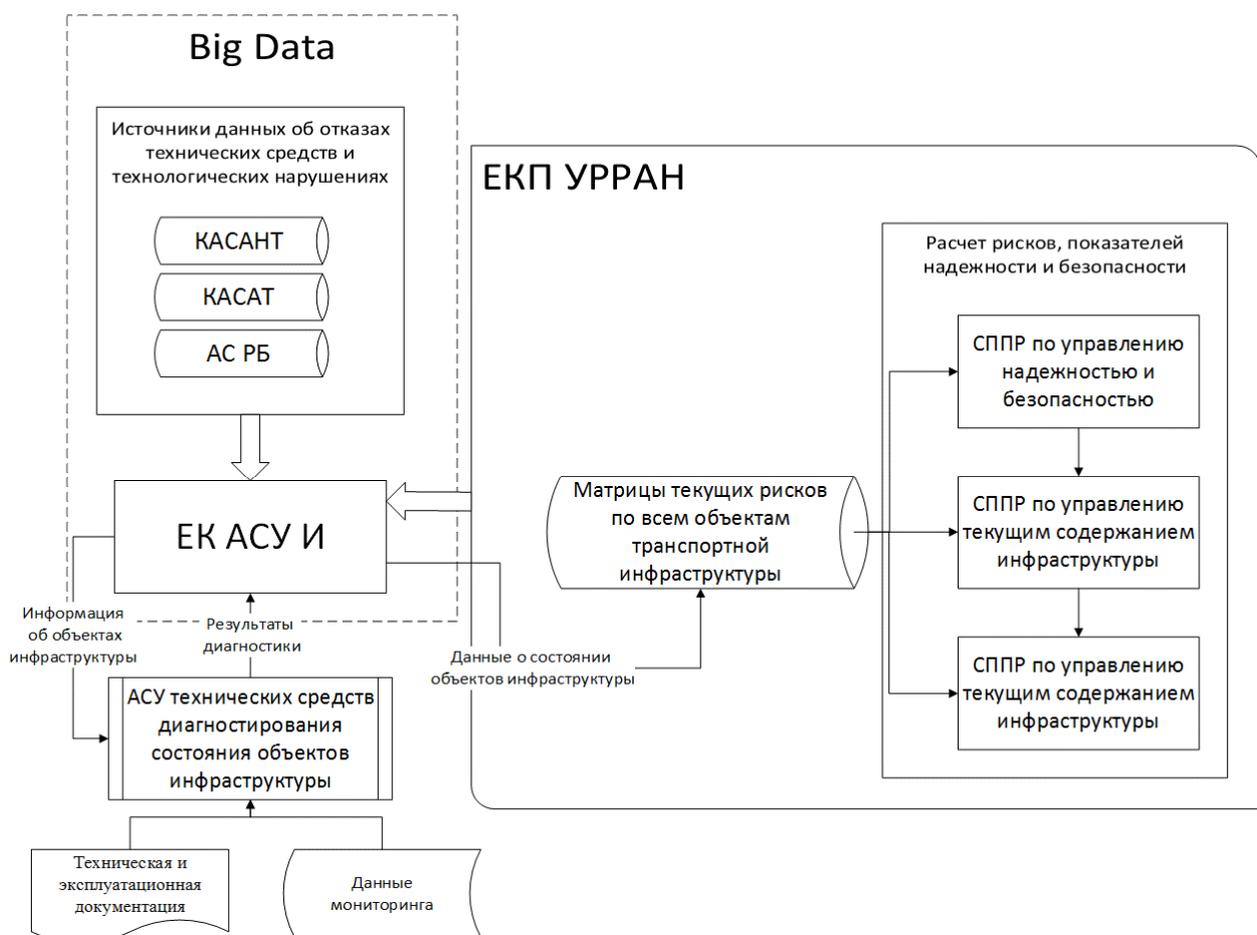


Рис. 1. Организация совместной работы информационных систем управления состоянием верхнего строения пути

Однако, переход к Big Data не представляется возможным без разработки новых методологий сбора и анализа информации на научной основе Data Science. Из-за преобладания (до 90%) доли неструктурированных данных, в глобальных, многофункциональных АС, большая часть времени и усилий при анализе данных расходуется на первичную обработку поступающей в подсистему принятия решений информации. Всей эта информации необходимо пройти процесс подготовки и преобразования в большие данные для того, чтобы последующая эффективная обработка и анализ при помощи аналитических моделей интеллектуального анализа данных (Data Mining), с целью поиска зависимостей и порождения гипотез, стал возможен.

#### 4. Методология обработки информации с применением интеллектуального анализа данных.

Переход к принципиально отличным технологиям обработки информации затронет все уровни единой АИС железных дорог и внедрение в ядро технологии УРРАН подсистемы интеллектуального анализа больших данных (например, такой анализ может базироваться на применении нейросетевых и нейро-нечетких алгоритмов) [6] не сможет обеспечить высокое качество порождаемых прогнозов без предварительной очистки данных и генерации признаков системами нижнего уровня – системой КАСАНТ или бортовыми АСУ (рис. 2).

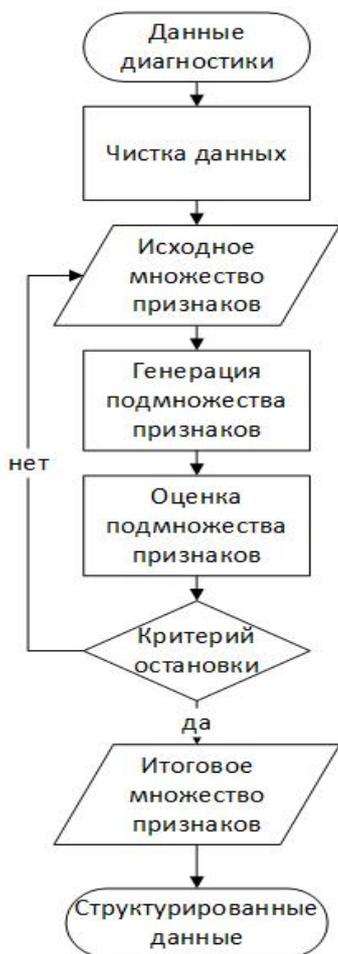


Рис. 2. Схема алгоритма структуризации данных для дальнейшего анализа с помощью нейросетевого алгоритма

Согласно схеме на рис. 2 следует отметить, что для оценки изменения состояния объекта инфраструктуры необходимы точные сведения о времени и месте всех проводимых ремонтных работ, а также о зарегистрированных событиях на участке пути, способных повлечь за собой резкое ухудшение состояния пути. В противном случае неверная или неполная информация приведет к

искажению картины деградации состояния объекта и помешает обучению прогнозного алгоритма. Также из набора данных следует исключить результаты мониторинга, содержащие недостаточно информации для получения реального понимания о состоянии объекта.

Таким образом, в ходе очистки данных необходимо: обновить и дополнить недостающую информацию для контекстуализации данных, удалить бессмысленную информацию. Также для лучшего понимания собранных данных следует провести первичный анализ собранной информации методами статистического анализа (метод линейной регрессии, кусочно-линейная модель и пр. в зависимости от полученных сведений о событиях на исследуемом участке). На последнем этапе очистки данных нужно провести нормализацию признаков, находящихся в различных диапазонах значений.

Для достижения высокой точности предсказаний крайне важно корректно выделить множество важных признаков состояния объекта, поэтому формирование такого множества должно происходить при участии экспертов по техническому обслуживанию железных дорог. К примеру, для оценки состояния геометрии рельсовой колеи (ГРК) такими признаками могут послужить: тип рельсов, тип шпал, возраст шпал, возраст балласта, тип балласта, класс пути, наличие железнодорожных переездов и мостов, радиусы кривизны пути. Перечисленные существенные признаки целесообразно использовать в качестве параметров входного слоя искусственной нейронной сети (ИНС).

Схема ИНС прямого распространения применительно к оценке параметров ГРК представлена на рис. 3. В зависимости от выбранной модели ИНС, выходной слой может содержать один или несколько нейронов. Например, в модели ИНС с единой временной точкой, заданное время может являться одним из входных признаков, а прогноз состояния участка пути через это время – результатом работы нейросети. Нейросеть с несколькими выходными нейронами может формировать прогнозы по объектам, разделенным на несколько категорий (например, по критерию загруженности участка пути), в таком случае число нейронов в выходном слое ИНС будет соответствовать количеству категорий.

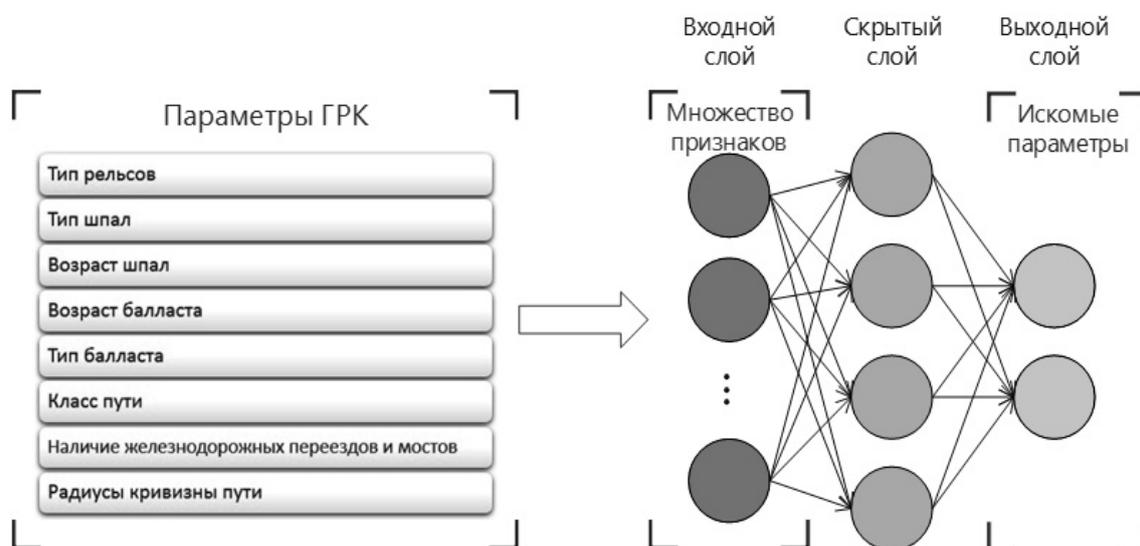


Рис.3. Структурная схема ИНС прямого распространения с одним скрытым слоем

К методам интеллектуального анализа данных относятся нейронные сети, деревья решений, генетические алгоритмы, алгоритмы установления кластеризации и пр. Добиться требуемой точности прогнозирования для решения задач принятия решений при большом объеме данных позволяют алгоритмы ИНС прямого распространения [7]. Распространенным примером такой сети является многослойный персептрон, представляющий собой гибкую и достаточно универсальную модель. Многослойный персептрон позволяет, при достаточном количестве скрытых слоев и достаточном количестве данных, аппроксимировать функции до любой желаемой степени [8].

В общем виде модель ИНС можно описать с помощью соотношения

$$y_j = f \left( \sum_{w_{ij}} x_i + b_j \right),$$

где  $y_j$  – выходной сигнал нейросети,  $x_i$  – входной сигнал, подаваемый на сеть,  $w_{ij}$  – вес нейронной связи,  $b_j$  – нейрон смещения,  $f$  – функция активации.

Входными сигналами нейросети  $x_1, \dots, x_n$  являются признаки состояния объекта, такие как представленные на рис. 3 параметры ГРК и время, а выходному сигналу соответствует прогноз изменения состояния объекта на исследуемом участке. Нейроны смещения представляют собой особый класс нейронов, не имеющих входных связей (их входные значения равны либо 1, либо  $-1$ ). Назначение нейронов смещения состоит в обеспечении возможности получения необходимого результата на выходе сети при обучении, за счет смещения графика функции активации нейронов.

При обучении ИНС корректирует веса нейронных связей, сопоставляя входной сигнал выходному с минимальной ошибкой. Минимизация ошибки осуществляется в соответствии с задачей

$$\sum_{k=1}^n (\tilde{y}_k - F_k(x, w))^2 \rightarrow \min,$$

где  $F_k(x, w)$  – значение выхода нейросети при подаче на ее вход  $k$ -го значения из обучающей выборки,  $\tilde{y}_k$  – целевое значение выхода нейросети для этого значения.

К одному из достаточно эффективных алгоритмов оптимизации весов нейросети относится алгоритм Левенберга–Марквардта (ЛМ-алгоритм), являющийся развитием метода градиентного спуска и позволяющий избежать локальных минимумов на поверхности ошибок за счет скорости сходимости второго порядка [9]. В качестве критерия оптимизации выступает среднеквадратическая ошибка модели на обучающей выборке.

Существуют различные способы оценки точности модели ИНС, такие как способы на основе среднеквадратичной ошибки, суммы квадратов ошибок, коэффициента детерминации, а также средней абсолютной процентной ошибки. В частности, среднеквадратичная ошибка (mean squared error) определяется следующим образом:

$$MSE = \frac{1}{k} \sum_{i=1}^k (m_i - p_i)^2,$$

где  $m_i$  – действительное значение,  $p_i$  – предсказанное значение,  $k$  – количество точек данных.

Помимо решения локальных диагностических задач, искусственные нейронные сети прямого распространения целесообразно использовать для синтеза эталонных регрессионных моделей при решении задач диагностирования сложных технических с использованием метода FDI (Fault Detection and Identification) [10].

В таком случае необходима декомпозиция комплекса параметров состояния железнодорожного пути на обозначенные категории, прогноз по каждой из которых моделируется простой ИНС и небольшим количеством входов, и одним выходом (шаблон пути, рихтовка, подуклонка, вертикальный и боковой износ рельсов и пр.). Параметры эталонной регрессионной модели объекта диагностирования  $\{\gamma_1, \gamma_2, \dots, \gamma_n\}$  определяются с условием минимизации ошибки модели на обучающей выборке параметров объекта, находящегося в условно принятом эталонном состоянии. В предположении нормального распределения признака для поиска предельно допустимого значения ошибки отклика обученной модели можно использовать формулу

$$\delta = \Omega_\alpha \cdot \sigma_\delta,$$

где с помощью  $\Omega_\alpha = m_\delta + 1,96 \cdot \frac{\sigma_\delta}{\sqrt{n}}$  задаются границы доверительного интервала для оценки математического ожидания  $m_\delta$  ошибки отклика,  $\sigma_\delta$  – среднее квадратическое отклонение ошибки отклика.

Алгоритм, направленный на разработку нейросетевой диагностической модели для оценки состояния железнодорожного пути, состоит из следующих этапов: 1) определение структуры модели с учетом концепции функционально-прозрачных нейронных сетей; 2) декомпозиция комплекса параметров железнодорожного пути на категории и создание нейросетевых таких субмоделей с ИНС несложной архитектуры, которые имеют  $r$  входных слоев, причем  $1 \leq r \leq 5$ , и один выходной слой; 3) получение сформированных обучающих выборок для каждой из субмоделей на основе информации, полученной мобильным диагностическим комплексом; 4) реализация машинного обучения; 5) поиск предельно допустимого значения ошибки отклика обученной модели; 6) адаптация состоящей из субмоделей эталонной нейросетевой модели к эксплуатационному техническому состоянию железнодорожного пути; 7) фазификация результатов работы субмоделей применительно к диагностической выборке и формирование вектора текущего состояния в  $i$ -й категории параметров состояния железнодорожного пути.

Отметим, что на последнем этапе алгоритма формирование вектора текущего состояния осуществляется с учетом нормированных функций принадлежности среднеквадратичной ошибки и следящего контрольного сигнала относительно каждой категории параметров. На промежуточных этапах для контроля качества обучения можно также использовать контроль остатков регрессии с использованием модели Тригга–Лича [11], которая позволяет формировать следящий контрольный сигнал в условиях адаптивности и реализации повышенной способности к самообучению.

## 5. Средства программной реализации интеллектуальных алгоритмов в информационных транспортных системах.

При обучении ИНС исходный набор данных делится на обучающий и тестовый массивы. Так как ИНС не способны экстраполировать далеко за пределы диапазона обучающих данных, результаты прогнозов на основании тестовых данных, сильно отличающихся от обучающих, будут неудовлетворительными. Однако при недостаточном объеме тестовой выборки точность работы ИНС будет затруднительно проверить, поэтому для обеспечения заданной точности прогнозов требуется правильный выбор тестовой и обучающей выборки [12]. Оптимальным вариантом решения этой проблемы будет варьирование размеров обучающей выборки от 20 до 80% общего объема данных с последующей проверкой точности модели методом среднеквадратичной ошибки.

Программную реализацию алгоритмов ИНС чаще всего осуществляют на базе языков C++ и Python, хорошо проявивших себя при решении различных типов задач машинного обучения. Язык C++ обладает расширенными возможностями контроля при машинном обучении за счет сочетания в себе возможностей как низкоуровневого, так и высокоуровневого языка программирования. Помимо того, C++ хорошо подходит для масштабных, ресурсоемких задач из-за статической типизации данных, обеспечивающей сравнительно высокую скорость обработки задач. К недостаткам C++ относят общую относительно высокую сложность освоения и обслуживания.

Язык Python, построенный на базе технологий Open Source, в настоящее время является наиболее популярным и универсальным инструментом для анализа данных. Недостатки языка Python связаны, в основном, с сильным разрастанием кода при решении глобальных задач, что приводит к серьезным временным и финансовым затратам на поиск ошибок. В то же время из-за сложившегося обширного и активного сообщества разработчиков, постоянно пополняющих язык готовыми библиотеками машинного обучения, Python является оптимальным выбором для исследователей, работающих с большими данными в любой предметной области.

На основе описанного в разделе 4 настоящей работы базового алгоритма создания нейросетевой диагностической модели для оценки состояния железнодорожного пути, и на основе модификаций этого алгоритма проводится разработка базового программного обеспечения с применением языка Python и встроенных математических библиотек.

### Заключение.

Существующие в настоящее время методы интеллектуального анализа больших данных обладают высоким потенциалом повышения надежности всего инфраструктурного комплекса железных дорог, но требуют при этом принципиальных изменений в подходе к работе с данными на всех уровнях управления железнодорожным хозяйством.

Конечной целью интеграции информационных систем железнодорожного транспорта является их глобальное взаимодействие для формирования комплексной оценки рисков возможных событий и достижения требуемых показателей надежности и безопасности движения. В настоящее время, достижение поставлен-

ной цели затруднительно без применения технологий работы с большими данными (Big Data) и гибких методов интеллектуального сбора и анализа данных, таких как искусственные нейронные сети, доказавших свою состоятельность в качестве инструмента для порождения достоверных гипотез в различных областях науки. В качестве перспективных направлений следует отметить разработку когнитивных карт для анализа транспортных моделей с неполной информацией [13] и использование алгоритмов оптимизации и интеллектуальных алгоритмов для поиска оптимальных параметров [14].

Рассмотренный в настоящей работе подход к разработке инструментально-методического обеспечения задач обработки информации и управления данными направлен на совершенствование компьютеризированных средств диагностики состояния железнодорожного пути, а также на функциональное расширение возможностей информационных транспортных систем с интеллектуальными компонентами. Нейросетевой алгоритм синтеза эталонной диагностической модели для оценки состояния железнодорожного пути может быть использован при создании проблемно-ориентированного программного обеспечения.

### Литература

1. Концепция развития систем диагностики и мониторинга объектов путевого хозяйства на период до 2025 года. // URL: <https://docs.cntd.ru/document/420365526> (дата обращения: 23.12.21).
2. Инструкция по оценке состояния инфраструктуры с использованием новых диагностических средств комплексной диагностики инфраструктуры («ИНТЕГРАЛ», «ЭРА»). Утверждена распоряжением ОАО «РЖД» от 05.12.2011.
3. Розенберг Е.Н., Розенберг А.М., Замышляев А.М. Система КАСАНТ: задачи, возможности, перспективы развития // Железнодорожный транспорт. 2008. № 9. С. 6–9.
4. Гапанович В.А., Шубинский И.Б., Замышляев А.М., Розенберг Е.Н. Система адаптивного управления техническим содержанием инфраструктуры железнодорожного транспорта (проект УРРАН) // Надежность. 2015. № 2. С. 4–13.
5. Замышляев А.М. Предпосылки для создания цифровой системы управления безопасностью движения // Надежность. 2019. № 4. С. 45–52.
6. Дружинина О. В., Людаговская М.А. Интеллектуальные методы для разработки и совершенствования информационно-управляющих систем на железнодорожном транспорте // Транспорт: наука, техника, управление. 2019. № 8. С. 3–12.
7. Хайкин С. Нейронные сети: полный курс. М.: Диалектика, 2019.
8. Shahin M.A. State-of-the-art review of some artificial intelligence applications in pile foundations // Geosci Front. 2016. 7(1). P. 33–44.
9. Transtrum M. K., Sethna J. P. Improvements to the Levenberg–Marquardt algorithm for nonlinear least-squares minimization // arXiv: 1201.5885v1 [physics.data-an] 27 Jan 2012. 32 p.
10. Грачев В. В., Грищенко А. В., Кручек В. А. Методика синтеза нейросетевых диагностических моделей сложных технических объектов // Автоматика на транспорте. 2020. Т. 6. № 4. С. 466–483.

11. *Лукашин Ю.П.* Адаптивные методы краткосрочного прогнозирования временных рядов. М.: Финансы и статистика, 2003.

12. *Шарден Б., Боскетти А., Массарон Л.* Крупномасштабное машинное обучение вместе с Python. М.: ДМК-Пресс, 2018.

13. *Оборотов А.В., Людаговская М.А., Кабанов М.А.* Применение методов искусственного интеллекта и когнитивного моделирования для исследования технических систем диагностирования // Материалы всероссийской научно-практической конференции «Актуальные проблемы математики, механики и естествознания», посвященной 100-летию профессора А.А. Шестакова (Москва, МИИТ, 23-24 апреля 2020 г.). М.: МИИТ, 2021. С. 115–125.

14. *Druzhinina O.V., Masina O.N., Petrov A.A., Lisovsky E.V., Lyudagovskaya M.A.* Neural network optimization algorithms for controlled switching systems // *Advances in Intelligent Systems and Computing (AISC)*. 2020. V. 1225. P. 470–483.

#### Сведения об авторах:

**Дружинина Ольга Валентиновна**,  
Федеральный исследовательский центр  
«Информатика и управление» Российской академии  
наук (ФИЦ ИУ РАН), главный научный сотрудник.  
Адрес: 119333 Москва, ул. Вавилова, 44, корп. 2.  
Тел. +7(499)-135-62-60.  
E-mail: ovdruzh@mail.ru.

**Людаговская Мария Андреевна**,  
Российский университет транспорта РУТ (МИИТ),  
аспирант.  
Адрес: 127994, Москва, ул. Образцова, д. 9, стр. 9.  
Тел. +7 (499)-649-19-35.  
E-mail: m.ludagovskaya@gmail.com.