

DOI: 10.15593/2499-9873/2021.2.05

УДК 656.13:004.89

А.К. Погодаев, Е.Л. Хабибуллина, Д.М. Инютин

Липецкий государственный технический университет,
Липецк, Россия

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ ПОСТРОЕНИЯ ПРОДУКЦИОННЫХ ПРАВИЛ ЭКСПЕРТНЫХ СИСТЕМ

Развитие урбанизации, стремительное увеличение жителей больших городов и как следствие – возросший темп жизни населения напрямую отразились на количестве транспортных средств. Именно поэтому интеллектуальные методы управления транспортными потоками, нацеленные на оптимизацию пропускной способности, набирают все большую популярность. Применение указанных методов позволяет с высокой эффективностью использовать уже имеющиеся дороги и автостразы без необходимости построения дополнительных полос, развязок, кольцевых дорог и так далее, что, в частности, постулируется стратегией Национальной технологической инициативы Российской Федерации.

Целью данного исследования является построение алгоритма, суть которого заключается в формировании продукционных правил для управления транспортным потоком путем направленного воздействия на его параметры. Таким образом, эксперты могут оценивать влияние определенных характеристик на те, которыми можно управлять.

Построение алгоритма происходит с помощью формирования нейросетевых моделей с последующим использованием метода нахождения наибольшего значения весовых коэффициентов и алгоритма Гарсона. Поскольку использование алгоритма подразумевает оценку экспертной группы, он должен обладать логическим (словесным) выводом правил, например, в следующем виде: «ЕСЛИ уклон – минимальный, ширина дорожного полотна – максимальная, ..., ТО процент тяжелых транспортных средств – минимальный». Данное преобразование осуществляется посредством использования функции принадлежности, которая позволяет полностью описать степень принадлежности определенного параметра к определенному нечеткому подмножеству. В задачах управления транспортными потоками рекомендуется использовать функцию принадлежности треугольной формы.

Исследование содержит результаты вычислительных экспериментов по определению оптимального разбиения входных параметров на нечеткие значения для построения корректных, удовлетворяющих реальным условиям правил.

При построении алгоритма особое внимание необходимо уделить оценке качества нейросетевой модели, так как она является основным механизмом. Для этого используются такие методы оценки, как среднеквадратическая ошибка (RMSE) и логистическая функция ошибки (LogLoss).

В качестве исходного набора данных для численного исследования были использованы данные, полученные от петлевых и радарных детекторов, которые описывают пропускную способность в зонах долгосрочной работы на участках транспортных коридоров. Для определения наиболее значимых параметров транспортного потока используется анализ чувствительности, основанный на применении формулы конечных приращений.

Ключевые слова: математическое моделирование, нейронные сети, продукционные правила, нечеткая логика, экспертные системы, моделирование транспортных систем, пропускная способность, извлечение продукционных правил, функция принадлежности, анализ чувствительности.

A.K. Pogodaev, E.L. Khabibullina, D.M. Inyutin

Lipetsk State Technical University, Lipetsk, Russian Federation

APPLYING NEURAL NETWORK MODELS TO THE CONSTRUCTION OF PRODUCTION RULES EXPERT SYSTEMS

The development of urbanization, the dramatic increase in the population of large cities and, as a consequence, the increased tempo of life, have had a direct impact on the number of vehicles. That is why intelligent methods of traffic flow control to optimize traffic capacity are growing in popularity. The application of these methods makes it possible to use existing roads and highways with high efficiency without the need to build additional lanes, interchanges, ring roads and so on, which in particular is postulated by the strategy of the National Technological Initiative of the Russian Federation.

The purpose of this study is to develop an algorithm, the idea of which is to form productive rules for the traffic flow control by directing the impact on its parameters. In this way, experts can assess the impact of certain characteristics on those that can be manipulated.

The construction of the algorithm is done by forming neural network models followed by using the method of the most dominant rule and Garson's algorithm. Since the use of the algorithm involves expert group evaluation, it must have a logical (verbal) rule output in the following form, e.g: "if the slope is minimum, the width of the roadway is maximum, ... then the percentage of heavy vehicles is minimum". This transformation is carried out through the use of the membership function, which allows to fully describe the degree to which a certain parameter belongs to a certain fuzzy subset. In the problems of traffic flow control, it is recommended to use a triangular-shaped membership function.

The study contains the results of computational experiments to determine the optimal partitioning of input parameters into fuzzy values to generate satisfying real-world conditions rules.

When constructing the algorithm, special attention should be paid to assessing the quality of the neural network model. For this purpose such methods of estimation as root mean square error (RMSE) and logistic error function (LogLoss) are used.

Data from loop and radar detectors describing the capacity in long-term operating areas on sections of transportation corridors were used as the initial data set for the numerical study. Sensitivity analysis based on the application of the finite increment formula was used to determine the most significant traffic flow parameters.

Keywords: mathematical modeling, neural networks, production rules, fuzzy logic, expert systems, transportation systems modeling, high-speed transportation corridor capacity, production rules extraction, membership function, sensitivity analysis.

Введение

Актуальность управления транспортным потоком обусловлена стремительным развитием и внедрением решений для систем мониторинга транспорта, in-door навигаций, телематических, мультисервисных и шеринговых платформ. Все больше компаний разрабатывают для автомобилей технологии, посредством которых машины будут «общаться» друг с другом и использовать данные от объектов дорожной инфраструктуры в реальном времени.

Задачи, связанные с нахождением оптимальных методов управления транспортными потоками, поиском эффективного расположения дорожно-транспортной сети и организацией движения транспортных средств, требуют учета множества различных факторов и характеристик, влияющих на них, в том числе и динамических показателей смешанных транспортных средств (легковые автомобили, тяжелые транспортные средства и т.д.).

Для определения наиболее значимых параметров транспортного потока используется анализ чувствительности, основанный на применении формулы конечных приращений (на теореме Лагранжа о промежуточной точке) [1]. Помимо анализа чувствительности выбор выходных параметров должен быть обусловлен возможностью управлять этими параметрами в реальном времени [1–4].

Необходимо также учитывать, что формулировка понятных правил, полученных на основе анализа данных, – это не то же самое, что создание прогностических моделей данных. Многие методы анализа данных, разработанные с помощью нейронных сетей, направлены в основном на построение моделей данных для предсказаний или адаптацию внутренних параметров этих моделей для учета известных (обучающих) образцов данных и позволяют делать прогнозы на неизвестных (тестовых) образцах данных. Таким образом, помимо разработки самой нейросетевой модели необходимо применение различных алгоритмов, позволяющих, оперируя выходом нейросети, формировать корректные правила.

1. Общий вид продукционных правил и обзор существующих методов их формирования

Большая часть известных нейросетевых алгоритмов оперирует числовыми, сложными для восприятия человеком характеристиками. Это обусловлено тем, что нейронная сеть является математической моделью, которая имеет структуру «черного ящика». Однако, используя нечеткую логику, можно преобразовать численные характеристики в нечеткие значения (лингвистические переменные). Ведь рассуждения, основанные на логических (словесных) правилах, более приемлемы для обычных людей, чем рекомендации, выдаваемые системами, основанными на нейронной сети, поскольку такие рассуждения понятны, содержат объяснения и могут быть подтверждены человеческим кон-

тролем. Это также повышает доверие к системе и может помочь обнаружить важные взаимосвязи и комбинации характеристик, если выразительная сила правил достаточна для этого.

Машинное обучение зародилось как подобласть искусственного интеллекта, которая ставит своей явной целью формулирование символических индуктивных методов (т.е. методов, которые учатся на примерах). Эти методы должны были обнаруживать правила, которые могут быть выражены на естественном языке и аналогичны создаваемым человеком-экспертом. Поскольку достижение такого понимания не всегда осуществимо, машинное обучение в последние годы расширилось и включает в себя все методы, которые обучаются на основе данных.

Стандартные четкие пропозициональные правила «ЕСЛИ ... ТО» являются наиболее простым и понятным способом выражения знаний, поэтому они рассматриваются в первую очередь. Хотя форма пропозициональных правил может быть различной, они всегда разбивают все пространство признаков X на некоторые подпространства. Общая форма четкого правила такова:

$$\text{ЕСЛИ } \mathbf{X} \in X^{(i)} \text{ ТО } \text{Class}(\mathbf{X}) = C_k .$$

Если \mathbf{X} принадлежит подпространству $X^{(i)}$, то ему должна быть присвоена метка класса C_k . Нечеткая версия этого правила представляет собой отображение из пространства X в пространство нечетких меток классов. Однако без определенных ограничений на форму границ принятия решений такие правила могут быть сложными для понимания.

Существуют различные способы построения таких правил. К основным из них можно отнести: использование деревьев решений, формирование правил с помощью индуктивных подходов и построение нейронных сетей [5].

Деревья решений являются важным инструментом в интеллектуальном анализе данных. Они быстры и просты в использовании, хотя иерархические правила, которые они генерируют, имеют несколько ограниченную мощность. Большинство деревьев используют нисходящий алгоритм, выполняющий эвристический поиск по восхождению от общего к специфическому, для наилучшего разбиения пространства признаков на области, содержащие векторы одного класса. Эвристиче-

ские методы обычно основаны на информационно-теоретических мерах. Несмотря на «жадные» алгоритмы поиска с восхождением на холм, которые могут создавать неоптимальные структуры деревьев, во многих случаях правила, генерируемые деревьями решений, являются простыми и точными.

Известны подходы к индуктивному обучению, которые также называются алгоритмами «концептуального обучения». Многие из этих алгоритмов работают только с символьными входными данными, поэтому непрерывные характеристики должны быть сначала дискретизированы. Для примера можно рассмотреть концепцию покрывающих алгоритмов. В этой концепции правила отнесения случаев к классу строятся начиная с «затравочного» примера, выбранного для каждого класса. Создается набор наиболее общих правил, которые охватывают этот и другие примеры, принадлежащие тому же классу (подходы типа звезда). К этим правилам применяется оценочная функция, включающая несколько критериев (основанная на точности правила – количество правильно классифицированных примеров, деленное на общее количество охваченных примеров), после чего выбирается лучшее правило. Примеры, покрытые этим правилом, удаляются из обучающего множества, и процесс повторяется. Разновидности включают алгоритмы, которые устойчивы к шумам, основаны на инкрементальном обучении, используют множество операторов конструктивной индукции для создания новых признаков, используют эволюционные алгоритмы для отбора признаков, основаны на гипотезах и имеют только частичную память о представленных примерах (для онлайн-обучения).

Нейронные сети обычно рассматриваются как структуры типа черный ящик, выполняющие таинственные функции и представляющие данные непонятным образом. Вопреки этому мнению, их можно использовать для получения простых и точных наборов логических правил. Следует рассмотреть два вопроса: понимание того, что на самом деле делают нейронные сети, и использование нейронных сетей для извлечения логических правил, описывающих данные. Хотя функцию, реализуемую типичной нейронной сетью, трудно понять, она может быть упрощена и аппроксимирована логическими правилами. Было разработано множество нейронных алгоритмов, которые извлекают логические правила непосредственно из данных [6–11]. Сравнений с

другими методами очень мало, а результаты в виде явных логических правил публикуются редко.

По сравнению с машинным обучением и методами дерева решений, нейросетевые алгоритмы имеют важные преимущества, особенно когда входные данные являются непрерывными. В таких случаях хорошие лингвистические переменные могут быть определены одновременно с логическими правилами, а отбор и объединение признаков в меньшее количество полезных признаков может быть включено в нейронную модель. Кроме того, встроены механизмы адаптации к постоянно меняющимся данным, а классификация с широким диапазоном, обеспечиваемая нейронными сетями, приводит к созданию более надежных логических правил.

Нейронные алгоритмы извлечения правил можно сравнивать по шести аспектам: а) «выразительная сила» извлеченных правил (типы извлеченных правил); б) «качество» извлеченных правил (точность, верность по сравнению с базовой сетью, понятность и согласованность правил); в) «прозрачность» метода, основанная на локальном и глобальном использовании нейронной сети (анализ отдельных узлов против анализа общей функции сети); г) алгоритмическая сложность метода; д) специализированные схемы обучения сети; е) обработка лингвистических переменных: некоторые методы работают только с двоичными переменными, другие – с дискретизированными входами, третьи – с непрерывными переменными, которые автоматически преобразуются в лингвистические переменные.

2. Формирование нейросетевой модели для построения продукционных правил

Анализ чувствительности нейросетевой модели, описывающей зависимость изменения стохастической пропускной способности секции транспортного коридора от определенных факторов, предварял построение продукционных правил. С учетом полученных результатов [1] и возможности управления в реальном времени в качестве входных аргументов (условной части правил) были выбраны следующие параметры, которые характеризуют текущее и прогнозируемое состояния транспортного коридора: прогнозируемая пропускная способность, средняя скорость движения транспортных средств по полосам движения, расположение высокоскоростного транспортного коридора (в черте или вне населенного пункта), уклон магистрали, процент больше-

грузных транспортных средств в транспортном коридоре, количество полос движения в одном направлении, ширина полосы движения, наличие полосы для разгона, скоростное ограничение.

Выходными аргументами (заключением правил) используемой модели были выбраны следующие параметры транспортного потока: процент тяжелых транспортных средств (может регулироваться установленными правилами допуска транспортных средств в коридор), количество полос для движения (может регулироваться использованием реверсивных полос и твердых обочин) и скоростные ограничения на определенных участках автострады (могут регулироваться с помощью адаптивных информационных табло).

Для получения словесных продукционных правил необходимо оперировать нечеткими значениями. Процесс преобразования исходных данных в нечеткие множества называется фаззификацией. Фаззификация – это установка соответствия между численным значением входной переменной системы нечеткого вывода и значением функции принадлежности соответствующего ей значения лингвистической переменной. Функции принадлежности могут быть разделены на два основных типа (рис. 1): линейные и нелинейные. К линейным относят кусочно-линейные, треугольные и трапецеидальные функции принадлежности. К нелинейным, в свою очередь, относятся полиномиальные, сигмоидальные и гауссовские функции [12–14].

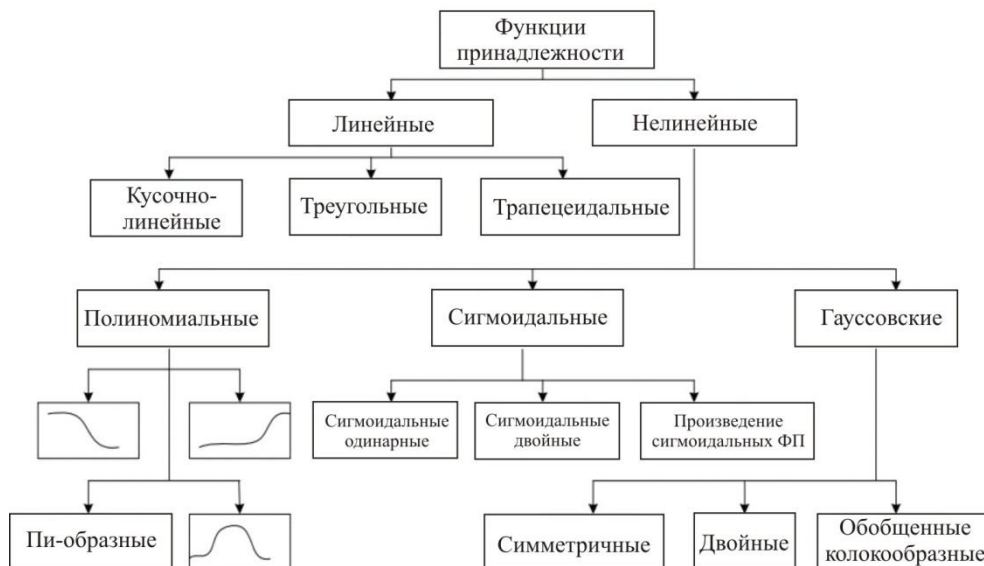


Рис. 1. Классификация функций принадлежности

Кусочно-линейные функции, как видно из названия, состоят из отрезков прямых линий, с помощью которых образуется непрерывная функция. К самым часто используемым линейным функциям относят треугольную и трапецеидальную функции. В данной работе используется функция принадлежности треугольной формы, которая задается следующим образом:

$$f(x, a, b, c) = \begin{cases} 1 - \frac{b-x}{b-a}, & a \leq x \leq b, \\ 0, & x \notin (a; c), \\ 1 - \frac{x-b}{c-b}, & b \leq x \leq c, \end{cases}$$

где a, b, c – некоторые числовые параметры, принимающие произвольные действительные значения и упорядоченные отношением $a \leq b \leq c$.

Несмотря на большое разнообразие видов нейронных сетей, все они имеют однотипную структуру, так как основаны на множестве похожих и связанных между собой элементов – нейронах. Модель нейрона включает в себя несколько входных сигналов и один выход. Каждому входному сигналу ставится в соответствие определенный весовой коэффициент, описывающий степень влияния на выходной сигнал. Сам же нейрон, оперируя входами, производит взвешенное суммирование в сумматоре, который имеет следующую структуру:

$$x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i.$$

После этого выходное значение передается в качестве аргумента в функцию активации.

Существует также нейрон смещения, предназначенный для сдвига значения функции активации с целью получения выходного сигнала. К особенностям данного нейрона можно отнести отсутствие входных сигналов и то, что они либо присутствуют по одному на каждом слое, либо вовсе отсутствуют.

В проведенном исследовании нейросетевая модель содержит один скрытый слой и построена с помощью функции активации *гиперболический тангенс*:

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1}.$$

Сам по себе тангенс имеет схожие черты с сигмойдой, однако имеет несколько ключевых отличий: обладает центром в нуле и преобразует данные в диапазон $[-1; 1]$.

Таким образом, общая форма используемой нейросетевой модели выглядит следующим образом:

$$\mathbf{y} = \Phi^{(k)}(w_0^{(k)} + \mathbf{W}_1^{(k)} \Phi^{(k-1)}(\dots(w_0^{(2)} + \mathbf{W}_1^{(2)} \Phi^{(1)}(w_0^{(1)} + \mathbf{W}_1^{(1)} \mathbf{x})\dots)),$$

где \mathbf{y} – вектор выходов; \mathbf{x} – вектор входов; $\Phi^{(i)}$ – вектор функций активаций от вектора аргументов, $i = 1, \dots, k$; $\mathbf{W}_1^{(i)}$ – матрица весовых коэффициентов; $w_0^{(i)}$ – весовые коэффициенты нейронов смещения, $i = 1, \dots, k$.

Формирование продукционных правил осуществляется с помощью двух различных методов на основе весов, полученных в результате анализа нейросетевой модели.

Первый метод сводится к выбору наиболее доминирующего правила для каждого нейрона выходного слоя (количество продукционных правил соответствует количеству нейронов выходного слоя). Чтобы сформировать правило, сначала выбирают нейрон скрытого слоя для каждого нейрона выходного слоя следующим образом:

$$h_s = \max_s(h_k v_{ks}),$$

где h_k – нейроны скрытого слоя; v_{ks} – веса «скрытый слой / выходной слой».

Затем для каждого выбранного нейрона скрытого слоя определяют комбинацию нейронов входного слоя:

$$x_j = \max_s(x_j w_{jc} - b_c),$$

где x_j – нейроны входного слоя; w_{jc} – веса «входной слой / скрытый слой»; b_c – вес нейрона смещения [3, 15].

Второй метод основан на применении алгоритма Гарсона, суть которого заключается в разбиении выходных весовых коэффициентов

скрытого слоя на компоненты, связанные с каждым входным нейроном, с использованием абсолютных значений весовых коэффициентов.

Для трехслойной нейронной сети с классической структурой алгоритм Гарсона выглядит следующим образом:

$$S_k(i) = \frac{\sum_{j=1}^n (w_{ij} v_{jk} / \sum_{i=1}^n w_{ij})}{\sum_{i=1}^n (\sum_{j=1}^n (w_{ij} v_{jk} / \sum_{i=1}^n w_{ij}))},$$

где i, j и k – индексы весов для нейронов входного, скрытого и выходного слоев соответственно; w_{ij} – веса «входной слой / скрытый слой»; v_{jk} – веса «скрытый слой / выходной слой» [2].

Полученные правила подвергаются экспертной оценке с целью выявления схожих по смыслу правил и выполнения их семантического контроля. Ниже приведен пример сформированного правила.

ЕСЛИ «уклон магистрали» = «ВЫСОКИЙ» И «ширина полосы движения» = «СРЕДНЯЯ» И «число полос» = «НИЗКОЕ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «средняя скорость движения транспортных средств по полосам движения» = «ВЫСОКАЯ», ТО «процент тяжелых транспортных средств в транспортном коридоре» = «ВЫСОКИЙ».

3. Реализация алгоритма и численные примеры

Для построения нейросетевой модели и рассмотренных алгоритмов был написан скрипт на языке программирования R с использованием библиотек `neuralnet` и `NeuralNetTools`. Структура нейросетевой модели, которую рекомендуется использовать для решения поставленной задачи, представлена на рис. 2.

С учетом специфики экспериментальных данных для региона была проведена декомпозиция структуры нейросетевой модели на три отдельные модели: для формирования правил с параметрами «процент тяжелых транспортных средств в транспортном коридоре», «количество полос», «скоростные ограничения» в заключении правила. На рис. 3 представлен пример структуры нейронной сети с параметром «процент тяжелых транспортных средств» в заключении правила.

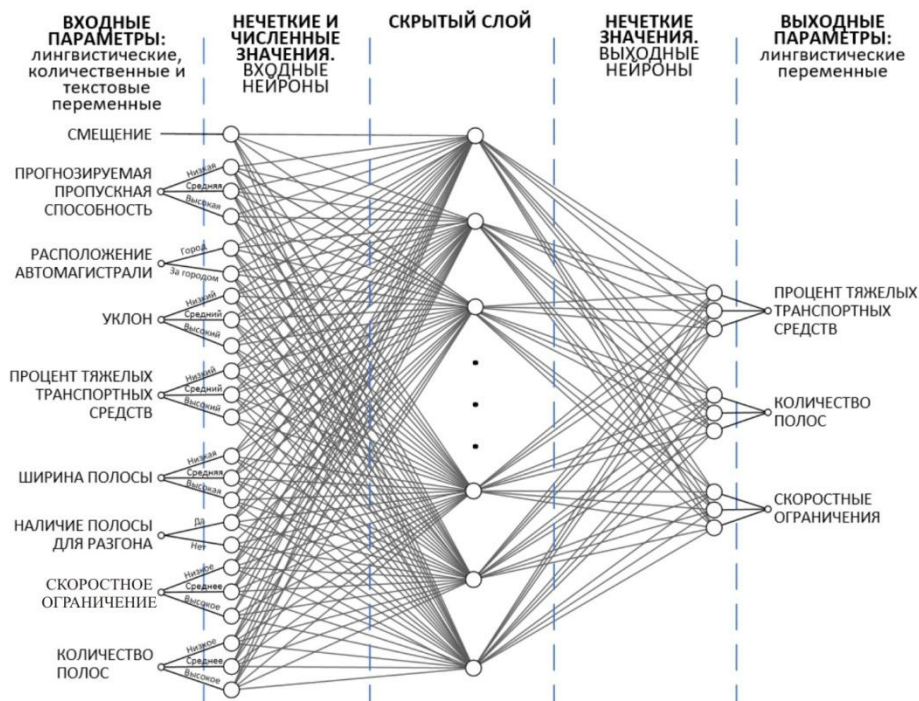


Рис. 2. Исходная структура нейросети




Рис. 3. Структура нейросети с выходным параметром «процент тяжелых транспортных средств»

Оценка качества нейросетевой модели проводилась с помощью среднеквадратической ошибки (RMSE) и логистической функции

ошибки (LogLoss). По проведенным экспериментам, среднеквадратическая ошибка в среднем составила: [0,1; 0,14] для параметра «процент тяжелых транспортных средств»; [0,05; 0,1] для параметра «скоростные ограничения» и [0,12; 0,18] для параметра «количество полос для движения». Данная оценка показывает разницу фактических и полученных значений; чем ближе значение этой оценки к нулю, тем лучше качество модели. Логистическая функция ошибки показала следующий результат: [18,1; 20,3] для параметра «процент тяжелых транспортных средств»; [25,1; 30,3] для параметра «скоростные ограничения» и [28,7; 32,4] для параметра «количество полос для движения». Оценка логистической ошибки показывает вероятность определения параметра с одним нечетким значением к другому нечеткому значению, например значение параметра «процент тяжелых транспортных средств» соответствует значению «НИЗКИЙ»; вероятность того, что нейросетевая модель определит данный параметр к значению «СРЕДНИЙ», равна 19,3. Следовательно, чем ниже значение этой вероятности, тем лучше полученная модель. Таким образом, можно прийти к выводу, что рассматриваемая нейросетевая модель имеет достаточную для решаемой задачи точность.

На следующем этапе с помощью метода нахождения наиболее доминирующего правила и алгоритма Гарсона формируются продукционные правила. Ниже представлены примеры сформированных правил:

ЕСЛИ «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «уклон магистрали» = «НИЗКИЙ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «число полос» = «ВЫШЕ СРЕДНЕГО» И «наличие полосы для разгона» = «НЕТ» И «максимальная разрешенная скорость» = «ВЫСОКАЯ» И «ширина полосы движения» = «БОЛЬШАЯ», ТО «процент большегрузных транспортных средств в транспортном коридоре» = «ВЫСОКИЙ»;

ЕСЛИ «прогнозируемая пропускная способность» = «НИЗКАЯ» И «уклон магистрали» = «НИЗКИЙ» И «расположение высокоскоростного транспортного коридора» = «ЗА ГОРОДОМ» И «число полос» = «НИЗКОЕ» И «наличие полосы для разгона» = «ДА» И «максимальная разрешенная скорость» = «НИЗКАЯ» И «ширина полосы движения» = «НИЗКАЯ», ТО «процент большегрузных транспортных средств в транспортном коридоре» = «НИЗКИЙ»;

ЕСЛИ «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «уклон магистрали» = «СРЕДНИЙ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «число полос» = «НИЗКОЕ» И «наличие полосы для разгона» = «НЕТ» И «максимальная разрешенная скорость» = «ВЫСОКАЯ» И «ширина полосы движения» = «СРЕДНЯЯ», ТО «процент большегрузных транспортных средств в транспортном коридоре» = «ВЫСОКИЙ»;

ЕСЛИ «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «уклон магистрали» = «СРЕДНИЙ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «число полос» = «ВЫСОКОЕ» И «наличие полосы для разгона» = «ДА» И «процент большегрузных транспортных средств в транспортном коридоре» = «НИЗКИЙ» И «ширина полосы движения» = «ВЫСОКАЯ», ТО «максимальная разрешенная скорость» = «ВЫСОКАЯ»;

ЕСЛИ «прогнозируемая пропускная способность» = «НИЗКАЯ» И «уклон магистрали» = «ВЫСОКИЙ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «число полос» = «НИЖЕ СРЕДНЕГО» И «наличие полосы для разгона» = «ДА» И «процент большегрузных транспортных средств в транспортном коридоре» = «СРЕДНИЙ» И «ширина полосы движения» = «НИЗКАЯ», ТО «максимальная разрешенная скорость» = «НИЗКАЯ»;

ЕСЛИ «прогнозируемая пропускная способность» = «СРЕДНЯЯ» И «уклон магистрали» = «СРЕДНИЙ» И «расположение высокоскоростного транспортного коридора» = «ГОРОД» И «число полос» = «ВЫСОКОЕ» И «наличие полосы для разгона» = «ДА» И «процент большегрузных транспортных средств в транспортном коридоре» = «НИЗКИЙ» И «ширина полосы движения» = «ВЫСОКАЯ», ТО «максимальная разрешенная скорость» = «ВЫСОКАЯ»;

ЕСЛИ «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «уклон магистрали» = «СРЕДНИЙ» И «расположение высокоскоростного транспортного коридора» = «ЗА ГОРОДОМ» И «число полос» = «ВЫШЕ СРЕДНЕГО» И «наличие полосы для разгона» = «НЕТ» И «процент большегрузных транспортных средств в транспортном коридоре» = «НИЗКИЙ» И «ширина полосы движения» = «СРЕДНЯЯ», ТО «максимальная разрешенная скорость» = «ВЫСОКАЯ»;

ЕСЛИ «прогнозируемая пропускная способность» = «СРЕДНЯЯ» И «уклон магистрали» = «ВЫСОКИЙ» И «расположение высокоско-

ростного транспортного коридора» = «ЗА ГОРОДОМ» И «наличие полосы для разгона» = «ДА» И «максимальная разрешенная скорость» = «НИЗКАЯ» И «процент большегрузных транспортных средств в транспортном коридоре» = «НИЗКИЙ» И «ширина полосы движения» = «ВЫСОКАЯ», ТО «число полос» = «ВЫСОКОЕ»;

ЕСЛИ «прогнозируемая пропускная способность» = «ВЫСОКАЯ» И «уклон магистрали» = «НИЗКИЙ» И «расположение высокоскоростного транспортного коридора» = «ЗА ГОРОДОМ» И «наличие полосы для разгона» = «ДА» И «максимальная разрешенная скорость» = «ВЫСОКАЯ» И «процент большегрузных транспортных средств в транспортном коридоре» = «ВЫСОКИЙ» И «ширина полосы движения» = «ВЫСОКАЯ», ТО «число полос» = «ВЫСОКОЕ»;

ЕСЛИ «прогнозируемая пропускная способность» = «СРЕДНЯЯ» И «уклон магистрали» = «ВЫСОКИЙ» И «расположение высокоскоростного транспортного коридора» = «ЗА ГОРОДОМ» И «наличие полосы для разгона» = «НЕТ» И «максимальная разрешенная скорость» = «ВЫСОКАЯ» И «процент большегрузных транспортных средств в транспортном коридоре» = «ВЫСОКИЙ» И «ширина полосы движения» = «СРЕДНЯЯ», ТО «число полос» = «ВЫСОКОЕ».

regulation
если: Capacity=max Grade=min Location=urban NumLanes=Abomeans Reduced=no SpeedLimit=max Width=max to: Trucks=max
если: Capacity=min Grade=min Location=rural NumLanes=Abomeans Reduced=no SpeedLimit=min Width=min to: Trucks=means
если: Capacity=max Grade=min Location=urban NumLanes=min Reduced=no SpeedLimit=min Width=max to: Trucks=min
если: Capacity=min Grade=max Location=urban NumLanes=Abomeans Reduced=yes SpeedLimit=min Width=means to: Trucks=max
если: Capacity=means Grade=means Location=urban NumLanes=Abomeans Reduced=no SpeedLimit=min Width=means to: Trucks=max
если: Capacity=means Grade=min Location=urban NumLanes=min Reduced=yes SpeedLimit=max Width=max to: Trucks=max
если: Capacity=max Grade=means Location=urban NumLanes=min Reduced=no SpeedLimit=max Width=means to: Trucks=max
если: Capacity=max Grade=min Location=urban NumLanes=Abomeans Reduced=yes SpeedLimit=min Width=max to: Trucks=max
если: Capacity=means Grade=means Location=urban NumLanes=max Reduced=no SpeedLimit=max Width=max to: Trucks=max
если: Capacity=max Grade=means Location=rural NumLanes=Abomeans Reduced=no SpeedLimit=min Width=means to: Trucks=max
если: Capacity=max Grade=min Location=urban NumLanes=min Reduced=yes SpeedLimit=max Width=min to: Trucks=max
если: Capacity=max Grade=min Location=urban NumLanes=Abomeans Reduced=yes SpeedLimit=min Width=max to: Trucks=max
если: Capacity=means Grade=means Location=urban NumLanes=max Reduced=no SpeedLimit=max Width=max to: Trucks=max
если: Capacity=max Grade=means Location=urban NumLanes=max Reduced=no SpeedLimit=max Width=max to: Trucks=max
если: Capacity=min Grade=min Location=urban NumLanes=Belmeans Reduced=yes SpeedLimit=max Width=min to: Trucks=means
если: Capacity=min Grade=min Location=rural NumLanes=min Reduced=no SpeedLimit=min Width=min to: Trucks=means

Рис. 4. Пример выходной формы с полученными правилами

Была также проведена экспертная оценка, которая показала непротиворечивость полученных правил. Для автоматизированной генерации правил было разработано проблемно-ориентированное про-

граммное обеспечение, пример интерфейса и результатов работы которого представлены на рис. 4 и 5.

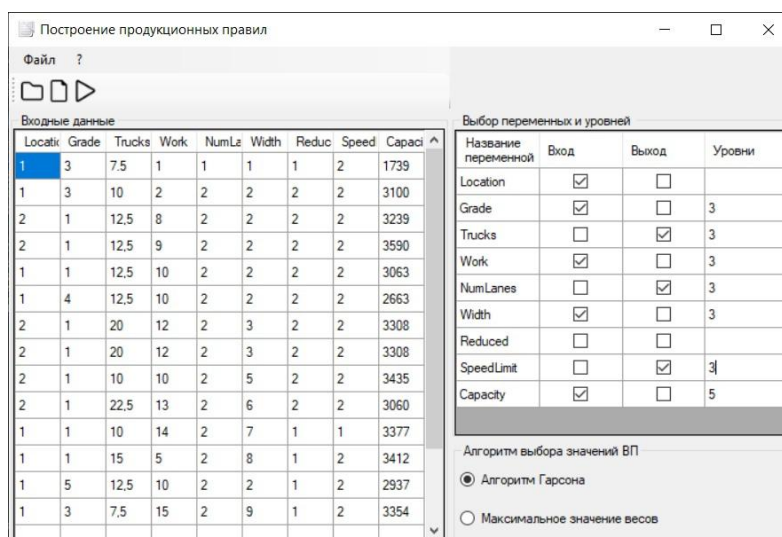


Рис. 5. Основное окно программного обеспечения

Заключение

В работе представлен алгоритм для формирования производственных правил экспертных систем, построенный на основе нейронечеткой структуры. Особое внимание уделено оценке качества используемой нейросетевой модели. Для выбора выходных параметров модели проведен анализ чувствительности, описывающей зависимость изменения стохастической пропускной способности секции транспортного коридора от определенных факторов с последующим учетом возможности управления в реальном времени. К особенностям данного способа можно отнести использование нечеткой логики, что, в свою очередь, позволяет экспертам легко оценить полученные правила и осуществить их семантический контроль.

В дальнейшем построенную базу производственных правил планируется использовать в экспертной системе управления транспортными потоками. Концептуальная схема экспертной системы управления транспортными потоками представлена на рис. 6.

По информации, получаемой из разнородных источников, в подсистеме сбора и агрегирования информации вычисляются значения па-

раметров системы и накапливаются в базе данных с учетом меток времени и GPS-координат. В подсистеме прогнозирования определяется прогнозируемое значение пропускной способности с использованием нейросетевой модели. Данные, поступающие из базы данных в виде количественного значения и соответствующие лингвистическим переменным, переводятся в нечеткие значения в подсистеме «Фаззификатор». Затем в подсистеме логического вывода осуществляется определение значений изменяемых параметров: процент тяжелых транспортных средств, скоростные ограничения, число полос движения. В качестве механизма логического вывода используется алгоритм Мамдани. В подсистеме «Дефаззификатор» осуществляется перевод нечетких значений в точные значения для лингвистических переменных. Подсистема передачи рекомендаций через беспроводные интерфейсы и сеть Интернет осуществляет передачу рекомендаций на устройства участников дорожного движения и объекты дорожной инфраструктуры.

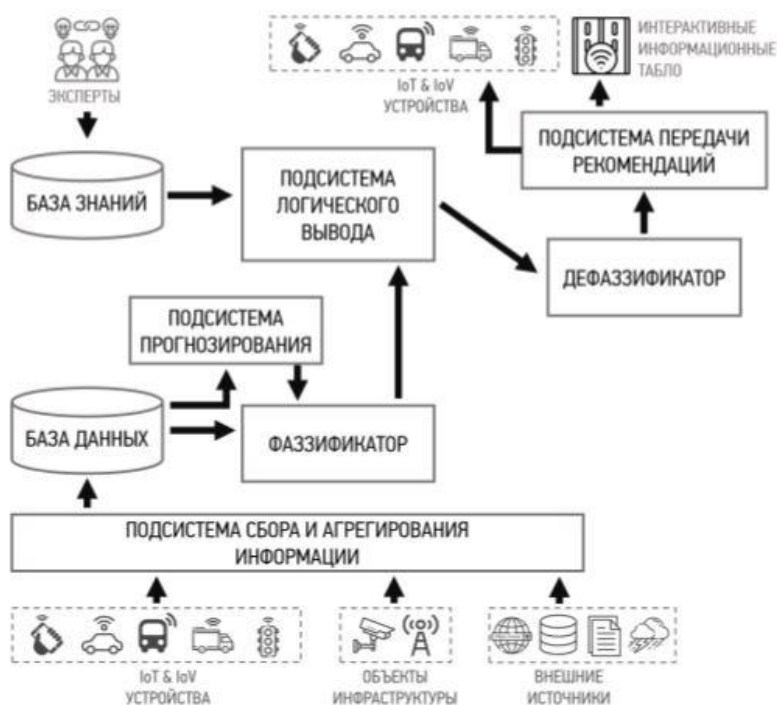


Рис. 6. Концептуальная схема экспертной системы управления транспортными потоками

Благодарность

Исследование выполнено за счет гранта Российского научного фонда (проект № 18-71-10034).

Список литературы

1. Sysoev A.S., Blyumin S.L., Scheglevatykh R.V. Approach to sensitivity analysis of neural network models based on analysis of Finite Fluctuations // Proceedings of the 14th International Conference on Pattern Recognition and Information Processing (PRIP'2019), Minsk, Belarus, 21–23 May 2019. – Minsk, Belarus, 2019. – P. 97–100.

2. Sysoev A.S., Voronin N. Approach to sensitivity analysis of stochastic freeway capacity model based on applying analysis of finite fluctuations // 1st International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency SUMMA, 20–22 November, 2019, Lipetsk, Russia. – Lipetsk, 2019. – P. 621–626.

3. Хабибуллина Е.Л., Погодаев А.К. Нейро-нечеткие алгоритмы экспертной системы в задаче управления транспортными потоками // Гибридные и синергетические интеллектуальные системы : материалы V Всероссийской Поспеловской конференции с международным участием, г. Зеленоградск 18–20 мая 2020 г. / Балтийский федеральный университет имени Иммануила Канта. – Зеленоградск, 2020. – С. 384–392.

4. Sysoev A.S., Khabibullina E.L. Functional model of expert traffic flow control system within high-speed transportation corridors // Journal of Physics: Conference Series. – IOP Publishing, 2020. – Vol. 1479, iss. 1. – P. 1114–1120.

5. Duch W., Setiono R., Zurada M.J. Computational intelligence methods for rule-based data understanding // Proceedings of the IEEE (P IEEE), June 2004 / Institute of Electrical and Electronics Engineers. – 2004. – P. 771–805. DOI: 10.1109/JPROC.2004.826605

6. Andrews R., Diederich J., Tickle A.B. A survey and critique of techniques for extracting rules from trained artificial neural networks // Knowledge-Based Systems. – 1995. – Vol. 8. – P. 373–389.

7. Duch W., Adamczak R., Grabczewski K. A new methodology of extraction, optimization and application of crisp and fuzzy logical rules // IEEE Transactions on Neural Networks. – 2001. – Vol. 12. – P. 277–306.

8. Lu H., Setiono R., Liu H. Effective data mining using neural networks // IEEE Trans. Knowledge and Data Engineering. – 1996. – Vol. 8. – P. 957–961.

9. Setiono R., Liu H. Symbolic representation of neural networks // IEEE Computer. – 1996. – Vol. 29. – P. 71–77.

10. Setiono R. Extracting M-of-N rules from trained neural networks // *IEEE Trans. Neural Networks*. – 2001. – Vol. 11. – P. 512–306.
11. Setiono R., Leow W.K. FERNN: an algorithm for fast extraction of rules from neural networks // *Applied Intelligence*. – 2000. – Vol. 12. – P. 15–25.
12. Хижняков Ю.Н. Алгоритмы нечеткого, нейронного и нейро-нечеткого управления в системах реального времени: учеб. пособие. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. – 160 с.
13. Григорьева Д.Р., Гареева Г.А., Басыров Р.Р. Основы нечеткой логики: учеб.-метод. пособие к практ. занятиям и лаб. работам. – Набережные Челны: Изд-во НЧИ КФУ, 2018. – 42 с.
14. Введение в математическое моделирование транспортных потоков: учеб. пособие / А.В. Гасников [и др.]; МЦНМО. – 2-е изд., испр. и доп. – М., 2013. – 215 с.
15. Sysoev A., Khabibullina E. Forming production rules in intelligent transportation system to control traffic flow // *Open Semantic Technology for Intelligent Systems*. – 2020. – Iss. 4. – P. 317–322.

References

1. Sysoev A. S., Blyumin S. L., Scheglevatykh R. V. Approach to Sensitivity Analysis of Neural Network Models Based on Analysis of Finite Fluctuations. Proceedings of the 14th International Conference on Pattern Recognition and Information Processing (PRIP'2019), Minsk, Belarus, May, 21–23 2019, 2019, pp. 97-100.
2. Sysoev A.S., Voronin N. Approach to Sensitivity Analysis of Stochastic Freeway Capacity Model Based on Applying Analysis of Finite Fluctuations. 1st International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency SUMMA, November, 20-22, 2019, Lipetsk, Russia, 2019, pp. 621-626.
3. Khabibullina E.L., Pogodaev A.K. Neuro-nechetkie algoritmy ekspertnoi sistemy v zadache upravleniia transportnymi potokami [Neuro-fuzzy algorithms of the expert system in the task of traffic control]. *Gibridnye i sinergeticheskie intellektual'nye sistemy, materialy V Vserossiiskoi Pospelovskoi konferentsii s mezhdunarodnym uchastiem* [Hybrid and Synergetic Intelligent Systems: Proceedings of the 5th All-Russian Pospelov Conference, Zelenogradsk, Kaliningrad region, May, 18–20 2020], Zelenogradsk, 2020, pp. 384-392.
4. Sysoev A.S., Khabibullina E.L. Functional model of expert traffic flow control system within high-speed transportation corridors. *Journal of Physics: Conference Series*, 2020, vol. 1479, iss. 1, pp. 1114-1120.
5. Duch W., Setiono R., Zurada M.J. Computational intelligence methods for rule-based data understanding. *Proceedings of the IEEE (P IEEE)*, June 2004. Pub-

lisher: Institute of Electrical and Electronics Engineers, 2004, pp. 771-805. DOI: 10.1109/JPROC.2004.826605

6. Andrews R., Diederich J., Tickle A.B. A Survey and Critique of Techniques for Extracting Rules from Trained Artificial Neural Networks. Knowledge-Based Systems, 1995, vol. 8, pp. 373–389.

7. Duch W., Adamczak R. and Grabczewski K. A New Methodology of Extraction, Optimization and Application of Crisp and Fuzzy Logical Rules. IEEE Transactions on Neural Networks, 2001, vol. 12, pp. 277-306.

8. Lu H., Setiono R., Liu H. Effective Data Mining Using Neural Networks. IEEE Trans. Knowledge and Data Engineering, 1996, vol. 8, pp. 957– 961.

9. Setiono R., Liu H. Symbolic Representation of Neural Networks. IEEE Computer, 1996, vol. 29, pp. 71-77.

10. Setiono R. Extracting M-of-N Rules From Trained Neural Networks. IEEE Trans. Neural Networks, 2001, vol. 11, pp. 512-306.

11. Setiono R., Leow W.K. FERNN: An Algorithm for Fast Extraction of Rules from Neural Networks. Applied Intelligence, 2000, vol. 12, pp. 15–25.

12. Khizhnyakov Y.N. Algoritmy nechetkogo, neuronnogo i neuro-nechetkogo upravleniia v sistemakh real'nogo vremeni [Algorithms of fuzzy, neural and neuro-fuzzy control in real-time systems], Perm, 2013, 160 p.

13. Grigoryeva D.R., Gareeva G.A., Basyrov R.R. Fuzzy Logic Fundamentals: Methodological Manual for Practical Exercises and Laboratory Work Naberezhnye Chelny, 2018. 42 p.

14. Gasnikov A.V. Introduction to Mathematical Traffic Flows Modeling: Textbook – Moscow, 2013. 215 p.

15. Sysoev A., Khabibullina E. Forming Production Rules in Intelligent Transportation System to Control Traffic Flow. Open Semantic Technology for Intelligent Systems, 2020, iss. 4, pp. 317-322.

Статья получена: 22.03.2021

Статья принята: 11.05.2021

Сведения об авторах

Погодаев Анатолий Кириянович (Липецк, Россия) – доктор технических наук, первый проректор, профессор кафедры «Прикладная математика», Липецкий государственный технический университет (398055, Липецк, ул. Московская, 30, e-mail: pak@stu.lipetsk.ru).

Хабидулина Елена Леонидовна (Липецк, Россия) – старший преподаватель кафедры «Прикладная математика», Липецкий государственный

технический университет (398055, Липецк, ул. Московская, 30, e-mail: habibullina_el@stu.lipetsk.ru).

Инютин Дмитрий Михайлович (Липецк, Россия) – магистрант кафедры «Прикладная математика», Липецкий государственный технический университет (398055, Липецк, ул. Московская, 30, e-mail: worlddreg0515@yandex.ru).

About the authors

Anatoly K. Pogodaev (Lipetsk, Russian Federation) – Dr. Habil. in Engineering, First Vice-rector, Professor, Department of Applied Mathematics, Lipetsk State Technical University (30, Moskovskaya st., Lipetsk, 398055, e-mail: pak@stu.lipetsk.ru).

Elena L. Khabibullina (Lipetsk, Russian Federation) – Senior Lecturer, Department of Applied Mathematics, Lipetsk State Technical University (30, Moskovskaya st., Lipetsk, 398055, e-mail: habibullina_el@stu.lipetsk.ru).

Dmitriy M. Inyutin (Lipetsk, Russian Federation) – Master Student, Department of Applied Mathematics, Lipetsk State Technical University (30, Moskovskaya st., Lipetsk, 398055, e-mail: worlddreg0515@yandex.ru).

Библиографическое описание статьи согласно ГОСТ Р 7.0.100–2018:

Погодаев, А.К. Применение нейросетевых моделей для построения производственных правил экспертных систем / А.К. Погодаев, Е.Л. Хабибуллина, Д.М. Инютин. – текст : непосредственный. – DOI: 10.15593/2499-9873/2021.2.05 // Прикладная математика и вопросы управления = Applied Mathematics and Control Sciences. – 2021. – № 2. – С. 71–90.

Цитирование статьи в изданиях РИНЦ:

Погодаев А.К., Хабибуллина Е.Л., Инютин Д.М. Применение нейросетевых моделей для построения производственных правил экспертных систем // Прикладная математика и вопросы управления. – 2021. – № 2. – С. 71–90. DOI: 10.15593/2499-9873/2021.2.05

Цитирование статьи в references и международных изданиях

Cite this article as:

Pogodaev A.K., Khabibullina E.L., Inyutin D.M. Applying neural network models to the construction of production rules expert systems. *Applied Mathematics and Control Sciences*, 2021, no. 2, pp. 71–90. DOI: 10.15593/2499-9873/2021.2.05 (in Russian)