




# 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.

**А**ктуальные 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.

## 1.

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

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





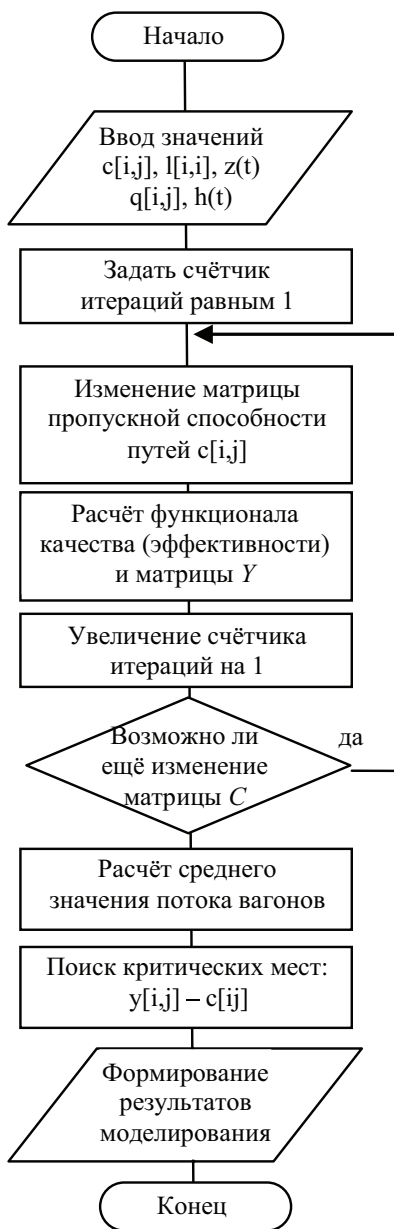


Рис. 2. Обобщённый алгоритм функционирования системы прогнозирования.

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  $\varepsilon$  — 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) / АТИ; 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](mailto:info@ditc.ras.ru), **Доенин В. В.** — [vidovas@mail.ru](mailto: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.**





## ON CONSTRUCTION OF AN INTELLIGENT SUBSYSTEM FOR ANALYZING THE PARAMETERS OF A MARSHALLING HUB

**Gridin, Vladimir N.**, Center for Information Technologies in Design of the Russian Academy of Sciences, Moscow, Russia.

**Doenin, Viktor V.**, Russian University of Transport (MIIT), Moscow, Russia.

**Panishchev, Vladimir S.**, Center for Information Technologies in Design of the Russian Academy of Sciences, Moscow, Russia.

### ABSTRACT

The article considers the issues of continuous monitoring of the situation at the marshalling yard and detection of the possibility of occurrence of dangerous situations. An approach is proposed for constructing an automated intellectual subsystem

for analyzing and timely forecasting the critical utilization of railway sorting units. The solution of the problem is proposed with the help of network communication technologies due to the use of information from automated data collection systems and the neural network decision support subsystem.

**Keywords:** transport, intelligent system, system analysis, forecasting of critical situations, simulation modeling, sorting node, neural network, information, communication technologies.

**Background.** Actual monitoring tasks and prospects for development of rail transport require the use of modern methods of the theory of transport systems, as well as creation of new tools and systems for automated design. In particular, this concerns continuous monitoring of the situation at the marshalling yard, timely notification of possible collisions and increasing the efficiency of loading and unloading operations.

The main logistics problems at the marshalling yard, for which solution simulation modeling is applied, consist in increasing the capacity of the tracks, searching for promising options that will ensure rational use of resources, minimum costs, reducing the probability of emergency situations on routes and stations, estimating the load of the sorting node.

For such purposes, problem-oriented simulation models, developed, as a rule, in a medium of profile type systems [1–4] are widely used. When developing simulation models, real transport systems are represented in the form of queuing systems. The complexity of solving the management problem is that distribution of resources among the multiple components of the transport system is carried out in the face of changing priorities and intensive interaction of processes, which are extremely difficult to be formulated in the language of formalized rules and sets of actions, and therefore it is difficult or in some cases impossible to build an adequate mathematical model. In this connection, in fact, the solution of these kinds of problems is carried out on the basis of construction of an imitation model that takes into account the probabilistic characteristics of the processes occurring.

**Objective.** The objective of the authors is to consider construction of an intelligent subsystem for analyzing the parameters of a sorting node.

**Methods.** The authors use general scientific and engineering methods, simulation modeling, evaluation approach, comparative analysis.

### Results.

#### I.

The construction of the simulation model of the sorting node allows to carry out system research and evaluation of design and technological solutions for existing and projected nodes, enables to monitor the dynamics of resource movement, their effectiveness, identify bottlenecks, the peculiarities of the station's operation in various conditions (and at critical loads), modeling actions «what if», including on the basis of elements of fuzzy logic and the mathematical apparatus of neural networks.

The analysis showed that the existing simulation models [5–11] require preliminary configuration, manual data entry and significant time costs. Creation of an effective simulation model of the sorting node assumes an adequate description of the specifics of technological processes in all subsystems and their system interaction. In the course of the simulation, equations of the dynamics of the change in the number of cars for the sorting fleet tracks, the known values of car groups on tracks, the predetermined line capacities for the calculated space-time network, etc. are used, however in real time this information is not always available and, accordingly does not allow to build forecasts for the node's load.

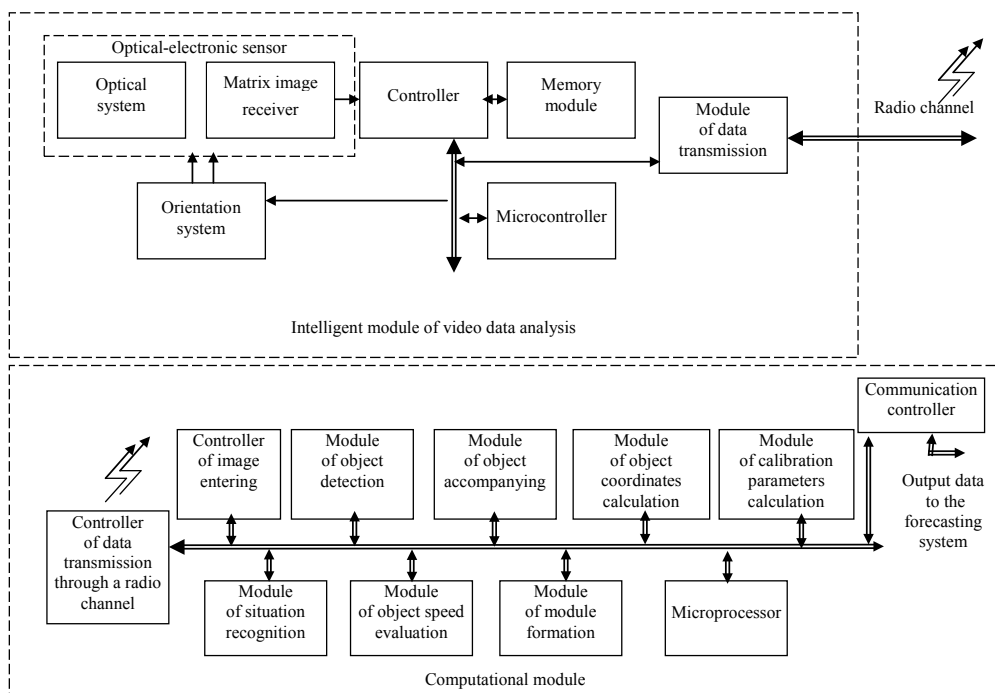
To build a model that is as close as possible to the operating marshalling yard, it is suggested to use the information of the automated control system on the location of cars, the order of formation of trains, as well as information from the technical vision system that automatically analyzes the numbers, the quantity of arriving cars, type of cargoes and type of cars.

There are examples of development of a mathematical model for retrieving data on cargo and passenger transportation by selecting images from geographically distributed sources that allows to describe, and simulate the processes of their analysis and recognition for the purpose of measuring characteristics and classifying objects. Image processing algorithms are also created in programmable logic integrated schemes and specialized processors for conditions of limited computing resources [12].

Thus, simulation modeling of the work of a marshalling yard, on the one hand, can be used to optimize the functioning processes taking into account selected targets, and on the other hand, for working out various non-standard scenarios and critical load modes. However, the application of this approach for forecasting the critical load of a railway sorting unit in real time is not always convenient and possible, especially if it is necessary to implement it within the framework of the global traffic regulation system. In this regard, there is a need to build an automated subsystem for monitoring of the values of the parameters that characterize the current workload and the mode of operation of the sorting unit, as well as for forecasting and early warning of a risk of occurrence of a critical situation, including taking into account the planned arrival of freight trains.

#### II.

As a mathematical apparatus of the intelligent subsystem for analysis and forecasting, it is proposed



**Pic. 1. Structural and functional organization of the system of technical vision.**

to share the methods of logical inference, the main representative of which are methods of fuzzy logic and decision trees, as well as neural network information processing methods. This is due to a large number of different types of parameters that can affect the capacity of the railway sorting node, as well as the property of neural networks that allow modeling non-linear processes, work with noisy data, adapt to operating conditions, generalize and extract essential features from incoming information. A key role is also played by the automation of decision-making and forecasting.

As a source of visual data on the current location of rolling stock and cargoes it is suggested to use network (IP) video cameras located in key nodes of the sorting station and integrated into a single network. To combine data from different video cameras, specially developed algorithms for forming a single workspace are used, including algorithms for calibrating and calculating the positions of each car in three-dimensional space based on analysis of their movement along railway tracks when viewed from various IP cameras. A unified working stage is formed, containing objects of rolling stock observed from various sources of visual data, goods, etc. Next, for each object, its location in three-dimensional space is calculated with reference to some, predetermined reference stationary objects at the marshalling yard. If possible, an estimate of the weight of the car, cargo on the platform and other characteristics is made on the basis of a priori tabular data.

Let's consider the structurally functional organization of the technical vision system, which provides visual data acquisition and situation analysis (Pic. 1).

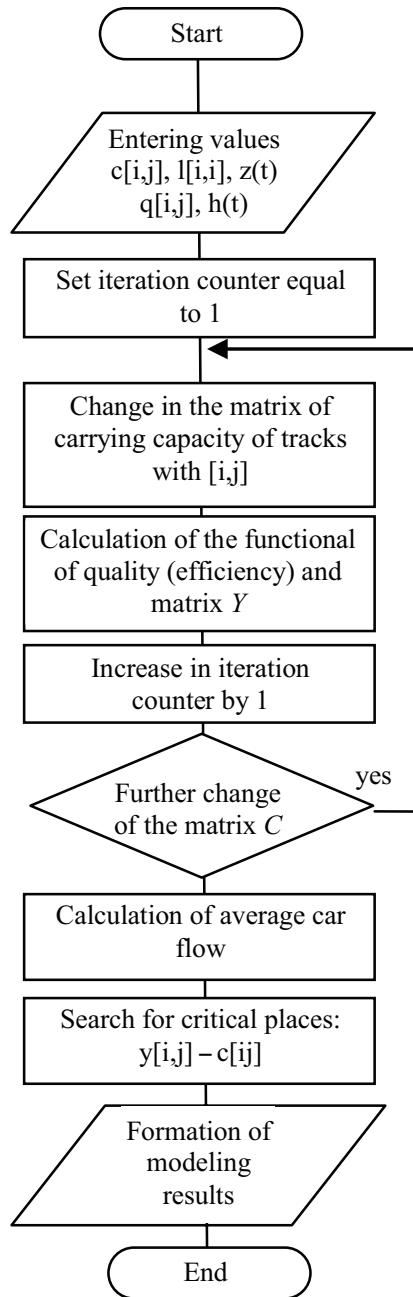
The technical vision system consists of several intelligent video analysis modules and a computational module. Intelligent modules are located geographically in such a way that they provide simultaneous observation and retrieval of video data at the key

nodes of the marshalling yard. Each intelligent module provides analysis of only its section of the marshalling yard and, after processing, transfers the information received to the computational module. The computational module provides a generalization of information on all intelligent modules and the transfer of the received qualitative and quantitative characteristics of the current state and the process of formation / breaking up of the trains.

The intelligent module is a structurally and functionally autonomous device that receives control commands from the computational module, providing, according to the received commands, the calculation of the location parameters of mobile railway objects and their characteristics, as well as the detection of critical situations. The principle of operation of each intelligent module is as follows: an opto-electronic sensor, oriented with the help of an orientation system to a given section of the marshalling yard, continuously receives images coming through the controller into the memory module. The microcontroller reads each frame of the image and produces the actions necessary for calculating the parameters of the railway mobile objects over the images: object detection, preliminary recognition and correlation to a certain class, and calculation of their parameters. The data through the data transmission module and the radio channel at 2,4 GHz are transmitted to the computational module.

The computational module, after receiving the next data from all intelligent modules, performs a comprehensive analysis of the situation at the marshalling yard, and also continuously and in real time transmits the results of the analysis and calculated parameters of the mobile objects (cars, platforms, shunting locomotives) in the process of sorting the train into an automated intellectual subsystem for analysis and forecasting the loading of the marshalling yard, which having an input task formation of a particular train issues recommendations





**Pic. 2. Generalized algorithm for functioning of the forecasting system.**

on the movement of cars for the formation of the target train, taking into account the chosen optimality criterion.


In the general case, the structure of the flows of a train's composition at the marshalling yard is represented in the form of a graph  $G$  [5, 13].

The capacity of the stations is significantly affected by the processing capacity of the humps, which is the processing of the most probable number of trains (cars) per day with optimal use of track facilities and technical equipment. The processing capacity of the hump, in addition to technical and technological

factors, is also influenced by the parameters of the composition to be broken up, in particular the weight of cars, the characteristics of the load, the number of uncouplings in the train, the number of closing groups, etc. No less important is the consideration of weather conditions, which can have a significant impact on the operation of the station.

Movement of cars after uncoupling on a hump is realized in accordance with the following parameters [5, 13]:

– carrying capacity matrix  $C = C[c_{ij}]$ , where  $c_{ij}$  are the carrying capacities of branches of graph  $G$



**Pic. 3. The structure of the perceptron with two layers of neurons.**

corresponding to tracks connecting node  $i$  to node  $j$ ;  
 – matrix of distances between nodes, vertices of the graph  $GL = [l_{ij}]$ ;

– cost matrix  $Q = [q_{ij}]$ , where  $q_{ij}$  determines the cost per unit of the track of car coupling movement along the branch  $ij$ ;

– input matrix of assignments  $Z_i = [z_{ik}(t)]$ , the elements of which correspond to the train formation plan (number of cars arriving at the input node at time  $t$ );

– output matrix of assignments  $Y_i = [y_{ik}(t)]$ , the elements of which correspond to the predicted load of the tracks of the sorting node (the number of cars located on the exit tracks at time  $t$ ).

Minimizing the cost of formation of a train is provided by minimizing the functional  $P = \sum \sum P_{ij} = \sum \sum (k_1 \cdot l_{ij} + k_2 \cdot g_{ij} + k_3 \cdot t_{av})$ , where  $k_i$  is weighting coefficients determining the influence of distance, time, cost of movement on branches;  $t_{av}$  is the average time spent by the trains for formation-breaking up at the node.

At the same time, on the one hand, it is necessary to ensure the maximum flow between nodes, and on the other hand, to have a minimum of costs. The search for correlation of quantities is realized using the approaches [13–16].

The process of formation and breaking up of trains is described using the probability distribution. The distribution functions for each  $i$ -th node of the network are given by the matrix  $H_i = [h_{ik}(t)]$ , where each element is the function of time distribution for formation-breaking up in the  $i$ -th node for the composition that came from node  $k$  and following to the node  $i$ . In the developed system, these functions

are calculated using statistical analysis and methods of neural network processing of information [17].

The capacity matrix  $C = C[c_{ij}]$ , is filled on the basis of a statistical approach, analysis of throughput for several years, taking into account the train's parameters and weather conditions, which requires a predictive neural network.

The distance matrix  $L = [l_{ij}]$  is a known quantity and is determined by the existing structure of the location of tracks and switches on the hump.

The cost matrix  $Q = [q_{ij}]$  is based on the automated collection of information on delays at the station of locomotives and locomotive brigades in real time. In addition, it is proposed to take into account the forecasting, the analysis of carrying capacity for several years, which also requires a neural network.

The input matrix of assignments in  $Z_i = [z_{ik}(t)]$ , is also known and determined by the work plan for the hump.

The output matrix of assignments  $Y_i = [y_{ik}(t)]$  is calculated using the neural network approach.


A generalized algorithm for the functioning of the forecasting system is shown in Pic. 2.

### III.

The neural network approach is used as the mathematical apparatus of the automated intellectual subsystem of analysis of the loading of the marshaling yard. It implies the need for the following main steps [17]:

1. Preliminary processing of data, identification of characteristic features, the most significant features and their combinations.

2. Preparation of the initial data, consisting in their coding and normalization to increase the informativeness



**Pic. 4. Structural diagram of the neuron used in constructing the system of intellectual analysis of the load of the sorting node.**





of the examples and bring them to a form that is available for processing by the network.

3. The choice of neural network architecture (paradigm) and its key parameters, such as the number of layers and the number of neurons in each of them.

4. Training, in the process of which the neural network implements the construction of rules that characterize the existing regularities in the data.

5. Using a trained neural network as an expert, submitting to the input new, not yet presented vector of input parameters, and getting the result of its work.

6. Interpretation of the result.

At the first stage, all possible technical and technological characteristics are analyzed, e.g. parameters of the current load, in particular the number of free / occupied tracks and the number of cars in the sorting park, trains awaiting breaking up and planned for the receipt, weight of cars, the presence of dangerous goods, the number of uncouplings in the train, closing groups, and so on. In addition, it is possible to take into account the influence of weather conditions, air temperature, wind speed and direction, the presence of precipitation.

At the second stage, the initial data is coded and normalized, which is associated with the need to work with a large number of different types of parameters. These can be numbers in an arbitrary range, dates, character strings, categorized data, etc. At the same time, the distinctive feature of neural networks is that in them all input and output parameters are represented as floating-point numbers, usually in the range [0 ... 1] or [-1 ... 1]. An additional purpose of data preprocessing is to increase the informative nature of the examples to increase the speed and effectiveness of training. The more bits of information each sample brings, the better the available data are used.

The average amount of information provided by each example  $x$  is equal to the entropy of the distribution of the values of the component  $H(x)$ . If these values are concentrated in a relatively small region of the unit interval, the information content of such a component is small and when all the values of the variable coincide, it does not carry any information. On the contrary, if the values of the variable  $x$  are uniformly distributed in the unit interval, the information is maximal.

The general principle of data preprocessing for neural network analysis is to encode and normalize consistent data in order to maximize the entropy of inputs and outputs.

The next two stages are inextricably linked and are the selection of the neural network paradigm, its key parameters and the adjustment of the weight coefficients. To solve the problem, it is quite possible to use a network of direct propagation, namely, a multilayer perceptron, the structure of which is shown in Pic. 3.

The input values of the neural network are the matrices presented above and converted into a column of input parameters.

At the nodes of the network neurons are located, each of which sequentially carries out the next set of calculations. First, the weighted sum  $V$  of the input quantities  $x_i$  [18] is calculated:

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

Here  $N$  is the dimension of the space of input signals,  $w_i$  is the synaptic coefficients or weights, and  $w_0$  is the displacement.

Then the activation function  $f$  comes into effect. One of the most commonly used functions is the logistic or sigmoid, which has the form:

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

where the coefficient  $b$  determines the steepness of the sigmoid.

Schematically, the structure of the neuron is shown in Pic. 4.

Applying the above formulas to all neurons of the network, we obtain the resulting formula for the operation of the entire network as a whole:

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

where  $y_k$  – the value of  $k$ -th neuron of the output layer [19].

#### IV.

One of the main problems in using the neural network approach is to select the optimal network topology, parameter values and structural features that would best suit the problem being solved on the available initial data. On the one hand, the number of hidden elements should be sufficient to solve the task, and on the other hand it cannot be too large to provide the expected generalizing ability and avoid retraining. This is due to the fact that the number of hidden elements depends on the complexity of the mapping that the neural network tends to reproduce, and it is not known in advance.

It is obvious that each sorting unit is a unique object and even stations close in their processing capacity can differ greatly in technical and technological features, the degree of influence of individual parameters on the resulting productivity. In this regard the construction of the neural network must be carried out individually for each object, and the selection of data for training the network, too, should be conducted individually. As the initial sample, it is possible to use both real historical data characterizing the parameters of the station operation over a period of time within which its main technical and technological indicators have not changed, as well as data obtained within the framework of simulation modeling, including in developing non-standard scenarios and regimes of critical congestion.

To train networks of the «multilayer perceptron» class, it is possible to use the Backpropagation (BP) algorithm, which is a gradient descent algorithm that minimizes the average quadratic network error:

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

where  $P$  is the number of examples in the training set,  $d_p^k$  is the desired output of the  $k$ -th neuron of the output layer on the  $p$ -th training example.

Minimization of the value of  $E$  is carried out using gradient methods. The change in weights occurs in the direction opposite to the direction of the greatest steepness for the cost function:

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

where  $\varepsilon$  is the value of the gradient step or the training coefficient.

The result of the work of the output layer neurons can be taken as values in the range [0, 1], where values close to 0 characterize a small load, and close to 1 values describe critical loading of the sorting node.

**Conclusion.** In the future, the trained neural network is able to perform the role of an automatic expert for continuous monitoring of the current load

of the marshalling yard, forecasting and early warning on a risk of occurrence of a critical situation. Integration of many such experts with the help of communication technologies into the global system of regulation of traffic flows promises to provide timely warning of risks and optimization of the parameters of the cargo transportation process.

## REFERENCES

1. Rakhmangulov, A. N. Railway transport-technological systems: organization of functioning: Monograph [*Zheleznodorozhnye transportno-technologicheskie sistemy: organizacija funkcionirovaniya. Monografija*]. Magnitogorsk, Publishing house of MSTU n.a. G. I. Nosov, 2014, 300 p.
2. Miroshnichenko, V. M., Nedzelsky, E. V. Simulation modeling of complex transport systems (using the example of railway stations) [*Imitacionnoe modelirovanie slozhnykh transportnykh sistem (na primere zheleznodorozhnykh stancij)*]. Proceedings of International conference «Sisteme de transport si logistic» (Chişinău, 11–13 Decembrie 2013), ATIC; Chişinău, Evrica, 2013, pp. 394–400.
3. Ulyanitsky, E. M., Lomash, D. A. Modeling of systems. Part 1: Simulation modeling of objects (processes) in railway transport: Teaching-methodological guide [*Modelirovanie sistem. – Chast' 1: Imitacionnoe modelirovanie ob'ektov (processov) na zheleznodorozhnom transporte: Ucheb.-metod. posobie*]. Rostov-on-Don, RGUPS publ., 2008, 38 p.
4. Kazakov, A. L., Maslov, A. M. Application of simulation modeling for synthetic planning of cargo terminals of railway transport [*Primenenie imitacionnogo modelirovaniya dlya sinteticheskogo planirovaniya gruzovykh terminalov zheleznodorozhnogo transporta*]. *Vestnik IrGTU*, 2010, Iss. 6, pp. 146–153.
5. Maksimei, I. V., Sukach, E. I., Giruts, P. V., Erofeeva, E. A. Simulation modeling of probabilistic characteristics of the railway network functioning [*Imitacionnoe modelirovanie veroyatnostnykh harakteristik funkcionirovaniya zheleznodorozhnoy seti*]. *Matematicheskije mashiny i sistemy*, 2008, Iss. 4, pp. 147–153.
6. Maksimei, I. V., Sukach, E. I., Giruts, P. V., Erofeeva, E. A. Automation of the stages of development and operation of simulation models of transport systems [*Avtomatizacija etapov razrabotki i ekspluatatsii imitacionnykh modelej transportnykh sistem*]. *Problemy programirovaniya*, 2008, Iss. 4, pp. 104–111.
7. Aleksandrov, A. E., Kovalev, I. A., Permikin, V. Yu. Modeling of transport systems: Training-methodological guide [*Modelirovanie transportnykh sistem: Ucheb.-metod. posobie*]. Yekaterinburg, UrGUPS publ., 2011, 56 p.
8. Lychkina, N. N. Designing the logistics infrastructure of an interregional multimodal logistics center with the use of simulation modeling [*Proektirovanie logisticheskoy infrastruktury mezhhregional'nogo mul'timodal'nogo logisticheskogo centra s primeneniem imitacionnogo modelirovaniya*]. *Logistika i upravlenie cepjami postavok*,

2014, Iss. 5, pp. 48–56.

9. Modern problems of the transport complex in Russia [*Sovremennye problemy transportnogo kompleksa Rossii*]. Interuniversity collection of scientific works. Ed. by A. N. Rakhmangulov. Magnitogorsk, Publishing house of MSTU n.a. G. I. Nosov, 2011, 209 p.

10. Simulation modeling program for operation of a railway station with a probability-statistical approach to changing the parameters of the incoming car flow. Certificate of state registration of the computer program № 2014613827 / Registered in the register of computer programs on 08.04.2014. R. G. Korol, P. V. Danilenko [*Programma imitacionnogo modelirovaniya raboty priporotovy zheleznodorozhnoj stancii s veroyatnostno-statisticheskim pododom k izmeneniju parametrov postupajushhego vagonopotoka. Svidetel'stvo o gosudarstvennoj registratsii programmy dlja EVM № 2014613827 / Zaregistr. v reestre programm dlja EVM 08.04.2014. R. G. Korol, P. V. Danilenko*].

11. Electronic resource: <http://gdsu.stu.ru/science/>. Last accessed 22.08.2017.

12. Ryzhikov, Yu. I. Imitation modeling. Theory and technology [*Imitacionnoe modelirovanie. Teoriya i tehnologii*]. St. Petersburg, Korona-print; Moscow, Alteks-A, 2004, 384 p.

13. Technology of system modeling [*Tehnologija sistemnogo modelirovaniya*]. Ed. by S. V. Emelyanov. Moscow, Mashinostroenie publ., Berlin, Technic publ., 1988, 520 p.

14. Shannon, R. Simulation modeling of systems – art and science [*Imitacionnoe modelirovanie sistem – iskusstvo i nauka: Transl. from English*]. Moscow, Mir publ., 1978, 420 p.

15. Sterligova, A. N. Inventory Management in Supply Chains: A Textbook [*Upravlenie zapasami v cepjakh postavok: Uchebnik*]. Moscow, Infra-M publ., 2008, 430 p.

16. Gridin, V. N., Solodovnikov, V. I. Preprocessing of data and revealing of logical regularities on the basis of genetic algorithm [*Predobrabotka dannyh i vyjavenie logicheskikh zakonomernostej na osnove geneticheskogo algoritma*]. *Sistemy i sredstva informatiki*, 2013, Iss. 2, pp. 244–259.

17. Gridin, V. N., Solodovnikov, V. I., Karnakov, V. V. Choice of initial values and optimization of neural network parameters [*Vybor nachal'nykh znachenij i optimizacija parametrov nejronnoj seti*]. *Novye informacionnye tehnologii v avtomatizirovannykh sistemah*, 2016, Iss. 19, pp. 270–273.

18. Gridin, V. N., Solodovnikov, V. I., Karnakov, V. V. Use of the modular neural network BP-SOM for extracting rules [*Ispol'zovanie modul'noj nejronnoj seti BP-SOM dlja izvlechenija pravil*]. *Informacionnye tehnologii v proektirovanii i proizvodstve*, 2015, Iss. 4, pp. 3–7.

19. Evdokimov, I. A., Solodovnikov, V. I. Automation of neural network construction within object-oriented approach [*Avtomatizacija postroeniya nejronnoj seti v ramkah ob'ektno-orientirovannogo podhoda*]. *Novye informacionnye tehnologii v avtomatizirovannykh sistemah*, 2015, Iss. 18, pp. 89–97. ●

Information about the authors:

**Gridin, Vladimir N.** – D.Sc. (Eng), professor, head of Center for Information Technologies in Design of the Russian Academy of Sciences, Moscow, Russia, [info@ditc.ras.ru](mailto:info@ditc.ras.ru).

**Doenin, Viktor V.** – D.Sc. (Eng), professor of Russian University of Transport (MIIT), Moscow, Russia, [vidovas@mail.ru](mailto:vidovas@mail.ru).

**Panishchev, Vladimir S.** – Ph.D. (Eng), senior researcher of Center for Information Technologies in Design of the Russian Academy of Sciences, Moscow, Russia, +7(495) 596–02–19.

Article received 19.07.2017, accepted 31.08.2017.

The work was supported by the Russian Fundamental Research Foundation, project 17–20–01133 ofi\_m\_Russian Railways.

