

Математическая модель оптимизации прибытия пожарного подразделения с использованием информационных систем мониторинга транспортной логистики города Воронежа

Алексей В. Кочегаров,	¹	Kochiegharov77@mail.ru
Андрей Б. Плаксицкий,	¹	pab13@mail.ru
Михаил С. Денисов,	¹	denisov.m.1981@gmail.com
Дмитрий С. Сайко	²	dmsajko@mail.ru

¹ кафедра пожарной и аварийно-спасательной техники, Воронежский институт ГПС МЧС России, Краснознаменная ул. д.231, г. Воронеж, 394052, Россия

² кафедра высшей математики, Воронежский государственный университет инженерных технологий, пр-т Революции д.19, г. Воронеж, 394036, Россия

Реферат. В последние годы сильными темпами растет строительство больших городов. С их ростом становится вопрос о дислокации пожарных и количестве пожарных депо. Наиболее эффективным является решение задачи поиска оптимального пути следования пожарного подразделения, с учетом информационных систем транспортной логистики в пределах города, что позволит оперативно прибыть к месту происшествия в любое время суток, вне зависимости от степени загруженности городских магистралей. Оперативность прибытия пожарных подразделений обеспечивает наиболее успешное тушение пожара. Основной задачей исследования является разработка предварительного маршрута и маршрута в случае непредвиденных факторов, влияющих на время прибытия пожарного автомобиля. Для построения маршрутов использовались активно развиваемые в настоящее время методы машинного обучения искусственных нейронных сетей. Для построения оптимального маршрута необходим правильный прогноз о будущем поведении сложной системы городского трафика на основании ее прошлого поведения. В рамках статистической теории машинного обучения рассмотрены задачи классификации и регрессии. Процесс обучения заключается в выборе функции классификации или регрессии из заранее заданного широкого класса таких функций. После определения схемы прогнозирования, необходимо оценить качество ее прогнозов, которые оцениваются не на основании наблюдений, а на основании уточненного стохастического процесса, итогом которого является построение правил предсказания. Верификация модели проводилась на основании данных, полученных в реальных выездах реальных пожарных расчетов, что позволило получить минимальное время прибытия пожарных подразделений.

Ключевые слова: математическое моделирование, оптимизация, пожарная безопасность

Mathematical model of optimizing the arrival of fire units with the use of information systems for monitoring transport logistics of Voronezh city

Aleksei V. Kochegarov,	¹	Kochiegharov77@mail.ru
Andrei B. Plaksitskii,	¹	pab13@mail.ru
Mikhail S. Denisov,	¹	denisov.m.1981@gmail.com
Dmitrii S. Saiko	²	dmsajko@mail.ru

¹ Voronezh institute of state firefighting service of ministry of russian federation for civil defence, emergencies and elimination of consequences of natural disasters, Krasnoznamennaya Str. 231, Voronezh, 394052, Russia

² department of higher mathematics, Voronezh state university of engineering technology, Revolution av., 19, Voronezh, 394036, Russia

Summary. In recent years, the strong pace of construction is increasing in big cities. With their growth becomes a question of the deployment of firefighters and the number of fire stations. The most effective solution is the problem of finding the optimum route of fire departments, taking into account the information transport logistics systems within the city that will allow us to arrive at the scene at any time, regardless of the degree of congestion of city roads. Prompt arrival of fire units provides the most successful fire fighting. The main objective of the study is to develop a preliminary route and the route in case of unforeseen factors affecting the time fire engine arrived. To construct the routes used to develop actively in the current methods of machine learning artificial neural networks. To construct the optimal route requires a correct prediction of the future behavior of a complex system of urban traffic based on its past behavior. Within the framework of statistical machine learning theory considered the problem of classification and regression. The learning process is to select a classification or a regression function of a predetermined broad class of such functions. After determining the prediction scheme, it is necessary to evaluate the quality of its forecasts, which are measured not on the basis of observations, and on the basis of an improved stochastic process, the result of the construction of the prediction rules. The model is verified on the basis of data collected in real departures real fire brigades, which made it possible to obtain a minimum time of arrival of fire units.

Keywords: mathematical modeling, optimization, fire safety

Для цитирования

Кочегаров А.В., Плаксицкий А.Б., Денисов М.С., Сайко Д. С. Математическая модель оптимизации прибытия пожарного подразделения с использованием информационных систем мониторинга транспортной логистики города Воронежа // Вестник ВГУИТ. 2016. № 3. С. 116–122. doi:10.20914/2310-1202-2016-3-116-122

For citation

Kochegarov A.V., Plaksitskii A. B., Denisov M. S., Saiko D. S. Mathematical model of optimizing the arrival of fire units with the use of information systems for monitoring transport logistics of Voronezh city. *Vestnik-VSUET*[Proceedings of VSUET], 2016, no. 3, pp. 116–122. (in Russian). doi:10.20914/2310-1202-2016-3-116-122

Введение

Для повышения оперативности реагирования пожарных подразделений наиболее эффективным методом является использование оптимального пути следования пожарного подразделения, с учетом прогнозирования поведения систем транспортной логистики в пределах города. Оптимальный путь следования, позволит оперативно прибыть к месту происшествия в любое время суток, вне зависимости от степени загруженности городских магистралей. Оперативность прибытия пожарных подразделений обеспечивает наиболее успешное тушение пожара. Прибытие первого пожарного подразделения в течении 10 минут для городского поселения дает большое преимущество в тушении пожара [1, 2].

Разработка методов, моделей и алгоритмов, численных методов оптимизации выбора данных и прогноза транспортной статистики процесса прибытия пожарного подразделения является актуальной задачей в крупном мегаполисе. Анализ процесса организации следования пожарного подразделения показал, что в данном вопросе отсутствует инструментарий расчета предварительного маршрута и маршрута в случае непредвиденных факторов [3]. Поэтому, основной задачей исследования является разработка предварительного маршрута и маршрута в случае непредвиденных факторов, влияющих на время прибытия ПА.

Для построения маршрутов использовались активно развиваемые в настоящее время методы машинного обучения искусственных нейронных сетей.

Для построения оптимального маршрута необходим правильный прогноз о будущем поведении сложной системы городского трафика на основании ее прошлого поведения.

1.1 Математическая модель

Основная задача исследования заключается в разработке предварительного маршрута и маршрута в случае непредвиденных факторов, влияющих на время прибытия ПА.

Для построения маршрутов мы используем активно развиваемые в настоящее время методы машинного обучения искусственных нейронных сетей.

Для построения оптимального маршрута нам необходим правильный прогноз о будущем поведении сложной системы городского трафика на основании ее прошлого поведения.

Многие задачи такого рода, возникающие в практических приложениях, не могут быть решены заранее известными методами или алгоритмами. Это происходит по той причине, что нам заранее не известны механизмы порождения

исходных данных или же известная нам информация недостаточна для построения адекватной модели источника, генерирующей поступающие к нам данные. В этих условиях оправдано применение следующего подхода, основанного на исследовании доступной нам последовательности исходных данных, и попытках строить прогноз совершенствуя нашу схему в процессе предсказания. Подход, при котором прошлые данные или примеры используются для первоначального формирования и совершенствования схемы предсказания, называется методом машинного обучения (Machine Learning).

Машинное обучение – чрезвычайно широкая и динамически развивающаяся область исследований, использующая огромное число теоретических и практических методов.

Статистическая теория машинного обучения – использует методы теории вероятностей и математической статистики. В основе данного подхода лежит предположение о том, что наблюдаемые исходы генерируются вероятностным источником, возможно, с неизвестными параметрами.

В рамках статистической теории машинного обучения мы рассматриваем задачи классификации и регрессии. Процесс обучения заключается в выборе функции классификации или регрессии из заранее заданного широкого класса таких функций.

Отметим два способа машинного обучения, используемых нами при исследовании. При первом способе часть совокупности данных – обучающая выборка – выделяется только для обучения. После того как метод предсказания определяется по обучающей выборке, более он не изменяется и в дальнейшем используется для решения задачи предсказания. При втором способе обучение никогда не прекращается, как говорится, оно происходит в режиме реального времени, т. е. предсказания и обучение происходят постоянно в процессе поступления новых данных.

После определения схемы прогнозирования, необходимо оценить качество ее прогнозов. Предварительно напомним, как оцениваются модели прогнозирования в классической статистической теории. В статистической теории прогноза мы предполагаем, что последовательность исходных данных (или исходов) является реализацией некоего стационарного стохастического процесса. Параметры этого процесса оцениваются на основании прошлых наблюдений, а на основании уточненного стохастического процесса строится правило предсказания. Функция риска данного правила предсказания определяется как среднее значение функции потерь, измеряющей различие между

предсказаниями и исходами. Среднее значение вычисляется по «истинному вероятностному распределению», которое лежит в основе модели генерации данных. Различные правила предсказания сравниваются по значениям своих функций риска.

В статистической теории машинного обучения также используется стохастическая модель генерации данных, то есть считается, что поступающие данные независимо и одинаково распределены. Вероятность ошибочной классификации или регрессии называется ошибкой обобщения [4].

Первый шаг в сторону от классической постановки заключается в том, что распределение, генерирующее данные, нам могут быть неизвестны и мы не можем, и не будем оценивать их параметры, так как они не используются в оценках ошибок классификации или регрессии.

Второй шаг заключается в том, что мы заранее не знаем какой из методов классификации или регрессии будет построен по наблюдаемой части данных в процессе обучения; нам задан целый класс таких методов – например, это может быть класс разделяющих гиперповерхностей в многомерном пространстве. Оценки ошибки обобщения при классификации или регрессии должны быть равномерными по всем таким вероятностным распределениям и применяемым методам. Эти оценки не зависят от распределения, генерирующего данные, а также от функции классификации или регрессии. Впервые данный подход был реализован в работах Вапника и Червоненкиса [5].

Для оценки предсказательной способности схемы классификации или регрессии используется теория обобщения. В рамках этой теории даются оценки вероятности ошибки классификации будущих данных при условии, что обучение проведено на случайной обучающей выборке достаточно большого размера и в его результате функция классификации (регрессии) согласована с обучающей выборкой.

Для оценки качества обучения нейросети нами был произведен статистический анализ значимости факторов, влияющих на время прибытия ПА при вызове на ЧС. В итоге были выявлены факторы, влияние которых на время прибытия статистически значимо. Мы приводим их по убыванию значимости:

1. координаты конечной точки x_1, x_2 ;
2. время суток x_3 ;
3. день недели x_4 ;
4. праздничный или предпраздничный день x_5 ;
5. стаж водителя x_6 ;
6. степень износа техники x_7 .

Далее мы строим линейную регрессионную модель необходимую для получения наиболее точного прогноза. Данная модель необходима

для оценки качества обучения нейросети и поддержки маршрутизации следования ПА. Самой употребляемой и наиболее простой из моделей множественной регрессии является линейная модель множественной регрессии:

$$y = \alpha' + \beta_1' x_1 + \beta_2' x_2 + \dots + \beta_p' x_p + \varepsilon$$

по математическому смыслу коэффициенты β_j' в уравнении равны частным производным резуль- тативного признака y по соответствующим факто-

рам: $\beta_1' = \frac{\partial y}{\partial x_1}, \beta_2' = \frac{\partial y}{\partial x_2}, \dots, \beta_p' = \frac{\partial y}{\partial x_p}$. Параметр

α называется свободным членом и определяет значение y в случае, когда все объясняющие переменные равны нулю. Однако, как и в случае парной регрессии, факторы по своему содержанию часто не могут принимать нулевых значений, и значение свободного члена не имеет практического смысла. При этом, в отличие от парной регрессии, значение каждого регрессионного коэффициента β_j' равно среднему изменению y при увеличении x_j на одну единицу лишь при условии, что все факторы остались неизменными. Величина ε представляет собой случайную ошибку регрессионной зависимости. Получение оценок параметров $\alpha', \beta_1', \beta_2', \dots, \beta_p'$ уравнения регрессии – одна из важнейших задач множественного регрессионного анализа. Самым распространенным методом решения этой задачи является метод наименьших квадратов (МНК). Его суть состоит в минимизации суммы квадратов отклонений наблюдаемых значений зависимой *переменной* y от её значений \hat{y} , получаемых по уравнению регрессии. Поскольку параметры $\alpha', \beta_1', \beta_2', \dots, \beta_p'$ являются случайными величинами, определить их истинные значения по выборке невозможно. Поэтому вместо теоретического уравнения регрессии оценивается так называемое эмпирическое уравнение регрессии, которое можно представить в виде:

$$y = a + b_1 x_1 + b_2 x_2 + \dots + b_p x_p + e.$$

Здесь a, b_1, b_2, \dots, b_p – оценки теоретических значений $\alpha', \beta_1', \beta_2', \dots, \beta_p'$, или эмпирические коэффициенты регрессии, e – оценка отклонения ε . Тогда расчетное выражение имеет вид: $\hat{y} = a + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$. Пусть имеется n наблюдений объясняющих переменных и соответствующих им значений резуль- тативного признака: $(x_{i1}, x_{i2}, \dots, x_{ip}, y_i)$, $i = \overline{1, n}$. Для однозначного определения значений параметров уравнения объем выборки n должен быть не меньше количества параметров, т. е. $n \geq p + 1$. В противном случае значения параметров не могут быть определены

однозначно. Если $n = p + 1$, оценки параметров рассчитываются единственным образом без МНК простой подстановкой значений в выражение. Получается система $(p + 1)$ уравнений с таким же количеством неизвестных, которая решается любым способом, применяемым к системам линейных алгебраических уравнений (СЛАУ). Однако с точки зрения статистического подхода такое решение задачи является ненадежным, поскольку измеренные значения переменных содержат различные виды погрешностей. Поэтому для получения надежных оценок параметров уравнения объём выборки должен значительно превышать количество определяемых по нему параметров.

При построении модели нами был использован матричный метод, поскольку, использовалась относительно небольшая выборка данных для анализа маршрутизации от одной пожарной части. Представим данные наблюдений и параметры модели в матричной форме.

$Y = [y_1, y_2, \dots, y_n]'$ – n – мерный вектор – столбец наблюдений зависимой переменной, в нашем случае это время и координаты узловых точек маршрута;

$B = [a, b_1, b_2, \dots, b_p]'$ – $(p + 1)$ – мерный вектор – столбец параметров уравнения регрессии (3);

$Y = [y_1, y_2, \dots, y_n]'$ – n – мерный вектор – столбец отклонений выборочных значений y_i от значений \hat{y}_i , получаемых по уравнению.

Для удобства записи столбцы записаны как строки и поэтому снабжены штрихом для обозначения операции транспонирования.

Наконец, значения независимых переменных запишем в виде прямоугольной матрицы размерности $n \times (p + 1)$:

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix}$$

Каждому столбцу этой матрицы отвечает набор из n значений одного из факторов, а первый столбец состоит из единиц, которые соответствуют значениям переменной при свободном члене.

В этих обозначениях эмпирическое уравнение регрессии выглядит так:

$$Y = XB + e \quad (1)$$

Отсюда вектор остатков регрессии можно выразить таким образом:

$$e = Y - XB \quad (2)$$

Таким образом, функционал $Q = \sum e_i^2$, который минимизируется по МНК, можно

записать как произведение вектора – строки e' на вектор – столбец e :

$$Q = e'e = (Y - XB)'(Y - XB) \quad (3)$$

В соответствии с МНК дифференцирование Q по вектору B приводит к выражению:

$$\frac{\partial Q}{\partial B} = -2X'Y + 2(X'X)B \quad (4)$$

которое для нахождения экстремума следует приравнять к нулю. В результате преобразований получаем выражение для вектора параметров регрессии:

$$B = (X'X)^{-1} X'Y \quad (5)$$

Здесь $(X'X)^{-1}$ – матрица, обратная к $X'X$.

Общий алгоритм выбора оптимального пути следования подразделений пожарной охраны к месту пожара представлен на рисунке 1.




Рисунок 1. Схема алгоритма выбора оптимального маршрута движения

Figure 1. Driving select the optimal rout of movement algorithm

Согласно этому алгоритму всякий раз, при возникновении препятствий в движении, маршрут будет перестроен с помощью обученной ранее нейросети, после чего произойдет ее переобучение с учетом вновь поступивших данных.

Для выбора оптимального маршрута на каждом шаге мы использовали многослойную нейросеть. Алгоритм ее обучения относительно несложен в реализации. Также многослойные с небольшим числом слоев достаточно эффективно применяются в задачах распознавания. Как правило, двух трех слоев достаточно для эффективного решения задач средней сложности [4, 5].

Абстрактная схема функционирования нашей сети, приведена на рисунке 2.




Рисунок 2. Схема функционирования нейросети
Figure 2. Scheme of functioning of neural network

Опишем использованный нами алгоритм обучения сети на примере однослойной сети, содержащий один слой. Пусть вектор \mathbf{X} является набором исходных данных описанных ранее. Каждая компонента $\mathbf{X} = (x_1, x_2, \dots, x_n)$ умножается на соответствующую компоненту вектора весов $\mathbf{W} = (w_1, w_2, \dots, w_n)$. Эти произведения суммируются, эта операция записывается в векторной форме как $Y = \mathbf{XW}$. Для обучения сети вектор \mathbf{X} подается на ее вход и вычисляется выход Y . Если Y правилен, то ничего не меняется. Однако если выход неправилен, то веса, присоединенные к входам, усиливающий ошибочный результат, модифицируются, чтобы уменьшить ошибку. Таким образом, алгоритм выглядит следующим образом:

1. Подать входной образ и вычислить Y .
- 2а. Если выход правильный, то перейти на шаг 1.
- 2б. Если выход неправильный и равен нулю, то добавить все входы к соответствующим им весам.

или

- 2в. Если выход неправильный и равен единице, то вычесть каждый вход из соответствующего ему веса.
3. Перейти на шаг 1.

Этот метод можно перенести на непрерывные входы и выходы. Для этого запишем, шаг 2 алгоритма обучения перцептрона обобщенной форме с помощью введения величины δ , которая равна разности между требуемым или целевым выходом T и реальным выходом Y :

$$\delta = (T - Y). \quad (6)$$

Случай, когда $\delta = 0$, соответствует шагу 2а, когда выход правилен и в сети ничего

не изменяется. Шаг 2б соответствует случаю $\delta > 0$, а шаг 2в случаю $\delta < 0$.

В любом из этих случаев перцептронный алгоритм обучения сохраняется, если δ умножается на величину каждого входа x_i и это произведение добавляется к соответствующему весу. С целью обобщения вводится коэффициент «скорости обучения» η , который умножается на δx_i , что позволяет управлять средней величиной изменения весов.

В алгебраической форме записи:

$$\Delta_i = \eta \delta x_i, w_i(n+1) = w_i(n) + \Delta_i, \quad (7)$$

где Δ_i – коррекция, связанная с i -м входом x_i ; $w_i(n+1)$ – значение веса i после коррекции; $w_i(n)$ – значение веса i до коррекции. В случае многослойной сети алгоритм работает аналогично с учетом того факта, что выходы одного слоя формируют входы второго и используется алгоритм обратного распространения ошибки [4-5].

Контроль качества обучения нейросети и ее переобучение проводится на основе сравнения с результатами базового прогноза маршрута и времени. Общая схема алгоритма контроля обучения представлена на рисунке 3

Этот базовый прогноз строится на основе линейной модели описанной нами ранее. Также, как для контроля, так и с целью самостоятельного, независимого прогноза маршрута и времени могут быть использованы нелинейные модели.




Рисунок 3. Алгоритм контроля обучения нейросети
Figure3. Learning neural network control algorithm

1.2 Верификация модели

В ходе исследования мы пользовались данными о выездах учебно-пожарной части ФГБОУ ВО Воронежский институт ГПС МЧС России. Всего за 2014–2015 годы было зарегистрировано 546 выездов. Для первоначального

обучения нейросети было сгенерировано 10000 адресов, локализованных в Советском и Ленинском районах города Воронежа.

Результаты работы алгоритма были протестированы на данных журнала выезда, были получены следующие результаты, представленные в таблице 1.

Таблица 1.

Данные о выездах пожарных подразделений к месту пожара

Table 1.

Information about the departures of fire units to the fire

	По журналу выездов	Оценка по модели регрессии с учетом данных о пробках на 2015 год	Оценка с помощью нейросети
Среднее время прибытия общее по 546 выездам	7 минут 30 секунд	6 минут 20 секунд	5 минут 40 секунд
Среднее время прибытия общее в понедельник	8 минут 0 секунд	6 минут 50 секунд	6 минут 20 секунд
Среднее время прибытия общее во вторник	7 минут 20 секунд	5 минут 50 секунд	5 минут 0 секунд
Среднее время прибытия общее в среду	7 минут 20 секунд	5 минут 50 секунд	5 минут 0 секунд
Среднее время прибытия в четверг	7 минут 20 секунд	5 минут 50 секунд	5 минут 0 секунд
Среднее время прибытия в пятницу	11 минут 40 секунд	9 минут 40 секунд	7 минут 40 секунд
Среднее время прибытия общее в субботу	5 минут 50 секунд	5 минут 0 секунд	5 минут 10 секунд
Среднее время прибытия общее в воскресенье	5 минут 30 секунд	5 минут 0 секунд	5 минут 0 секунд
Среднее время прибытия общее в праздничные дни	6 минут 0 секунд	6 минут 0 секунд	5 минут 30 секунд
Среднее время прибытия общее в предпраздничные дни	9 минут 0 секунд	8 минут 0 секунд	7 минут 0 секунд

Вывод

Таким образом, модель расчета прибытия пожарных подразделений с использованием обученной ранее многослойной нейросети, показала свою эффективность. Выбор оптимального маршрута на каждом шаге, в том числе и при возникновении препятствий в движении,

при помощи многослойной нейросети перестраивался. После чего происходило переобучение с учетом вновь поступивших данных. Протестированные результаты работы алгоритма по 10000 адресам локализованных в Советском и Ленинском районах города Воронежа, позволили получить минимальное время прибытия пожарного подразделения.

ЛИТЕРАТУРА

1 Кочегаров А.В., Плаксицкий А.Б., Денисов М.С. Оптимизация маршрутов прибытия пожарных автомобилей в условиях сложных транспортных систем г. Воронежа // Проблемы обеспечения безопасности при ликвидации последствий чрезвычайных ситуаций. 2015. Т. 1. С. 229–232

2 Кочегаров А.В., Плаксицкий А.Б., Денисов М.С. Оптимизация маршрутов прибытия пожарных автомобилей в условиях сложных транспортных систем // Вестник Санкт-Петербургского университета ГПС МЧС России. 2016. № 1. С. 74–79.

3 Дорохин С.В., Скрыпников А.В. Обоснование области применения информационных устройств и их эффективность на участках лесных автомобильных дорог // Современные проблемы науки и естествознания. 2015. № 1–1. С. 87.

4 Воронцов К.В. Математические методы обучения по прецедентам (теория обучения машин). URL: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf>

5 Увалиев Д.С., Лысенко А.А., Выговтов А.В. Применение математического моделирования при решении прикладных задач // Проблемы обеспечения безопасности при ликвидации последствий чрезвычайных ситуаций. 2014. № 1 (3). С. 315–317.

REFERENCES

1 Kochegarov A.V., Plaksitskiy A.B., Denisov M.S. Optimizing routes arrival of fire trucks in complex transport systems Voronezh. *Problemy obespecheniya bezopasnosti pri likvidatsii posledstviy chrezvychaynykh situatsii* [Security issues in the aftermath of emergencies] 2015, vol. 1, pp. 229–232. (in Russian)

2 Kochegarov A.V., Plaksitskiy A.B., Denisov M.S. Optimizing routes arrival of fire trucks in complex transport systems. *Vestnik Sankt-Peterburgskogo universiteta GPS MChS Rossii* [Bulletin of St. Petersburg State University Fire Service] 2016, no. 1, pp. 74–79. (in Russian)

3 Dorokhin S.V., Skrypnikov A.V. Justification of the application of information devices and their effectiveness in the areas of forest roads. *Sovremannye problem nauki i estestvoznaniya* [Modern problems of science and natural science] 2015, no. 1–1, pp. 87. (in Russian)

СВЕДЕНИЯ ОБ АВТОРАХ

Алексей В. Кочегаров доцент, профессор, Воронежский институт ГПС МЧС России, Краснознаменная ул. д.231, г.Воронеж, 394052, Россия Kochiegharov77@mail.ru

Андрей Б. Плаксицкий доцент, Воронежский институт ГПС МЧС России, Краснознаменная ул. д.231, г.Воронеж, 394052, Россия pab13@mail.ru

Михаил С. Денисов доцент, Воронежский институт ГПС МЧС России, Краснознаменная ул. д.231, г.Воронеж, 394052, Россия denisov.m.1981@gmail.com

Дмитрий С. Сайко д. ф.-м. н., профессор, заведующий кафедрой, кафедра высшей математики, Воронежский государственный университет инженерных технологий, пр-т Революции, 19, г. Воронеж, 394036, Россия, dmsajko@mail.ru

КРИТЕРИЙ АВТОРСТВА

Алексей В. Кочегаров предложил методику проводил научные консультации

Михаил С. Денисов выполнил расчеты

Андрей Б. Плаксицкий обзор литературных источников по исследуемой проблеме написал рукопись, корректировал её до подачи в редакцию

Дмитрий С. Сайко проводил научные консультации

КОНФЛИКТ ИНТЕРЕСОВ

Авторы заявляют об отсутствии конфликта интересов.

ПОСТУПИЛА 01.08.2016

ПРИНЯТА В ПЕЧАТЬ 22.08.2016

4 Vorontsov K.V. Matematicheskie metody obucheniya po pretsedentam [Mathematical methods of training on precedents (machine learning theory)]. Available at: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf> (in Russian)

5 Uvaliev D.S., Lysenko A.A., Vytovtov A.V. Application of mathematical modeling in solving applied problems. *Problemy obespecheniya bezopasnosti pri likvidatsii posledsvii chrezvychainykh situatsii* [Security issues in the aftermath of emergencies] 2014, no. 1 (3), pp. 315–317. (in Russian)

INFORMATION ABOUT AUTHORS

Alexey V. Kochegarov associate professor, professor, EMERCOM of Russia, Krasnoznamennaya Str. 231, Voronezh, 394052, Russia Kochiegharov77@mail.ru

Andrew B. Plaksitskiy assistant professor, EMERCOM of Russia, Krasnoznamennaya Str. 231, Voronezh, 394052, Russia pab13@mail.ru

Mikhail S. Denisov assistant professor, VISFS of EMERCOM of Russia, Krasnoznamennaya Str. 231, Voronezh, 394052, Russia denisov.m.1981@gmail.com

Dmitrii S. Saiko doc. phys.-math. sci., professor, head of department, department of higher mathematics, Voronezh state university of engineering technologies, Revolution av., 19, 394036, Voronezh, Russia, dmsajko@mail.ru

CONTRIBUTION

Aleksei V. Kochegarov proposed methodology conducted scientific advice

Mikhail S. Denisov performed the calculations

Andrei B. Plaksitskii review of the literature on the researched topic written manuscript, correct it before the submission to the editor

Dmitrii S. Saiko conducted scientific advice

CONFLICT OF INTEREST

The authors declare no conflict of interest.

RECEIVED 8.1.2016

ACCEPTED 8.22.2016