

Раздел III. Алгоритмы обработки информации

УДК 004.896

DOI 10.18522/2311-3103-2023-2-175-186

Х.С. Аламир, Е.В. Заргарян, Ю.А. Заргарян

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА КОНТРОЛЯ ЗАТОРОВ НА ДОРОГАХ С ИСПОЛЬЗОВАНИЕМ КОНТРОЛИРУЕМОГО АЛГОРИТМА МАШИННОГО ОБУЧЕНИЯ НА БАЗЕ АДАПТИВНОГО IOTN

Явление заторов на дорогах возникает, когда норма спроса на дороге или на транспортном объекте превышает имеющуюся пропускную способность, причем бывает двух видов: либо рутинная, т.е. возникает в определенные моменты времени, которые являются пиковыми, например, на дороге, идущих или возвращающихся с работы или учебных заведений людей; либо другой тип – внезапные появившиеся заторы, возникающие в результате дорожно-транспортного происшествия, то есть в случае аварии на дороге, либо в силу других форс-мажорных причин. В связи с этим для уменьшения нарастания заторов в городах, можно и необходимо в современных условиях жизни и развития технологий использовать концепцию умных систем. Она отличается множеством алгоритмов, используемых в мире машинного обучения (ML) и Интернета вещей (IoT) для более точного прогнозирования потока трафика в краткосрочной перспективе и выявления возможностей для предотвращения заторов. В современных городах могут использоваться множество различных датчиков для сбора информации для прогнозирования краткосрочного трафика на территории города и точного захвата пространственной и временной эволюции (изменения) транспортного потока. Алгоритмы, внедренные в машинное обучение, улучшают возможности разрабатываемой системы. Качество принимаемых решений разрабатываемого искусственного интеллекта увеличивается при одновременном увеличении объема собираемых данных. В этой статье предлагается модель системы TCC-SVM для анализа пробок на дорогах в среде умного города. Предлагаемая модель включает в себя систему управления трафиком Интернета вещей (IoT), которая сообщает о заторах в определенной точке. Существующие системы управления дорожным движением становятся неэффективными из-за увеличения количества транспортных средств на дорогах. В городских районах пробки и аварии являются серьезной проблемой. Интеллектуальная транспортная система необходима для решения проблем, вызванных заторами на дорогах.

Нейронные сети; прогноз городского трафика; машинное обучение; интернет вещей; интеллектуальные систем; метод опорных векторов (SVM).

H.S. Alamir, E.V. Zargaryan, Yu.A. Zargaryan

INTELLIGENT TRAFFIC CONGESTION CONTROL SYSTEM USING A CONTROLLED MACHINE LEARNING ALGORITHM ON ADAPTIVE IOTN

The phenomenon of congestion on the roads occurs when the demand rate on the road or on a transport facility exceeds the available capacity, and there are two types: either routine, i.e. occurs at certain times that are peak, for example, on the road, walking or returning from work or educational institutions of people; or another type – sudden traffic jams that have appeared as a result of a traffic accident, that is, in the event of an accident on the road, or due to other force majeure reasons. In this regard, in order to reduce the increase in congestion in cities, it is possible and necessary to use the concept of smart systems in modern conditions of life and technology development. It is distinguished by a variety of algorithms used in the world of machine learning

(ML) and the Internet of Things (IoT) to more accurately predict the flow of traffic in the short term and identify opportunities to prevent congestion. In modern cities, many different sensors can be used to collect information to predict short-term traffic in the city and accurately capture the spatial and temporal evolution (change) of traffic flow. Algorithms embedded in machine learning improve the capabilities of the system being developed. The quality of the decisions made by the developed artificial intelligence increases with a simultaneous increase in the volume of data collected. This article proposes a model of the TCC-SVM system for analyzing traffic jams in a smart city environment. The proposed model includes an Internet of Things (IoT) traffic management system that reports congestion at a certain point. Existing traffic management systems are becoming ineffective due to the increase in the number of vehicles on the roads. In urban areas, traffic jams and accidents are a serious problem. An intelligent transport system is necessary to solve the problems caused by congestion on the roads.

Neural networks; urban traffic forecast; machine learning; internet of things; intelligent systems; support vector machine (SVM).

Введение: В умных городах данные об уровнях заторов являются важным аспектом управления дорожным движением. Эти данные о трафике определяются рядом различных датчиков с использованием радаров, микроволн и т.д. Валид предложил методику расчета плотности трафика с использованием подхода метода опорных векторов (SVM) [1–3]. Различные изображения текущего трафика захватываются и затем отправляются в предлагаемую систему, которая также получает информацию о более медленных скоростях, более длительном времени в пути и увеличении очередей автомобилей, а затем вычисляет плотность трафика [4].

Пробки на дорогах являются проблематичным вопросом, это происходит, когда количество автомобилей на дорогах города поднимается выше пропускной способности этой дороги, также известной как «насыщение». Борьба с заторами, которая влияет на многие проблемы, с которыми сталкиваются граждане, является одной из основных проблем транспортной системы в умных городах [1]. Загрязнение воздуха, использование топлива, нарушения ПДД и шумовое загрязнение, а также многочисленные упущенные возможности и аварии – все это проблемы современного города, влияние которых необходимо оптимизировать для удобства проживания в данном городе. В большинстве современных систем светофоров тайминги зафиксированы на всех перекрестках и не могут быть скорректированы в соответствии с изменениями плотности движения. Поэтому это была одна из самых важных составляющих, которая заставляла транспортные средства большую часть времени ждать в очередях, чтобы количество транспортных средств не увеличивалось на других дорогах, и очевидно, что эта процедура приводит к потере большего количества времени в ожидании в потоке транспорта. Особое внимание необходимо уделить времени ожидания в транспортном потоке машин экстренных служб [2]. Из-за фиксированных таймингов сигналов светофоров интенсивное движение может быть сконцентрировано в одном направлении в определенное время, но это вызывает накладные расходы и тратит много времени [5].

Связь между различными устройствами происходит в основном с помощью датчиков, исполнительных механизмов и мобильных устройств; Выполнение запроса выполняется одним и тем же диапазоном устройств. В 2018 году количество умных устройств превзошло максимально предполагаемое [6] и продолжает расти. Электронные устройства, такие как беспроводные датчики, смартфоны и другие встроенные системы, подключенные к Интернету или локальной сети (LAN), которая использует термин Интернет вещей (IoT) изменили возможности исследования и корректировки, в частности транспортных потоков. В последнее время стало известно, что умных устройств становится все больше, а потому информация, собираемая этими устройствами, будет все более уверенно охватывать исследуемую зону. Исторически сложилось так, что первая проверка компьютерного интеллекта

произошла в пятидесятых годах прошлого века. Вычислительный интеллект - это то, что нас интересует, и мы широко занимаемся им в нашем исследовании, которое считается отраслью искусственного интеллекта (ИИ), с помощью которой можно увеличить случаи обучения для новых проблем, которые могут возникнуть во время работы, и цель состоит в том, чтобы исследовать более широкое видение и уточнить ожидаемые проблемы на всех уровнях.

А с развитием приложений на базе искусственного интеллекта, основной функцией которого и для которого он был разработан, является обработка и изучение собранных данных с целью принятия возможных решений, связанных со значимыми шаблонами в дополнение к различным вариантам, которые являются факторами, стимулирующими и использующими развитие в работе алгоритмов искусственного интеллекта и алгоритмов машинного обучения. Акцент будет сделан на изменении динамики времени светофора в соответствии с зависимостью, в основном, от плотности движения в городах, также можно учесть расчет некоторых факторов важного значения, которые могут быть причиной контроля заторов на дорогах или, наоборот, кучи факторов, снижающих заторы на дорогах. Чтобы сэкономить время и найти решения других, связанных с этим проблем, в этой статье сфокусируемся на использовании датчиков, как части концепции Интернета вещей с целью получения приемлемых результатов, которые эффективно способствуют процессу управления потоком информации, связанной с трафиком, за счет использования различных классификаторов, таких как Perceptron, Naive Bayes, Decision Tree, Logistic Regression и K-Nearest (персептрон, нативный Байес, дерево решений, логистическая регрессия и K-ближайший).

В этом исследовании SVM используется для поиска точки затора на дорожном перекрестке с использованием различных статистических показателей, таких как частота промахов точности, специфичность, чувствительность, ложноположительное значение, ложноотрицательное значение, положительное отношение вероятности, отрицательное отношение вероятности, положительное значение прогноза и отрицательное значение предиктива. С помощью этих матриц перегруженность может быть идентифицирована более точно по сравнению с изученными исследованиями.

Предлагаемая модель системы (TCC-SVM). На рис. 1 демонстрируется новая модель системы контроля заторов на дорогах (ТСС) с использованием SVM в ML [7] для интеллектуальной системы управления дорожным движением. С помощью этой модели можно предоставить полную картину модели системы TCC-SVM, которая предлагается в данной статье, в которой данные собираются и принимаются интеллектуальными устройствами с поддержкой IoT. С помощью этой модели данные сигналов одного узла передаются другому узлу и обновляются. Затем следующий слой, называемый сенсорным, получает данные от датчиков и облака, состоящих из входных параметров, которые используются для поиска точки скопления.

Модель была разделена на четыре разных слоя, в которых данные после получения их из облака и датчиков передаются в систему управления для обработки полученных результатов. Исходные данные вводились после передачи из облака и датчики распределялись в слои объекта, а после ввода исходных данных начинается следующий этап, на котором данные передаются на следующий слой, который является преслойной обработкой [8]. В этом слое данные улучшаются путем обработки найденных значений (недостающих значений), а после первого и второго этапов формируется следующий слой, в котором данные передаются на прикладной уровень. Прикладной слой, в свою очередь, разделен на два слоя, первый слой – это слой производительности, а другой слой – слой прогнозирования. На уровне

прогнозирования проводится работа над SVM для оптимальной оценки пробок на дорогах. Также на данном этапе работы производительность слоя оценивается по значениям, полученным в результате анализа слоя прогнозирования.




Рис. 1. Предлагаемая модель разрабатываемой системы (TCC_SVM)

При наличии RFID-датчиков водители смогут получать уведомления о точке заторов на дорогах [9], а высокоточное прогнозирование этих пробок может быть достигнуто с помощью предлагаемой модели системы TCC-SVM с использованием SVM, использование которой приходится на методы машинного обучения. Дороги претерпевают изменения, которые иногда могут привести к ухудшению состояния в результате плохих погодных условий, в связи с чем в основном это сказывается на объеме движения [10]. Неблагоприятная погода может быть комбинацией различных факторов, например дождя, влажности, температуры и т.д.

Исследование касается данных, которые были доступны и собраны через Интернет, которые состоят из потока данных о различных погодных условиях и трафике, и которые обновляются с интервалом в 10 минут в рамках работы системы. В табл. 1 объясняются основные переменные входа, а также выхода, чтобы предсказать заторы на дорогах в любом месте и времени. Знание и обнаружение каких-либо точек заторов в транспортном потоке в том или ином месте и в плохих погодных условиях является основной целью этого исследования.

Таблица 1

Входные/выходные переменные предлагаемой системы	
№	Имя входной/выходной переменной
Вход 1	Время
Вход 2	Скорость движения
Вход 3	Транспортный поток
Вход 4	Влажность
Вход 5	Скорость ветра
Вход 6	Температура воздуха
Выход 1	Вместимость

Как мы знаем, уравнение прямой равно

$$X_2 = ax_1 + b, \quad (1)$$

где a - наклон линии, b – пересечение; следовательно

$$ax_1 - x_2 + b = 0.$$

Пусть $\bar{X} = (X_1 - X_2)^T$ и $\bar{W} = (a - 1)$ тогда приведенное выше уравнение может быть записано как

$$\bar{W} \cdot \bar{X} + b = 0. \quad (2)$$

Это уравнение получено из 2-мерных векторов. Но на самом деле, он также работает для любого числа измерений, уравнение (2), также известное как уравнение гиперплоскости.

Направление вектора $\bar{X} = (X_1, X_2)^T$, написано, как $\bar{W}$ и определяется как

$$W = \frac{x_1}{\|X\|} + \frac{x_2}{\|X\|}, \quad (3)$$

где

$$\|X\| = \sqrt{X_1^2 + X_2^2 + X_3^2 \dots X_n^2}.$$

Как мы знаем, что

$$\cos(\theta) = \frac{x_1}{\|X\|} \text{ и } \cos(\alpha) = \frac{x_2}{\|X\|}.$$

Уравнение (3) также может быть записано как

$$\begin{aligned} W &= (\cos(\theta), \cos(\alpha)) \\ \bar{w} \cdot \bar{x} &= \|w\| \|x\| \cos(\theta) \\ \theta &= \beta - \alpha \\ \cos(\theta) &= \cos(\alpha) + \sin(\beta) \sin(\alpha) \\ &= \cos(\beta) \cos(\alpha) + \sin(\beta) \sin(\alpha) \\ &= \frac{w_1}{\|w\|} \frac{x_1}{\|x\|} + \frac{w_2}{\|w\|} \frac{x_2}{\|x\|} \\ \bar{w} \cdot \bar{x} &= \sum_{i=1}^n w_i x_i. \end{aligned} \quad (4)$$

Точно так же, как приведенное выше уравнение было рассчитано для размерных векторов, скалярное произведение может быть рассчитано

$$f = y(w \cdot x + b).$$

Затем F , который называется функциональным полем набора данных

$$f = \min_{i=1 \dots m} f_i.$$

В городских районах основными проблемами являются пробки и аварии. Интеллектуальная транспортная система необходима для решения проблем, вызванных пробками на дорогах. Один из объектов: выделенная сеть транспортных средств

(VANET), отслеживает заторы на дорогах, отображая статистику по номерам транспортных средств на экране мобильного устройства. Информация поступает с различных перекрестков, что позволяет участникам дорожного движения выбрать маршрут и объехать заторы на оживленной дороге. Поэтому необходимо разработать интеллектуальную систему обнаружения пробок на дорогах, а также распространить эти возможности в управляющих системах автомобилей, чтобы можно было перенаправить входящий трафик и уменьшить заторы без участия людей [11–13].

При сравнении гиперплоскостей будет дополнительно выбрана гиперплоскость с наибольшим F ; F – называется геометрическим полем набора данных. Для достижения нашей цели по поиску оптимальной гиперплоскости нам необходимо определить ее значения w и b .

Функция Лагранжа

$$\mathcal{L}(w, b, \alpha) = \frac{1}{2} w \cdot w - \sum_{i=1}^m \alpha_i [y_i(w x_i + b) - 1].$$

$$\nabla \mathcal{L}(w, b, \alpha) = \sum_{i=1}^m \alpha_i y_i x_i = 0. \quad (5)$$

$$\nabla_b \mathcal{L}(w, b, \alpha) = -\sum_{i=1}^m \alpha_i y_i = 0. \quad (6)$$

Из уравнений (5) и (6) получаем

$$w = \sum_{i=1}^m \alpha_i y_i x_i \text{ и } \sum_{i=1}^m \alpha_i y_i = 0. \quad (7)$$

После подстановки функции Лагранжа получаем $\mathcal{L}$

$$\max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j x_i x_j. \quad (8)$$

Поскольку ограничения содержат неравенства, мы распространяем метод множителя Лагранжа на условия Каруш-Куна-Такера (ККТ). Комплементарное условие ККТ гласит, что

$$\alpha_i [y_i (w_i x^* + b) - 1] = 0 \quad (9)$$

x^* является оптимальной точкой.

α является положительным значением и α для других точек ≈ 0 так

$$y_i ((w_i x^* + b) - 1) = 0. \quad (10)$$

Они называются опорными векторами, которые являются ближайшими точками к гиперплоскости. Исходя из уравнения (10)

$$\begin{aligned} w - \sum_{i=1}^m \alpha_i y_i x_i &= 0 \\ w &= \sum_{i=1}^m \alpha_i y_i x_i. \end{aligned} \quad (11)$$

Для вычисления значения b получаем

$$y_i ((w_i x^* + b) - 1) = 0. \quad (12)$$

Умножаем обе стороны на y_i в уравнении (12) и получаем

$$y_i^2 ((w_i x^* + b) - 1) = 0,$$

где

$$\begin{aligned} y_i^2 &= 1 \\ ((w_i x^* + b) - y_i) &= 0 \\ b &= y_i - w_i x^* \end{aligned} \quad (13)$$

тогда

$$b = \frac{1}{S} \sum_{i=1}^S (y_i - w \cdot x) \quad (14)$$

S – число опорных векторов. В одном случае у нас будет гиперплоскость, тогда мы сможем использовать гиперплоскость для прогнозирования. Когда функция гипотезы равна

$$h(w_i) = \begin{cases} +1 & \text{if } w \cdot x + b \geq 0 \\ -1 & \text{if } w \cdot x + b < 0 \end{cases} \quad (15)$$

Вышеуказанная точка на гиперплоскости будет классифицирована как класс +1 (обнаружена перегрузка), а точка под гиперплоскостью будет классифицирована как -1 (перегрузка не найдена).

Таким образом, основная цель алгоритма SM – найти гиперплоскость, которая могла бы точно разделить данные, и нам нужно найти наилучшую гиперплоскость, которую часто называют оптимальной гиперплоскостью [14, 15].

Необходимо также улучшить согласованность светофоров и уменьшить заторы на дорогах. Необходимо разработать интеллектуальную систему светофоров для связи с аварийными транспортными средствами. Помимо рассмотрения значимости автомобилей в соответствии с характером инцидента, предлагаемая система включает защиту от взлома [12].

Анализ результатов. Пробки являются основной проблемой в многочисленных уличных сетях. В различных автомобильных навигационных приложениях и машинах на главных улицах прогнозирование пробок в режиме реального времени может быть сделано с помощью интернет-технологий. Правило вывода о параллельной обработке записей с устройств, видео и датчиков генерирует отчетливую онтологию в предлагаемой работе на основе датчиков [16].

Программное обеспечение для моделирования MATLAB использовалось для прогнозирования точек перегруженности. Результаты точности и пропуска во время обучения и валидации представлены в табл. 2. Для применения алгоритма SVM использовался набор данных из 1786 наборов записи; эти данные были разделены на 70% для обучения (1250 образцов) и 30% для обучения и валидации (536 образцов). Для оценки различных статистических данных, используемых для бенчмаркинга и эффективности, использовались различные метрики: точность, специфичность и чувствительность. Истинный положительный результат выражается с точки зрения чувствительности, а точный отрицательный – с точки зрения специфичности. Параметры, полученные из формул, задаются уравнениями (16)-(25).

Таблица 2

Обучение предлагаемой модели системы TCC-SVM при прогнозировании заторов на дорогах
Предлагаемая модель системы TCC-SVM (70% выборочных данных при обучении)

Общее количество образцов (N=1250)		Результат (Выход) (O_0O_1)	
Ожидаемый результат(T_0T_1)		O_0 (отсутствие заторов)	O_0 (наличие заторов)
Ввод	$T_0 = 838$ Положительная	Положительная	Отрицательная
	$T_1 = 412$ Отрицательная	836	02
		13	398

$$\text{Misrate} = \frac{(o_1/t_0 + o_0/t_1)}{t_0 + t_1} \quad (16)$$

$$\text{Accuracy} = \frac{(o_0/t_0 + o_1/t_1)}{t_0 + t_1} \quad (17)$$

$$\text{Sensitivity} = T_C(T_C + F_{NC}) \quad (18)$$

$$\text{Specificity} = T_{NC}(T_{NC} + F_C) \quad (19)$$

$$\text{Poor predictive value} = \frac{o_1/t_1}{(o_1/t_1 + o_0/t_1)} \quad (20)$$

$$\text{Positive prediction value} = \frac{o_0/t_0}{o_0/t_1 + o_1/t_0} \quad (21)$$

$$\text{False positive ratio} = 1 - \text{Specificity} \quad (22)$$

$$\text{False – negative ratio} = 1 - \text{sensitivity} \quad (23)$$

$$\text{Likelihood ratio positive} = \frac{\text{Sensitivity}}{(1 - \text{Specificity})} \quad (24)$$

$$\text{Likelihood ratio negative} = \frac{(1 - \text{Sensitivity})}{\text{Specificity}} \quad (25)$$

Предлагаемая модель системы TCC-SVM вычисляет ожидаемый результат как отрицательный (0) и положительный (1). Отрицательный результат (0) указывает на отсутствие переполненности, в то время как положительный результат (1) указывает на переполненность [17–21].

В таблице 2 показан прогноз пробок на дорогах, подготовленный с помощью предлагаемой модели системы TCS-SVM на этапе обучения. Всего в ходе обучения было использовано 1250 образцов. Они были далее разделены на 838 положительных и 412 отрицательных образцов. Результаты вернули 836 образцов как положительный класс, который правильно предсказал отсутствие заторов. Тем не менее, 2 записи были неправильно предсказаны как отрицательные, что говорит о том, что заторы были обнаружены, когда не было заторов. Аналогичным образом, из 412 образцов, давших отрицательный результат, 398 образцов правильно предсказали отрицательный результат, что означает, что были обнаружены перегрузки, а 14 образцов неправильно предсказали положительный результат, что указывает на отсутствие перегруженности, когда там действительно существовали заторы.

Предлагаемая модель TCS-SVM для заторов на дорогах на этапе проверки проиллюстрирована в таблице 3. 286 положительных и 250 отрицательных результатов были получены в общей сложности из 536 образцов, использованных в процессе валидации. Было обнаружено, что 4 записи ошибочно предсказывали отрицательный результат, что означает, что перегруженность была обнаружена, когда на самом деле не было перегруженности, тогда как 280 положительных записей правильно предполагали отсутствие перегруженности. Как и в предыдущем примере, 242 из 250 образцов, которые дали отрицательный результат, подразумевающий перегруженность, были идентифицированы точно прогнозируемыми перегрузками, но 7 образцов ошибочно предсказали положительный результат, не показывая заторы при возникновении заторов.

Таблица 3

Валидация предлагаемой модели системы TCC-SVM в ходе прогнозирования заторов на дорогах
Предлагаемая модель системы TCC-SVM (30% выборочных данных при валидации)

Общее количество образцов (N = 536)		Результат (Вывод) (O_0, O_1)	
Ожидаемый результат (T_0, T_1)		O_0 (отсутствие заторов) O_1 (наличие заторов)	
Ввод	$T_0 = 286$ Положительная	Положительная	Отрицательная
	$T_1 = 250$ Отрицательная	280	04
		07	242

Табл. 4 показывает производительность предложенной модели системы TCC-SVM с точки зрения чувствительности, специфичности, точности и частоты промахов на этапах обучения и проверки. Это ясно показывает, что предлагаемая система TCC-SVM во время обучения возвращала уровни 98%, 99,5%, 98,7% и 1,3% для чувствительности, специфичности, точности и частоты промахов соответственно. И во время проверки предложенная система TCC-SVM вернула уровни 97,56%, 98,37%, 97,9% и 2,1% для чувствительности, специфичности, точности и частоты ошибок соответственно. Кроме того, были добавлены дополнительные статистические меры для прогнозирования таких значений, как ложноположительные, ложноотрицательные, отрицательное отношение правдоподобия и поло-

жительное отношение, а также положительные и отрицательные значения предсказания. Результаты при обучении составили 0,5%, 2%, 196,0,0051, 99,76% и 96,60%. Во время проверки предложенная система TCC-SVM вернула 1,63%,

Таблица 4

**Оценка эффективности предлагаемой модели системы TCC-SVM
при валидации и обучении с использованием различных статистических
показателей**

	Чувствительность	Специфичность	Точность	Процент промахов	Ложноположительное значение
Обучение	(0.995)	(0.98)	(0.987)	1.3%	(0.005)
	99.5%	98%	98.7%		0.5%
Проверка	(0.9837)	(0.9756)	(0.979)	2.1%	(0.0163)
	98.37%	97.56%	97.9%		1.63%
	Ложноотрицательное значение	Коэффициент вероятности положительный	Коэффициент вероятности отрицательный	Положительное значение прогноза	Отрицательное значение прогноза
Обучение	2%	196	0.0051	99.76%	96.60%
Проверка	2.44%	59.85	0.0167	98.59%	97.18%

Вывод. Модель TCC-SVM была предложена для интеллектуальной системы управления дорожным движением, которая могла бы анализировать данные с различных сенсорных устройств для прогнозирования пробок на дорогах. Используя уровень предварительной обработки для улучшения входящих данных путем обработки отсутствующих значений, система опорных векторов используется для прогнозирования перегрузки. Результаты моделирования показывают, что предложенная модель TCC-SVM работает значительно лучше, чем предыдущие подходы.

В этом исследовании SVM используется для нахождения точки блокировки на перекрестке улиц с использованием различных фактических показателей, например, точности, специфичности, чувствительности, ложноположительного значения, вводящей в заблуждение ложноотрицательного значения, положительной доли вероятности, отрицательной доли вероятности, положительного значения прогноза и отрицательного значения прогноза.

Среди ограничений этого исследования – временные задержки, так как на производительность системы может повлиять задержка в получении информации от предыдущего состояния. Кроме того, непрерывная подача информации в систему может увеличить сложность данных. Большая часть данных не отбрасывается, потому что нет методов, связанных с обработкой этой информации. Процедуры или возможности, подобные человеческим, могут быть связаны для улучшения производительности системы.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Lana I., Del Ser J., Velez M., et Vlahogianni E. I. Road Traffic Forecasting: Recent Advances and New Challenges // IEEE Intell. Transp. Syst. Mag. – 2018. – Vol. 10, No. 2. – P. 93-109.
2. Заргарян Е.В., Аюнджян Ж.Ж. Исследование автоматизации коллаборативных роботов и способы их применения // Технологии разработки информационных систем ТРИС-2020: Матер. X Международной научно-технической конференции. "Технологии разработки информационных систем". – 2020. – С. 218-223.
3. Заргарян Ю.А. Задача управляемости в адаптивной автоматной обучаемой системе управления // Технологии разработки информационных систем ТРИС-2020: Матер. X Международной научно-технической конференции. "Технологии разработки информационных систем". – 2020.

4. Zargaryan E.V., Zargaryan Y.A., Dmitrieva I.A., Sakharova O.N. and Pushnina I.V. Modeling design information systems with many criteria. Information Technologies and Engineering – APITECH - 2020 // Journal of Physics: Conference Series. – 2020. – Vol. 2085 (3). – P. 032057(1-7). – DOI: 10.1088/1742-6596/1679/3/032057.
5. Kamarianakis Y. et Prastacos P. Forecasting Traffic Flow Conditions in an Urban Network: Comparison of Multivariate and Univariate Approaches // Transp. Res. Rec. J. Transp. Res. Board. – Janv. 2003. – Vol. 1857, No. 1. – P. 74-84.
6. Zargaryan E.V., Zargaryan Y.A., Kapc I.V., Sakharova O.N., Kalyakina I.M and Dmitrieva I.A. Method of estimating the Pareto-optimal solutions based on the usefulness // International Conference on Advances in Material Science and Technology - CAMSTech-2020. IOP Conf. Series: Materials Science and Engineering. – 2020. – Vol. 919 (2). – P. 022027 (1-8). – DOI: 10.1088/1757-899X/919/2/022027.
7. Nagatani T. The physics of traffic jams // Rep. Prog. Phys. – Sept. 2002. – Vol. 65, No. 9. – P. 1331-1386.
8. Jiber M., Lamouik I., Ali Y., et Sabri M.A. Traffic flow prediction using neural network // in 2018 International Conference on Intelligent Systems and Computer Vision (ISCV), Fez, 2018. – P. 1-4.
9. Zhang Y. et Liu Y. Comparison of Parametric and Nonparametric Techniques for Non-peak Traffic Forecasting. – 2009. – Vol. 3, No. 3. – P. 7.
10. Beloglazov D., Shapovalov I., Soloviev V., Zargaryan E. The hybrid method of path planning in non-determined environments based on potential fields // ARPN Journal of Engineering and Applied Sciences. – 2017. – Vol. 12, No. 23. – P. 6762-6772.
11. Zargarjan E.V., Zargarjan Ju.A., Finaev V.I. Information support for the training of fuzzy production account balance in the conditions of incomplete data. Innovative technologies and didactics in teaching (ITDT-2016): Collected papers. – 2016. – P. 128-138.
12. Ahmed M.S. et. Cook A.R. Analysis of Freeway Traffic Time-Series Data by Using Box-Jenkins Techniques. – P. 9.
13. Финаев В.И., Заргарян Ю.А., Заргарян Е.В., Соловьев В.В. Формализация групп подвижных объектов в условиях неопределённости для выбора управляющих решений // Информатизация и связь. – 2016. – № 3. – С. 56-62.
14. Slimani I., Farissi I. El, et Achchab S. Artificial Neural Networks for Demand Forecasting: Application Using Moroccan Supermarket Data. – 2015.
15. Slimani I., Farissi I. El, et Achchab S. Configuration and implementation of a daily artificial neural network-based forecasting system using real supermarket data // Int. J. Logist. Syst. Manag. – 2017. – Vol. 28, No. 2. – P. 144-163.
16. Пушнина И.В. Система управления подвижным объектом в условиях неопределённости // Наука и образование на рубеже тысячелетий: Сб. научно-исследовательских работ. – Кисловодск: КГТИ, 2018. – С. 65-74.
17. Wang X., Wang C. Time series data cleaning: A survey // IEEE Access. – 2020. – Vol. 8. – P. 1866-1881. – DOI: 10.1109/ACCESS.2019.2962152.
18. Data-driven smart cities: Big Data, analytics, and security. – 2018. – URL: <https://skelia.com/articles/data-driven-smart-cities-big-data-analytics-and-security> (дата обращения: 14.09.2020).
19. Kim J., Tae D., Seok J. A survey of missing data imputation using generative adversarial networks // Proc. of the 2020 Int. Conf. on Artificial Intelligence in Information and Communication, ICAIIC. – 2020. – P. 454-456. – DOI: 10.1109/ICAIIIC48513.2020.9065044.
20. Dmitrieva I.A., Milesenko L.P., Begun O.V., Berezhnaya A.V. Information Modernization of The General Theory of Environmental Safety Ensuring // IOP Conference Series: Materials Science and Engineering. III International Scientific Conference. – Krasnoyarsk, 2021. – P. 12072.
21. Аламир Х.С., Заргарян Е.В., Заргарян Ю.А. Модель прогнозирования транспортного потока на основе нейронных сетей для предсказания трафика на дорогах // Известия ЮФУ. Технические науки. – 2021. – № 6 (223). – С. 124-132.

REFERENCES

1. Lana I., Del Ser J., Velez M., et Vlahogianni E. I. Road Traffic Forecasting: Recent Advances and New Challenges, *IEEE Intell. Transp. Syst. Mag.*, 2018, Vol. 10, No. 2, pp. 93-109,
2. Zargaryan E.V., Akopdzhanyan Zh.Zh. Issledovanie avtomatizatsii kollaborativnykh robotov i sposoby ikh primeneniya [Research of automation of collaborative robots and methods of their application. In the collection], *Tekhnologii razrabotki informatsionnykh sistem TRIS-2020: Mater. X Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii. "Tekhnologii razrabotki*

- informatsionnykh sistem*" [Technologies for the development of information systems TRIS-2020. Materials of the X International Scientific and Technical Conference. "Technologies for the Development of Information Systems"], 2020, pp. 218-223.
3. Zargaryan Yu.A. Zadacha upravlyaemosti v adaptivnoy avtomatnoy obuchaemoy sisteme upravleniya [The problem of controllability in an adaptive automaton learning control system], *Tekhnologii razrabotki informatsionnykh sistem TRIS-2020: Mater. X Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii. "Tekhnologii razrabotki informatsionnykh sistem"* [Technologies for the development of information systems TRIS-2020. Materials of the X International Scientific and Technical Conference. "Technologies for the Development of Information Systems"], 2020.
4. Zargaryan E.V., Zargaryan Y.A., Dmitrieva I.A., Sakharova O.N. and Pushnina I.V. Modeling design information systems with many criteria. Information Technologies and Engineering – APITECH – 2020, *Journal of Physics: Conference Series*, 2020, Vol. 2085 (3), pp. 032057(1-7). – DOI: 10.1088/1742-6596/1679/3/032057.
5. Kamarianakis Y. et Prastacos P. Forecasting Traffic Flow Conditions in an Urban Network: Comparison of Multivariate and Univariate Approaches, *Transp. Res. Rec. J. Transp. Res. Board.*, Janv. 2003, Vol. 1857, No. 1, pp. 74-84.
6. Zargaryan E.V., Zargaryan Y.A., Kapc I.V., Sakharova O.N., Kalyakina I.M and Dmitrieva I.A. Method of estimating the Pareto-optimal solutions based on the usefulness, *International Conference on Advances in Material Science and Technology - CAMSTech-2020. IOP Conf. Series: Materials Science and Engineering*, 2020, Vol. 919 (2), pp. 022027 (1-8). DOI: 10.1088/1757-899X/919/2/022027.
7. Nagatani T. The physics of traffic jams, *Rep. Prog. Phys.*, Sept. 2002, Vol. 65, No. 9, pp. 1331-1386.
8. Jiber M., Lamouik I., Ali Y., et Sabri M.A. Traffic flow prediction using neural network // in 2018 International Conference on Intelligent Systems and Computer Vision (ISCV), Fez, 2018. – P. 1-4.
9. Zhang Y. et Liu Y. Comparison of Parametric and Nonparametric Techniques for Non-peak Traffic Forecasting, 2009, Vol. 3, No. 3, pp. 7.
10. Beloglazov D., Shapovalov I., Soloviev V., Zargaryan E. The hybrid method of path planning in non-determined environments based on potential fields, *ARPN Journal of Engineering and Applied Sciences*, 2017, Vol. 12, No. 23, pp. 6762-6772.
11. Zargarjan E.V., Zargarjan Ju.A., Finaev V.I. Information support for the training of fuzzy production account balance in the conditions of incomplete data. Innovative technologies and didactics in teaching (ITDT-2016): Collected papers, 2016, pp. 128-138.
12. Ahmed M.S. et. Cook A.R. Analysis of Freeway Traffic Time-Series Data by Using Box-Jenkins Techniques, pp. 9.
13. Finaev V.I., Zargaryan Yu.A., Zargaryan E.V., Solov'ev V.V. Formalizatsiya grupp podvizhnykh ob'ektov v usloviyakh neopredelennosti dlya vybora upravlyayushchikh resheniy [Formalization of groups of mobile objects in conditions of uncertainty for the choice of control decisions], *Informatizatsiya i svyaz'* [Informatization and communication], 2016, No. 3, pp. 56-62.
14. Slimani I., Farissi I. El, et Achchab S. Artificial Neural Networks for Demand Forecasting: Application Using Moroccan Supermarket Data, 2015.
15. Slimani I., Farissi I. El, et Achchab S. Configuration and implementation of a daily artificial neural network-based forecasting system using real supermarket data, *Int. J. Logist. Syst. Manag.*, 2017, Vol. 28, No. 2, pp. 144-163.
16. Pushnina I.V. Sistema upravleniya podvizhnym ob'ektom v usloviyakh neopredelennosti [Control system of a moving object under conditions of uncertainty], *Nauka i obrazovanie na rubezhe tysyacheletiy: Sb. nauchno-issledovatel'skikh rabot* [Science and education at the turn of the millennium. collection of research papers]. Kislovodsk: KGTI, 2018, pp. 65-74.
17. Wang X., Wang C. Time series data cleaning: A survey, *IEEE Access*, 2020, Vol. 8, pp. 1866-1881. – DOI: 10.1109/ACCESS.2019.2962152.
18. Data-driven smart cities: Big Data, analytics, and security, 2018. Available at: <https://skelia.com/articles/data-driven-smart-cities-big-data-analytics-and-security> (accessed 14 September 2020).
19. Kim J., Tae D., Seok J. A survey of missing data imputation using generative adversarial networks, *Proc. of the 2020 Int. Conf. on Artificial Intelligence in Information and Communication, ICAIIC*, 2020, pp. 454-456. DOI: 10.1109/ICAIIIC48513.2020.9065044.

20. Dmitrieva I.A., Milesheko L.P., Begun O.V., Berezhnaya A.V. Information Modernization of the General Theory of Environmental Safety Ensuring, *IOP Conference Series: Materials Science and Engineering. III International Scientific Conference*. Krasnoyarsk, 2021, pp. 12072.
21. Alamiir Kh.S., Zargaryan E.V., Zargaryan Yu.A. Model' prognozirovaniya transportnogo potoka na osnove neyronnykh setey dlya predskazaniya trafika na dorogakh [A traffic flow prediction model based on neural networks for predicting traffic on the roads], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 6 (223), pp 124-132.

Статью рекомендовал к опубликованию д.т.н. Ю.А. Кравченко.

Аламир Хайдер Сагбан Хуссейн – Южный федеральный университет, e-mail: alamiir@sfedu.ru; г. Таганрог, Россия; кафедра систем автоматического управления; аспирант.

Заргарян Елена Валерьевна – e-mail: ezargaryan@sfedu.ru; кафедра систем автоматического управления; к.т.н.; доцент.

Заргарян Юрий Артурович – e-mail: yazargaryan@sfedu.ru; кафедра систем автоматического управления; к.т.н.; доцент.

Alamiir Haider Sagban Hussein – Southern Federal University, e-mail: alamiir@sfedu.ru; Taganrog, Russia; the department of automatic control systems; postgraduate student.

Zargaryan Elena Valerevna – e-mail: ezargaryan@sfedu.ru; the department of automatic control systems; cand. of eng. sc.; associate professor.

Zargaryan Yuri Arturovich – e-mail: yazargaryan@sfedu.ru; the department of automatic control systems; cand. of eng. sc.; associate professor.

УДК 007.519.816

DOI 10.18522/2311-3103-2023-2-186-200

С.И. Родзин, А.В. Боженюк, Ю.А. Кравченко, О.Н. Родзина

МЕТОДЫ НЕЧЕТКОГО МНОГОКРИТЕРИАЛЬНОГО ГРУППОВОГО ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ЗАДАЧ ЭВАКУАЦИИ ПРИ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЯХ*

Целями данной статьи является анализ современного состояния исследований в области нечетких методов многокритериальной оптимизации, а также разработка операторов агрегации и алгоритмов, использующих нечеткое многокритериальное групповое принятие решений с применением интуиционистского отношения лингвистических предпочтений. Представлены наиболее известные нечеткие методы многокритериальной оптимизации: ELECTRE, PROMETHEE, VIKOR, TOPSIS, ANP, ANP, MACSBETH, DEMATEL, интеграл Шоке и DEA, рассмотрены их особенности, области применения и наиболее цитируемые статьи. Большинство реальных задач оптимизации могут иметь противоречивые цели. Также представлены метод нечеткого принятия многоцелевых решений FMODM для ситуаций, когда существуют неточности и неопределенность в некоторых целях и переменных, от которых они зависят; методы нечеткого многоцелевого линейного программирования FMOLP, нечеткого многопредметного целевого программирования FMOGP и нечеткие эвристические методы принятия решений. Рассмотрена проблема нечеткого многокритериального группового принятия решений при эвакуации с интуитивным отношением лингвистических предпочтений. Отмечено, что методы нечеткой логики особенно подходят для принятия решений об эвакуации, когда данных мало, знание причинно-следственных связей неточно, а наблюдения и критерии могут быть выражены в лингвистических качественных терминах. Представлены основные этапы группового принятия наилучшего решения среди альтернатив в нечеткой среде: объединение оценок экспертов; получение итоговой оценки для каждой альтернативы, представленной лингвистической переменной; ранжирование альтернатив; групповое принятие наиболее предпочтительного

* Исследование выполнено за счет гранта Российского научного фонда № 22-71-10121, <https://rscf.ru/project/22-71-10121/> в Южном федеральном университете.