

Научная статья  
УДК 614.849  
doi:10.34987/vestnik.sibpsa.2025.37.31.024

## Моделирование реагирования подразделений пожарной охраны на пожароопасные инциденты

*Анна Викторовна Зиненко*<sup>1</sup>

*Сергей Александрович Гилек*<sup>2</sup>

<sup>1</sup>Сибирский федеральный университет, Красноярск, Россия

<sup>2</sup>Сибирская пожарно-спасательная академия ГПС МЧС России, г. Железногорск, Россия

*Автор, ответственный за переписку: Анна Викторовна Зиненко anna-z@mail.ru*

**Аннотация.** Работа посвящена повышению эффективности оперативного реагирования подразделений пожарной охраны на чрезвычайные ситуации путем оптимизации процесса определения необходимых ресурсов. Авторами поставлена задача формализации данного процесса как задачи регрессии в машинном обучении, где по характеристикам объекта (пожарно-тактическим и специфическим признакам инцидента) необходимо спрогнозировать количественные параметры сил и средств: количество звеньев ГДЗС, ГДЗ, личного состава, подразделений и пожарных автомобилей. Для решения задачи предложен модифицированный двухэтапный алгоритм на основе градиентного бустинга. На первом этапе для снижения размерности факторного пространства и учета 12 разнородных пожарно-тактических характеристик объекта вводится интегральный показатель, веса для которого рассчитываются с использованием метода главных компонент. На втором этапе реализуется алгоритм градиентного бустинга, где в качестве слабых предсказателей используются решающие деревья заданной глубины, обеспечивающей учет всех признаков. Модель обучена и протестирована на выборке из 1507 сценариев. Качество прогноза оценено по средней абсолютной ошибке (MAE). Наилучшие результаты достигнуты для предсказания количества пожарных автомобилей и ГДЗ (ошибка 3-14% от среднего значения), для других ресурсов ошибка составила 20-30%. Разработанный подход позволяет автоматизировать и ускорить принятие решений при ликвидации пожаров, что в перспективе снизит временные и материальные потери.

**Ключевые слова:** ликвидация пожара, пожарно-тактические характеристики, метод главных компонент, градиентный бустинг

**Для цитирования:** Зиненко А.В. Гилек С.А. Моделирование реагирования подразделений пожарной охраны на пожароопасные инциденты // Сибирский пожарно-спасательный вестник. 2025. № 4 (39). С. 134-140.  
<https://doi.org/10.34987/vestnik.sibpsa.2025.37.31.024>.

Original article.

## Modeling the response of fire departments to fire incidents

Anna V. Zinenko<sup>1</sup>

Sergey A. Gilek<sup>2</sup>

<sup>1</sup>Siberian Federal University, Krasnoyarsk, Russia

<sup>2</sup>Siberian Fire and Rescue Academy EMERCOM of Russia, Zheleznogorsk, Russia

**Corresponding author:** Anna V. Zinenko, anna-z@mail.ru

**Abstract.** This paper aims to improve the efficiency of fire departments' emergency response by optimizing the process of determining the required resources. The authors set the objective of formalizing this process as a regression problem in machine learning. Using facility characteristics (fire-tactical and incident-specific features), they must predict the quantitative parameters of forces and resources, including the number of firefighting and fire protection units, personnel, units, and fire trucks. For solvation of this problem the authors proposed a modified two-stage algorithm based on gradient boosting. In the first stage, an integral indicator introduced to reduce the dimensionality of the factor space and account for 12 heterogeneous fire-tactical characteristics of the facility. The weights for this indicator were calculated using the principal component analysis. In the second stage, a gradient boosting algorithm was implemented, using decision trees of a specified depth, ensuring that all features are taken into account, as weak predictors. The model was trained and tested on a sample of 1,507 scenarios. The forecast quality was assessed using the mean absolute error (MAE). The best results were achieved for predicting the number of fire trucks and GSP (errors of 3-14% of the average value); for other resources, the error was 20-30%. The developed approach enables automation and acceleration of decision-making during fire suppression, which will ultimately reduce time and material losses.

**Keywords:** fire suppression, fire-tactical characteristics, principal component analysis, gradient boosting

**For citation:** Zinenko A.V., Gilek S.A. Modeling the response of fire departments to fire incidents // Siberian Fire and Rescue Bulletin.2025. № 4 (39). С. 134-140. (In Russ.) <https://doi.org/10.34987/vestnik.sibpsa.2025.37.31.024>.

### Введение

В Российской Федерации к институциональным субъектам, обеспечивающим безопасность, можно отнести организации государственных органов исполнительной власти, осуществляющих оперативное реагирования на происшествия и чрезвычайные ситуации. Эти организации характеризуются сложной структурой управления, а также специфическими особенностями объема и интенсивностью поступления информации для принятия управленческих решений.

Повышение эффективности системы обработки информации при реагировании на чрезвычайные ситуации и происшествия в подразделениях пожарной охраны позволяет сэкономить время, затрачиваемое на выезд и существенно уменьшить потери от пожаров.

Эффективное реагирование на пожароопасные инциденты описывается следующей задачей поддержки принятия решений. На каждый пожароопасный инцидент необходимо оперативно определить ресурсы для ликвидации инцидента, к которым относятся:

1. количество звеньев ГДЗС (ед.),
2. количество ГДЗ (чел.),
3. общее количество личного состава (чел.),
4. количество подразделений (ед.),
5. количество ПА (ед.).

Все вышеперечисленные параметры зависят от характеристик объекта, на котором произошел инцидент. Данные характеристики можно разделить на две группы: первичные пожарно-тактические признаки объекта (высота здания, огнестойкость конструкций, наличие

или отсутствие систем автоматической противопожарной защиты и др.) и специфические признаки, разные для каждого отдельного инцидента, такие как площадь пожара, этаж возникновения пожара и номер ближайшего подразделения пожарной охраны.

В работе предложено рассмотреть определение ресурсов, необходимых для ликвидации пожара в зависимости от характеристик объекта как задачу машинного обучения. Для этого следует на основании имеющихся данных обучить алгоритм и протестировать его на тестовой выборке. После обучения и тестирования алгоритм при подаче входных признаков способен определять необходимые ресурсы для ликвидации пожара уже на новых объектах

## Методы

Поскольку выходные переменные числовые, поставленная задача предсказания количества ресурсов для ликвидации пожара является задачей регрессии. Предиктивные алгоритмы машинного обучения условно можно разделить на слабые и ансамблевые. Слабым алгоритмом выступает, к примеру, дерево решений [1]. Дерево решений состоит из узлов и листьев. В узлах задается расщепление. Например, «Значения признака А больше 0,5?». Те элементы выборки, которые соответствуют условию идут в левый узел дерева, а те, которые не соответствуют – в правый. Далее на следующем уровне задается следующее расщепление и так далее, пока дерево не достигнет своей предельной глубины (задаваемой лицом, принимающим решения). В задаче регрессии на последнем уровне – листьях – отображаются средние значения результирующего признака для каждого расщепления. В процессе обучения дерева предсказанные значения результирующего признака сравниваются с фактическими и задаются признаки и пороги для расщеплений, минимизирующие разницу между прогнозом и фактом [2]. Пример дерева решений для входных признаков «Площадь пожара», «Этаж пожара» и выходного признака «Количество звеньев» показан на Рис.1.

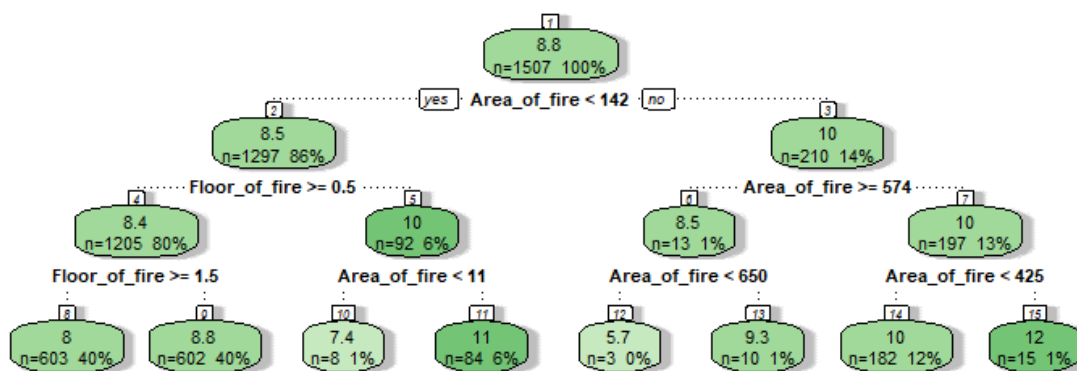


Рис.1. Пример дерева решений

В данном случае в выборке содержится 1507 единиц, в корень дерева был взят признак «Площадь пожара», порогом для расщепления в корне послужило значение площади пожара 142. Отметим, что последний уровень – листья следует округлить до целых чисел, так как выходная переменная, как и все результирующие признаки в задаче, количественная.

Поскольку в решаемой задаче имеется большое количество входных переменных, слабые предикторные алгоритмы не покажут хороших результатов [3]. Из ансамблевых алгоритмов машинного обучения, наиболее современным и эффективным является алгоритм градиентного бустинга, который последовательно строит решающие деревья, каждое последующее из которых лучше предыдущего (показывает меньшее отклонение прогнозных данных от фактических) [4].

Рассмотрим алгоритм градиентного бустинга. Как и в каждом алгоритме обучения с учителем выборка разделяется на обучающую и тестовую, и обучение модели производится на обучающей выборке.

На первом шаге строится слабый классификатор (дерево решений), в результате которого получается вектор предсказаний  $\hat{Y}^1 (\hat{y}_1^1, \hat{y}_2^1, \dots, \hat{y}_n^1)$ , где  $n$  – объем обучающей выборки. Затем рассчитываются отклонения  $\varepsilon_1^1, \varepsilon_2^1, \dots, \varepsilon_n^1, \varepsilon_i^1 = y_i - \hat{y}_i^1$ . На следующем шаге строится дерево решений по тем же входным признакам, но в качестве целевой переменной выступают отклонения. Таким образом, следующий прогноз имеет вид  $\hat{Y}^2 = \hat{Y}^1 + \hat{\varepsilon}^1, \hat{y}_i^2 = \hat{y}_i^1 + \alpha \hat{\varepsilon}_i^1$ , где  $\alpha$  – скорость обучения, варьируется от близкой к нулю величины до единицы. Второй шаг повторяется до тех пор, пока каждое новое слагаемое не перестает менять вес общей суммы. Целевой функцией, которую минимизирует алгоритм градиентного бустинга может выступать любая функция ошибки, но как правило это среднеквадратичная ошибка [5], определяемая по формуле

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2. \quad (1)$$

На этапе валидации прогноз целевых переменных производится на тестовой выборке. При этом алгоритму на вход подаются только независимые переменные, а фактические значения целевых переменных сравниваются с прогнозными. Отметим, что для каждой выходной переменной алгоритм градиентного бустинга реализуется отдельно.

Алгоритмы градиентного бустинга и решающих деревьев встроены во многое программное обеспечение, к примеру, Python и R. Однако, поставленная задача определения количества ресурсов для ликвидации пожара имеет некоторые особенности, которые вызывают необходимость модификации стандартного алгоритма градиентного бустинга.

К первой особенности относится большое количество признаков. Если специфических признаков имеется всего три: площадь пожара, этаж пожара, номер ближайшего подразделения, то первичные пожарно-тактические признаки объекта насчитывают 12 характеристик, среди которых содержатся категориальные. Ни один как встроенный в программное обеспечение, так и разработанный вручную алгоритм решения задачи регрессии, не покажет удовлетворительных результатов на таком количестве смешанных признаков, даже при условии кодирования категориальных переменных. Вторая особенность поставленной задачи – это практическая важность всех факторов, что не позволяет исключить какие-либо из них.

Для решения первой проблемы предлагается рассчитать интегральный показатель пожарно-тактических характеристик, который затем выступит факторным признаком, и таким образом снизить размерность факторного пространства до четырех. Интегральный показатель рассчитывается по следующей формуле:

$$I = \sum_{i=1}^n w_i F_i, \quad (2)$$

где,  $n$  – количество пожарно-тактических характеристик,  $F_i$  –  $i$ -я характеристика,  $w_i$  – вес  $i$ -й характеристики.

Для определения весов воспользуемся методом главных компонент [6]. Как правило, метод главных компонент используется для снижения размерности. Вместо исходных признаков используются те собственные векторы ковариационной матрицы признаков, которые вносят наибольший вклад в общую дисперсию [7]. В поставленной задаче классическим способом применить метод главных компонент не удастся, поскольку имеются закодированные категориальные признаки и, как следствие, размерность за счет расчета собственных векторов ковариационной матрицы не снижается. Однако, метод главных компонент позволяет определить ковариацию между новыми компонентами (собственными векторами) и исходными признаками. Тогда целесообразно предположить, что чем больше суммарное абсолютное

значение ковариации между  $i$ -м исходным признаком и главными компонентами, тем больше его вес в сумме главных компонент. Нормировка производится по следующей формуле:

$$w_i = \frac{scov_{i,PC}}{\sum_{i=1}^n scov_{i,PC}}, \quad (3)$$

где,  $scov_{i,PC}$  – суммарная ковариация между  $i$ -м исходным признаком и главными компонентами.

Вторая проблема решается выбором такой глубины решающих деревьев, используемых в алгоритме градиентного бустинга, чтобы учитывались все факторные признаки. При этом реализация алгоритма градиентного бустинга должна производиться не с использованием встроенных библиотек (это лишает возможности контроля учета всех признаков в решающих деревьях), а вручную, тогда как сами решающие деревья можно строить с использованием встроенных программных средств, таких как Python Scilearn [8].

Таким образом, в работе алгоритм градиентного бустинга модифицирован в двухэтапный алгоритм: на первом этапе рассчитывается интегральный показатель пожарно-тактических характеристик, а на втором – реализуется непосредственно градиентный бустинг с требованием надлежащей глубины решающих деревьев.

## Результаты и обсуждение

Рассматривается выборка из 1507 сценариев, в каждом из которых имеется информация о входных признаках: 12 пожарно-тактических характеристик, площади пожара, этаже пожара, номере ближайшего подразделения пожарной охраны и выходных признаках: количестве звеньев ГДЗС, количестве ГДЗ, общем количестве личного состава, количестве подразделений, количестве ПА. В первую очередь, исходная выборка делится на тренировочную и тестовую в соотношении 80: 20. Обучение модели производится на тренировочной выборке.

На первом этапе определены веса каждой пожарно-тактической характеристики в рассчитываемом интегральном показателе. Для этого был использован модуль «Rcomp» среды программирования RStudio. Итоговые веса всех 12 характеристик показаны на Рис.2. Можно заметить, что все они колеблются в границах от 6 до 9,5 %.




Рис.2. Веса пожарно-тактических характеристик для расчета интегрального показателя

Далее по формуле 2 были рассчитаны интегральные показатели по каждому сценарию. Итогом стал датасет, состоящий из четырех факторных и пяти результирующих признаков. Модели градиентного бустинга были построены отдельно для каждого выходного признака. Глубина деревьев была выбрана 4, что позволило учитывать все признаки, при этом избежав перегруженности алгоритма и переобучения слабых предсказателей. Модель градиентного

бустинга обучалась по схеме, описанной в предыдущем разделе. Результатом обучения выступает вектор весов каждого решающего дерева в итоговом предсказании.

На этапе тестирования в обученную модель подавались факторные признаки из тестовой выборки. Затем полученные прогнозы сравнивались с фактическими результирующими признаками по метрике «Средняя абсолютная ошибка» (MAE). Метрика MAE рассчитывается по следующей формуле [9]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (4)$$

где,  $n$  – количество элементов в выборке,  $y_i$  – фактическое значение,  $\hat{y}_i$  – прогнозное значение.

**Таблица. Результаты тестирования**

Признак	Кол-во звеньев ГДЗС	Кол-во ГДЗ	Кол-во ЛС	Кол-во подразделений	Кол-во ПА
MAE	2	6	6	2	3
Среднее	9	41	28	10	79

Поскольку входные переменные целочисленные, а ошибка – абсолютная, мы округлили значения ошибок и средних в большую сторону. Лучшие результаты модель показывает по признакам «Количество ГДЗ» и «Количество ПА» (3 и 14 % от среднего), при этом по признакам «Количество звеньев ГДЗС» и «Количество подразделений» модель показывает худший результат – 20 и 30% от среднего соответственно. В дальнейшем планируется совершенствование модели, для чего будет осуществлен анализ влияния каждого входного фактора. Итогом исследования станет разработка прототипа программного обеспечения модели реагирования на пожароопасные ситуации.

#### Список источников

1. Шемелова О.В. Метод "Дерева решений" при решении задач теории вероятностей // Евразийское Научное Объединение. 2021. № 12-1 (82). С. 43-45.
2. Мефтахетдинова Д.Р., Магеррамов З.Т. Анализ дерева решений и логистический регрессионный анализ как аналитические методы системы поддержки принятия решений // Sciences of Europe. 2023. № 112 (112). С. 69-73.
3. Анастасиади Д. Е., Верещагин А.А., Пятаков М.А. Машинное обучение и его применение в различных областях, включая медицину, финансы и производство // Научный аспект. 2024. Т. 46. №4. С. 6166 –6174.
4. Коновалов Г.Г. применение машинного обучения для оптимизации запросов в системах управления базами данных // Международный журнал гуманитарных и естественных наук. 2023. № 10-2 (85). – С. 58-61.
5. Салтанаева Е.А., Шакиров А.А., Гимаева А.Р. Сравнение традиционных методов машинного обучения и глубокого обучения // Научно-технический вестник Поволжья. 2023. № 12. С. 379-381.
6. Салимгареева Д.А. Метод главных компонент // NovaInfo.Ru. 2017. Т. 3. № 58. С. 5-9
7. Фомина Е.Е. Применение категориального метода главных компонент в прикладных социологических исследованиях // Russian Economic Bulletin. 2022. Т. 5. № 1. С. 18-25.
8. Картер Д. Искусственный интеллект. Машинное обучение / Д. Картер. – Москва: «Автор» 2024. 268 с.
9. Борисова Л.Р. Анализ продолжительности жизни в регионах Российской Федерации по методам машинного обучения и регрессионному анализу // Современная математика и концепции инновационного математического образования. 2021. Т. 8. № 1. С. 224-230.

#### References

1. Shemelova O. V. The "Decision Tree" Method in Solving Probability Theory Problems // Eurasian Scientific Association. 2021. No. 12-1 (82). Pp. 43-45.

2. Meftakhetdinova D. R., Magerramov Z. T. Decision Tree Analysis and Logistic Regression Analysis as Analytical Methods of a Decision Support System // Sciences of Europe. 2023. No. 112 (112). Pp. 69-73.
3. Anastasiadi D. E., Vereshchagin A. A., Pyatakov M. A. Machine Learning and Its Application in Various Fields, Including Medicine, Finance, and Manufacturing // Scientific Aspect. 2024. Vol. 46. No. 4. P. 6166–6174.
4. Kononov G. G. Application of Machine Learning to Optimize Queries in Database Management Systems // International Journal of Humanities and Natural Sciences. 2023. No. 10-2 (85). – P. 58-61.
5. Saltanaeva E. A., Shakirov A. A., Gimaeva A. R. Comparison of Traditional Methods of Machine Learning and Deep Learning // Scientific and Technical Bulletin of the Volga Region. 2023. No. 12. P. 379-381.
6. Salimgareeva D. A. Principal Component Analysis // NovaInfo.Ru. 2017. Vol. 3. No. 58. P. 5-9.
7. Fomina E. E. Application of the Categorical Principal Component Analysis in Applied Sociological Research // Russian Economic Bulletin. 2022. Vol. 5. No. 1. Pp. 18-25
8. Carter, D. Artificial Intelligence. Machine Learning / D. Carter. – Moscow: "Author" 2024. 268 p.
9. Borisova, L.R. Analysis of Life Expectancy in the Regions of the Russian Federation Using Machine Learning and Regression Analysis // Modern Mathematics and Concepts of Innovative Mathematical Education. 2021. Vol. 8. No. 1. Pp. 224-230.

Информация об авторах

А.В. Зиненко – кандидат технических наук, доцент

Information about the author

A.V. Zinenko – Ph.D. of Engineering Science, Docent

**Вклад авторов:** все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

**Contribution of the authors:** the authors contributed equally to this article. The authors declare no conflicts of interests.

Статья поступила в редакцию 14.11.2025, одобрена после рецензирования 15.12.2025, принята к публикации 16.12.2025.

The article was submitted 14.11.2025, approved after reviewing 15.12.2025, accepted for publication 16.12.2025.