



О построении интеллектуальной подсистемы анализа параметров сортировочного узла



Владимир ГРИДИН
Vladimir N. GRIDIN

Виктор ДОЕНИН
Viktor V. DOENIN



Владимир ПАНИЩЕВ
Vladimir S. PANISHCHEV

Гридин Владимир Николаевич – доктор технических наук, профессор, научный руководитель ЦИТП РАН, Москва, Россия.

Доенин Виктор Васильевич – доктор технических наук, профессор Российского университета транспорта (МИИТ), Москва, Россия.

Панищев Владимир Славиевич – кандидат технических наук, старший научный сотрудник ЦИТП РАН, Москва, Россия.

On Construction of an Intelligent Subsystem for Analyzing the Parameters of a Marshalling Hub

(текст статьи на англ. яз. – English text of the article – p. 14)

В работе рассмотрены вопросы непрерывного мониторинга обстановки на сортировочной станции и выявления возможности возникновения опасных ситуаций. Предлагается подход к построению автоматизированной интеллектуальной подсистемы анализа и своевременного прогнозирования критической загруженности железнодорожных сортировочных узлов. Предложено решение задачи с помощью сетевых коммуникационных технологий за счёт использования информации от автоматизированных систем сбора данных и нейросетевой подсистемы поддержки принятия решений.

Ключевые слова: транспорт, интеллектуальная система, системный анализ, прогнозирование критических ситуаций, имитационное моделирование, сортировочный узел, нейронная сеть, информация, коммуникационные технологии.

Актуальные задачи мониторинга и перспективы развития железнодорожного транспорта требуют использования современных методов теории транспортных систем, а также создания новых инструментальных средств и систем автоматизированного проектирования. В частности, это касается непрерывного мониторинга обстановки на сортировочной станции, своевременного оповещения о возможных коллизиях и повышения эффективности погрузочно-разгрузочных операций.

Основные проблемы в области логистики на сортировочной станции, для решения которых применяется имитационное моделирование, заключаются в увеличении пропускной способности путей, поиске перспективных вариантов, обеспечивающих рациональное использование ресурсов, минимальный уровень издержек, снижение вероятности аварийных ситуаций на путях и станциях, оценку загрузки сортировочного узла.

Для подобных целей широко используются проблемно-ориентированные имита-

ционные модели, разработанные, как правило, в среде систем профильного типа [1–4]. При разработке имитационных моделей реальные транспортные системы представляются в виде систем массового обслуживания. Трудоёмкость решения задачи управления при этом заключается в том, что распределение ресурсов между множественными компонентами транспортной системы осуществляется в условиях меняющихся приоритетов и интенсивного взаимодействия процессов, которые крайне сложно сформулировать на языке формализованных правил и совокупностей действий, а значит и сложно или в некоторых случаях нереализуемо построить адекватную ситуации математическую модель. В связи с этим, собственно, решение такого рода задач и осуществляется на основе построения имитационной модели, учитывающей вероятностные характеристики происходящих процессов.

I.

Построение имитационной модели сортировочного узла позволяет проводить системное исследование и оценку проектно-технологических решений для существующих и проектируемых узлов, даёт возможность отслеживать динамику движения ресурсов, их эффективность, выявлять «узкие места», особенности процессов функционирования станции в различных условиях (и при критических нагрузках), моделируя действия «что если», в том числе на основе элементов нечёткой логики и математического аппарата нейронных сетей.

Проведённый анализ показал, что существующие имитационные модели [5–11] требуют предварительной настройки, ручного ввода данных и значительных затрат времени. Создание эффективной имитационной модели сортировочного узла предполагает адекватное описание специфики технологических процессов во всех подсистемах и их системного взаимодействия. В ходе моделирования используются уравнения динамики изменения количества вагонов для путей сортировочного парка, известные величины групп вагонов на путях, заранее заданные пропускные способности линий для расчётной пространственно-временной сети и т.п., однако в режиме реального времени эта инфор-

мация не всегда доступна и соответственно не позволяет строить прогнозы загрузки узла.

Для построения модели, максимально приближенной к работающей сортировочной станции, предлагается в качестве входных данных использовать информацию автоматизированной системы управления о месте нахождения вагонов, очередности формирования составов, а также сведения от системы технического зрения, которая автоматически считывает номера, количество прибывающих вагонов, формирует ответ о типе грузов и типе вагонов.

Известны примеры разработки математической модели извлечения данных о грузопассажирских перевозках посредством отбора поступающих с распределённых территориально источников изображений, которая позволяет описать, моделировать процессы их анализа и распознавания с целью измерения характеристик и классификации объектов. Созданы и алгоритмы обработки изображений в программируемых логических интегральных схемах и специализированных процессорах в условиях ограниченных вычислительных ресурсов [12].

Таким образом, имитационное моделирование работы сортировочной станции, с одной стороны, может быть использовано для оптимизации процессов функционирования с учётом выбранных целевых показателей, а с другой — для отработки различных нештатных сценариев и режимов критической загруженности. Однако применение данного подхода для прогнозирования критической загруженности железнодорожного сортировочного узла в режиме реального времени не всегда удобно и возможно, особенно если это приходится осуществлять в рамках глобальной системы регулирования транспортных потоков. В связи с этим возникает потребность в построении автоматизированной подсистемы мониторинга значений параметров, характеризующих текущую загруженность и режим функционирования сортировочного узла, а также прогнозирования и заблаговременного оповещения о возможности возникновения критической ситуации, в том числе с учётом планируемого поступления грузовых составов.



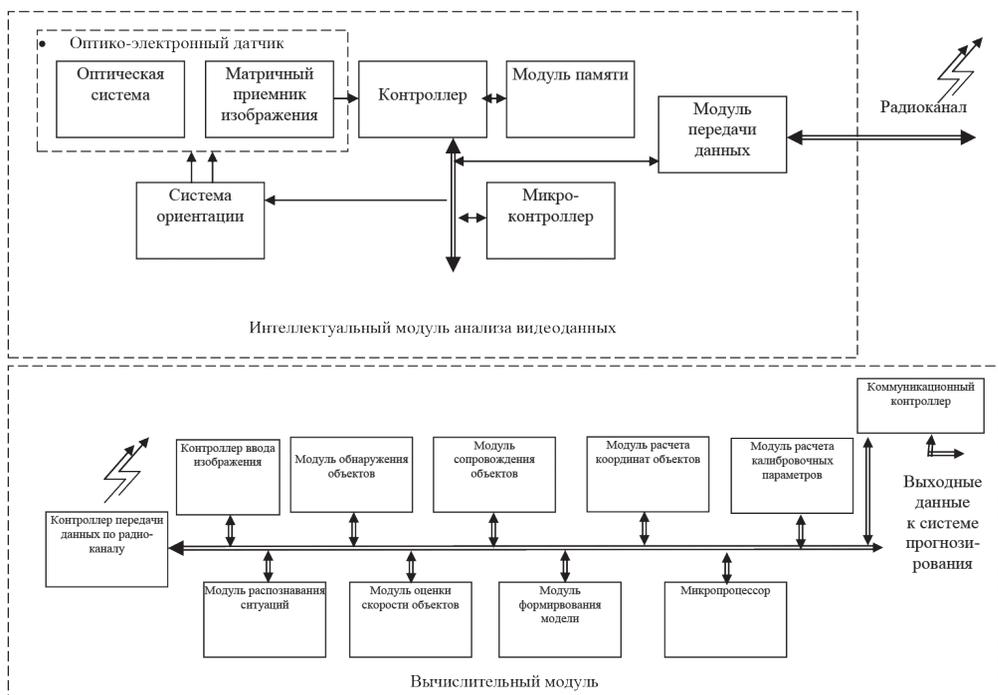


Рис. 1. Структурно-функциональная организация системы технического зрения.

II.

В качестве математического аппарата интеллектуальной подсистемы анализа и прогнозирования предлагается совместное использование методов логического вывода, основным представителем которых являются методы нечёткой логики и дерева решений, а также нейросетевые методы обработки информации. Это обусловлено большим числом разнотипных параметров, которые способны повлиять на пропускную способность железнодорожного сортировочного узла, а также свойством нейронных сетей, позволяющим моделировать нелинейные процессы, работать с зашумлёнными данными, адаптироваться к условиям функционирования, обобщать и извлекать существенные особенности из поступающей информации. Ключевую роль также играют вопросы автоматизации процесса принятия решений и прогнозирования.

Источником получения визуальных данных о текущем расположении подвижного состава и грузов планируется сделать сетевые (IP) видеокamеры, размещённые в ключевых узлах сортировочной станции и объединённые в единую сеть. Для объединения данных от различных видеокamер

используются специально разработанные алгоритмы формирования единого рабочего пространства, включающие алгоритмы калибровки и вычисления позиций каждого вагона в трёхмерном пространстве на основе анализа их перемещения по железнодорожным путям при наблюдении с различных IP видеокamер. Сформирована единая рабочая сцена, содержащая наблюдаемые с различных источников визуальных данных объекты подвижного состава, грузы и т.д. Далее для каждого объекта вычисляется его местоположение в трёхмерном пространстве с привязкой к некоторым, заранее заданным реперным стационарным объектам на сортировочной станции. При возможности производится на основе априорных табличных данных оценка массы вагона, груза на платформе и иных характеристик.

Рассмотрим структурно-функциональную организацию системы технического зрения, обеспечивающую получение визуальных данных и анализ ситуации (рис. 1).

Система технического зрения состоит из нескольких интеллектуальных модулей анализа видеоданных и вычислительного модуля. Интеллектуальные модули располагают территориально таким образом,

чтобы они обеспечивали одновременное наблюдение и получение видеоданных на ключевых узлах сортировочной станции. Каждый интеллектуальный модуль отвечает за анализ только своего участка сортировочной станции и, предварительно обработав, передаёт полученную информацию в вычислительный модуль. Вычислительный модуль обеспечивает обобщение информации обо всех интеллектуальных модулях и передачу полученных качественных и количественных характеристик о текущем состоянии и процессе формирования/расформирования составов.

Интеллектуальный модуль представляет собой конструктивно и функционально автономное устройство, получающее команды управления от вычислительного модуля, обеспечивающие согласно полученным командам вычисление параметров местоположения подвижных железнодорожных объектов и их характеристик, а также обнаружение критических ситуаций. Принцип функционирования каждого интеллектуального модуля состоит в следующем: оптико-электронный датчик, ориентированный при помощи системы ориентации на заданный участок сортировочной станции, непрерывно получает изображения, поступающие через контроллер в модуль памяти. Микроконтроллер считывает каждый кадр изображения и производит необходимые для вычисления параметров железнодорожных подвижных объектов действия над изображениями: обнаружение объектов, предварительное распознавание, отнесение их к определённому классу и вычисление параметров. Данные через модуль передачи и радиоканал на частоте 2,4 ГГц переправляются в вычислительный модуль.

Вычислительный модуль после получения очередных данных от всех интеллектуальных модулей производит комплексный анализ ситуации на сортировочной станции, а также непрерывно в реальном времени передаёт результаты анализа и вычисленные параметры подвижных объектов (вагонов, платформ, маневровых локомотивов) в процессе сортировки состава в автоматизированную интеллектуальную подсистему анализа и прогнозирования загруженности сортировочной станции, которая, имея задание на входе о форми-

ровании того или иного состава, выдаёт на своём выходе рекомендации по перемещению вагонов для формирования целевого состава с учётом выбранного критерия оптимальности.

В общем случае структура потоков движения транспортного состава на сортировочной станции представляется в виде графа G [5, 13].

На пропускную способность станций существенно влияет перерабатывающая способность сортировочных горок, представляющая собой обработку наиболее вероятного числа поездов (вагонов) за сутки при оптимальном использовании путевого развития и технического оснащения. На перерабатывающую способность сортировочной горки, кроме технических и технологических факторов, также оказывают влияние параметры состава, подлежащего расформированию, в частности вес вагонов, характеристики груза, число отцепов в составе, число замыкающих групп и т.д. Не менее важен учёт погодных условий, которые могут оказать существенное влияние на работу станции.

Движение вагонов после расцепки на сортировочной горке реализуется в соответствии со следующими параметрами [5, 13]:

- матрица пропускной способности $C = C[c_{ij}]$, где c_{ij} – пропускные способности ветвей графа G , соответствующих путям, соединяющим узел i с узлом j ;

- матрица расстояний между узлами, вершинами графа $G L = [l_{ij}]$;

- стоимостная матрица $Q = [q_{ij}]$, где q_{ij} определяет стоимость единицы пути движения сцепки вагонов по ветви ij ;

- входная матрица назначений $Z_i = [z_{ki}(t)]$, элементы которой соответствуют плану формирования поездов (количество вагонов, поступающих на входной узел в момент времени t);

- выходная матрица назначений $Y_i = [y_{ki}(t)]$, элементы которой соответствуют прогнозируемой загрузке путей сортировочного узла (количество вагонов, находящихся на выходных путях в момент времени t).

Минимизация затрат на формирование состава обеспечивается минимизацией функционала

$$P = \sum \sum P_{ij} = \sum \sum (k_1 \cdot l_{ij} + k_2 \cdot g_{ij} + k_3 \cdot t_{cp}),$$



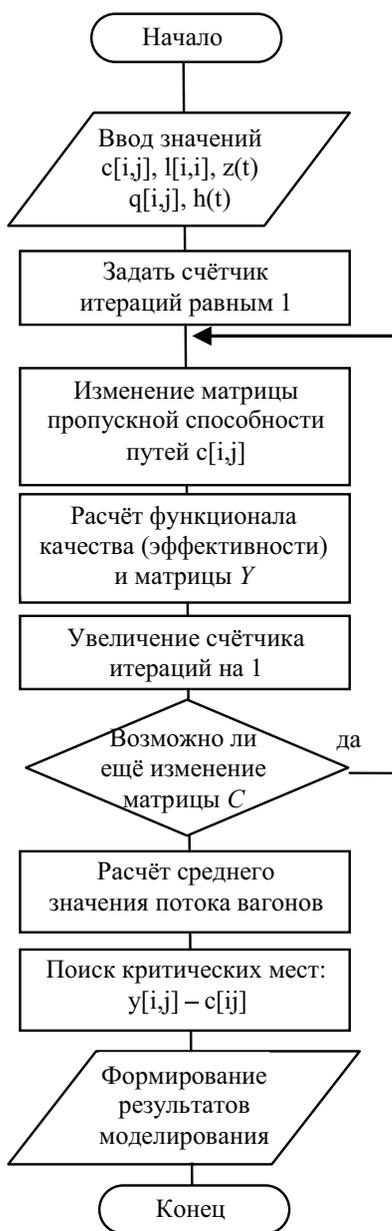


Рис. 2. Обобщённый алгоритм функционирования системы прогнозирования.

где k_i – весовые коэффициенты, определяющие влияние расстояния, времени, стоимости движения по ветвям; t_{cp} – среднее значение времени, затраченное составами на формирование/расформирование в узле.

При этом, с одной стороны, необходимо обеспечить максимальный поток между узлами, а с другой стороны, иметь минимум затрат. Поиск соотношений величин реализуется с использованием подходов [13–16].

Процесс формирования и расформирования составов описывается с помощью распределения вероятностей. Функции распределения для каждого i -го узла сети задаются матрицей $H_i = [h_{ki}(t)]$, где каждый элемент есть функция распределения времени на формирование-расформирование в i -ом узле для состава, пришедшего с узла k и следующего в узел l . В разрабатываемой системе эти функции рассчитываются с помощью статистического анализа и методов нейросетевой обработки информации [17].

Матрица пропускной способности $C = C[c_{ij}]$ заполняется на основе статистического подхода, анализа пропускной способности за несколько лет с учётом параметров состава и погодных условий, для чего необходима прогностическая нейронная сеть.

Матрица расстояний $L = [l_{ij}]$ является заранее известной величиной и определяется существующей структурой расположения путей и стрелок на сортировочной горке.

Стоимостная матрица $Q = [q_{ij}]$ строится на основе автоматизированного сбора информации о задержках на станции локомотивов и локомотивных бригад в режиме реального времени. Кроме того, предлагается учитывать прогнозирование, анализ пропускной способности за несколько лет, для чего также нужна нейронная сеть.

Входная матрица назначений в $Z_i = [z_{ki}(t)]$ также известна и определяется планом работы сортировочной горки.

Выходная матрица назначений $Y_i = [y_{ki}(t)]$ рассчитывается с использованием нейросетевого подхода.

Обобщённый алгоритм функционирования системы прогнозирования представлен на рис. 2.

III.

В качестве математического аппарата автоматизированной интеллектуальной подсистемы анализа загруженности сортировочной станции использован нейросетевой подход. Он подразумевает необходимость выполнения следующих основных этапов [17]:

1. Предварительная обработка данных, выявление характерных особенностей, наиболее значимых признаков и их сочетаний.

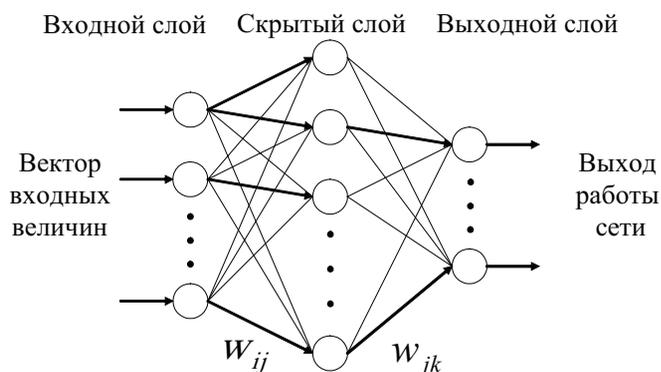


Рис. 3. Структура перцептрона с двумя слоями нейронов.

2. Подготовка исходных данных, заключающаяся в их кодировании и нормировке для увеличения информативности примеров и приведения к виду, который доступен для обработки сетью.

3. Выбор нейросетевой архитектуры (парадигмы) и таких её ключевых параметров, как количество слоёв и число нейронов в каждом из них.

4. Обучение, в процессе которого нейросеть осуществляет построение правил, характеризующих имеющиеся закономерности в данных.

5. Использование обученной нейросети в качестве эксперта, подавая на вход новые, ещё не предъявлявшиеся вектора входных параметров, и получая результат её работы.

6. Интерпретации полученного результата.

На первом этапе осуществляется анализ всех возможных признаков технического и технологического характера, параметров текущей загруженности, в частности, числа свободных/занятых путей и количества вагонов в сортировочном парке, ожидающих роспуск и планируемых к поступлению составов, веса вагонов, наличия опасных грузов, количества отцепов в составе, замыкающих групп и т.д. Дополнительно можно учитывать влияние погодных условий, температуру воздуха, скорость и направление ветра, наличие осадков.

На втором этапе происходит кодирование и нормировка исходных данных, что связано с необходимостью работать с большим числом разнотипных параметров. Это могут быть числа в произвольном диапазоне, даты, символьные строки, категоризованные данные и т.д. В то же время особенность нейронных сетей заключается в том,

что в них все входные и выходные параметры представлены в виде чисел с плавающей точкой, обычно в диапазоне $[0...1]$ или $[-1...1]$. Дополнительной целью предобработки данных является увеличение информативности примеров для повышения скорости и эффективности обучения. Чем больше бит информации принесёт каждый пример, тем лучше используются имеющиеся данные.

Среднее количество информации, приносимой каждым примером x , равно энтропии распределения значений компоненты $H(x)$. Если эти значения сосредоточены в относительно небольшой области единичного интервала, информационное содержание такой компоненты мало и, когда все значения переменной совпадают, она не несёт никакой информации. Напротив, если значения переменной x равномерно распределены в единичном интервале, информация её максимальна.

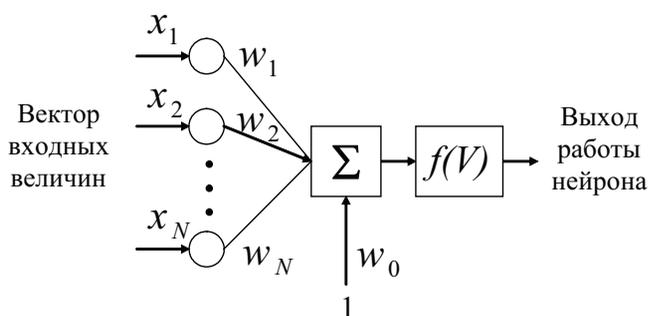
Общий принцип предобработки данных для нейросетевого анализа состоит в таком кодировании и нормировке непротиворечивых данных, чтобы добиться максимизации энтропии входов и выходов.

Последующие два этапа неразрывно связаны и заключаются в выборе нейросетевой парадигмы, её ключевых параметров и подстройке весовых коэффициентов. Для решения поставленной задачи вполне можно воспользоваться сетью прямого распространения, а именно, многослойным перцептроном, структура которого показана на рис. 3.

В качестве входных величин нейросети выступают матрицы, представленные выше и преобразованные в столбец входных параметров.



Рис. 4. Структурная схема нейрона, используемого при построении системы интеллектуального анализа загруженности сортировочного узла.



В узлах сети расположены нейроны, каждый из которых последовательно осуществляет следующий набор вычислений. Сначала вычисляется взвешенная сумма V входных величин x_i [18]:

$$V = \sum_{i=1}^N w_i \cdot x_i + w_0.$$

Здесь N – размерность пространства входных сигналов, w_i – синаптические коэффициенты или веса, w_0 – смещение.

Затем вступает в действие функция активации f . Одной из наиболее часто используемых её функций является логистическая или сигмоида, которая имеет вид:

$$f(V) = \frac{1}{1 + \exp(-b \cdot V)},$$

где коэффициент b определяет крутизну сигмоиды.

Схематично структура нейрона представлена на рис. 4.

Применив приведённые формулы ко всем нейронам сети, получим результирующую формулу работы сети в целом:

$$y_k(x_1, \dots, x_N) = f\left(\sum_{j=0}^m w_{jk} \cdot f\left(\sum_{i=0}^n w_{ij} x_i\right)\right),$$

где y_k – значение k -го нейрона выходного слоя [19].

IV.

Одной из основных проблем при использовании нейросетевого подхода является выбор оптимальной топологии сети, значений параметров и структурных особенностей, которые бы наилучшим образом удовлетворяли решаемой задаче на имеющихся исходных данных. С одной стороны, число скрытых элементов должно быть достаточным для решения поставленной задачи, а с другой – не может быть слишком большим, чтобы обеспечить

ожидаемую обобщающую способность и избежать переобучения. Это связано с тем обстоятельством, что количество скрытых элементов зависит от сложности того отображения, которое нейронная сеть стремится воспроизвести, а оно заранее неизвестно.

Очевидно, что каждый сортировочный узел является уникальным объектом и даже близкие по перерабатывающей способности станции могут сильно отличаться по техническим и технологическим признакам, степени влияния отдельных параметров на результирующую производительность. В связи с этим и построение нейросети необходимо осуществлять индивидуально для каждого объекта, и выборку данных для обучения сети тоже вести индивидуально. В качестве исходной выборки можно использовать как реальные исторические данные, характеризующие параметры работы станции за период, в рамках которого не изменялись её основные технические и технологические показатели, так и данные, полученные в рамках имитационного моделирования, в том числе при обработке нештатных сценариев и режимов критической загруженности.

Для обучения сетей класса «многослойный перцептрон» можно воспользоваться алгоритмом обратного распространения ошибки (Backpropagation, BP), который является алгоритмом градиентного спуска, минимизирующим среднюю квадратическую ошибку работы сети:

$$E = \frac{1}{P} \sum_{p=1}^P \sum_k (d_p^k - y_p^k)^2,$$

где P – число примеров в обучающем множестве, d_p^k – желаемый выход k -го нейрона выходного слоя на p -ом обучающем примере.

Минимизация величины E осуществляется с помощью градиентных методов. Изменение весов происходит в направлении, обратном к направлению наибольшей крутизны для функции стоимости:

$$w(t+1) = w(t) - \varepsilon \frac{\partial E}{\partial w},$$

где ε — величина градиентного шага или коэффициент обучения.

Результатом работы нейронов выходного слоя могут быть приняты величины в диапазоне $[0, 1]$, где близкие к 0 значения характеризуют малую загрузку, а близкие к 1 — критическую загрузку сортировочного узла.

В дальнейшем обученная нейросеть способна выполнять роль автоматического эксперта для постоянного мониторинга текущей загруженности сортировочной станции, прогнозирования и заблаговременного оповещения о возможности возникновения критической ситуации. Интеграция множества таких экспертов с помощью коммуникационных технологий в глобальную систему регулирования транспортных потоков обещает обеспечить своевременное предупреждение рисков и оптимизацию параметров грузоперевозочного процесса.

ЛИТЕРАТУРА

1. Рахмангулов А. Н. Железнодорожные транспортно-технологические системы: организация функционирования: Монография. — Магнитогорск: Изд-во МГТУ им. Г. И. Носова, 2014. — 300 с.
2. Мирошниченко В. М., Недзельский Е. В. Имитационное моделирование сложных транспортных систем (на примере железнодорожных станций) // Material. Confer. Internațională «Sisteme de transport și logistică» (Chișinău, 11–13 Decembrie 2013) / АТИС; Chișinău, Evrica, 2013. С. 394–400.
3. Ульяницкий Е. М., Ломаш Д. А. Моделирование систем. — Часть 1: Имитационное моделирование объектов (процессов) на железнодорожном транспорте: Учеб.-метод. пособие. — Ростов-на-Дону: РГУПС, 2008. — 38 с.
4. Казаков А. Л., Маслов А. М. Применение имитационного моделирования для синтетического планирования грузовых терминалов железнодорожного транспорта // Вестник ИрГТУ. — 2010. — № 6. — С. 146–153.
5. Максимей И. В., Сукач Е. И., Гируц П. В., Ерофеева Е. А. Имитационное моделирование

вероятностных характеристик функционирования железнодорожной сети // Математические машины и системы. — 2008. — № 4. — С. 147–153.

6. Максимей И. В., Сукач Е. И., Гируц П. В., Ерофеева Е. А. Автоматизация этапов разработки и эксплуатации имитационных моделей транспортных систем // Проблемы программирования. — 2008. — № 4. — С. 104–111.

7. Александров А. Э., Ковалёв И. А., Пермикин В. Ю. Моделирование транспортных систем: Учеб.-метод. пособие. — Екатеринбург: УрГУПС, 2011. — 56 с.

8. Лычкина Н. Н. Проектирование логистической инфраструктуры межрегионального мультимодального логистического центра с применением имитационного моделирования // Логистика и управление цепями поставок. — 2014. — № 5. — С. 48–56.

9. Современные проблемы транспортного комплекса России: Межвуз. сб. науч. трудов / Под ред. А. Н. Рахмангулова. — Магнитогорск: Изд-во МГТУ им. Г. И. Носова, 2011. — 209 с.

10. Программа имитационного моделирования работы припортовой железнодорожной станции с вероятностно-статистическим подходом к изменению параметров поступающего вагонотока. Свидетельство о государственной регистрации программы для ЭВМ № 2014613827 / Зарегистр. в реестре программ для ЭВМ 08.04.2014. Р. Г. Король, П. В. Даниленко.

11. Электронный ресурс: <http://gdsu.stu.ru/science/>. Доступ 22.08.2017.

12. Рыжиков Ю. И. Имитационное моделирование. Теория и технологии. — СПб.: Корона-принт; М.: Альтекс-А, 2004. — 384 с.

13. Технология системного моделирования / Под общ. ред. С. В. Емельянова. — М.: Машиностроение; Берлин: Техник, 1988. — 520 с.

14. Шеннон Р. Имитационное моделирование систем — искусство и наука: Пер. с англ. — М.: Мир, 1978. — 420 с.

15. Стерлигова А. Н. Управление запасами в цепях поставок: Учебник. — М.: Инфра-М, 2008. — 430 с.

16. Гридин В. Н., Солодовников В. И. Предобработка данных и выявление логических закономерностей на основе генетического алгоритма // Системы и средства информатики. — 2013. — № 2. — С. 244–259.

17. Гридин В. Н., Солодовников В. И., Карнаков В. В. Выбор начальных значений и оптимизация параметров нейронной сети // Новые информационные технологии в автоматизированных системах. — 2016. — № 19. — С. 270–273.

18. Гридин В. Н., Солодовников В. И., Карнаков В. В. Использование модульной нейронной сети BP-SOM для извлечения правил // Информационные технологии в проектировании и производстве. — 2015. — № 4. — С. 3–7.

19. Евдокимов И. А., Солодовников В. И. Автоматизация построения нейронной сети в рамках объектно-ориентированного подхода // Новые информационные технологии в автоматизированных системах. — 2015. — № 18. — С. 89–97. ●

Координаты авторов: **Гридин В. Н.** — info@ditc.ras.ru, **Доенин В. В.** — vidovas@mail.ru, **Панищев В. С.** — +7(495) 596–02–19.

Статья поступила в редакцию 19.07.2017, принята к публикации 31.08.2017.

Работа выполнена при поддержке РФФИ, проект 17–20–01133 офи_м_РЖД.

