

ственного влияния на распределение температуры в радиальном сечении. Это подтверждается результатами моделирования изменения температуры дренажного трубопровода с наличием стенки трубы и металлопокрытия и без них.

Таблица 1. Теплофизические характеристики материалов теплоизоляции.

Наименование	Коэффициент теплопроводности, Вт/(м*К)	Удельный коэффициент теплоемкости, Дж/(кг*К)	Плотность, кг/м <sup>3</sup>
Базальтовое волокно	0,039	860	50
МПБ-50/кт2	$0,035+0,17\cdot 10^{-3}t_{cp}$	845	70
Blanket 1050	$0,011+0,98\cdot 10^{-3}t_{cp}$	850	64
Blanket 1260	$0,012+0,91\cdot 10^{-3}t_{cp}$	845	96
Blanket 1430	$0,016+0,56\cdot 10^{-3}t_{cp}$	855	160

В результате моделирования теплогидравлических процессов было получено распределение температур на поверхности металлопокрытия. Среднее отклонение результатов моделирования трубопровода линии отвода аргона от прямого измерения составляет 7,35 %. Разница обусловлена наличием сложной геометрии в боксе оборудования, конвективными потоками от нижерасположенного оборудования, не учтенного в модели и не точностью приборов измерения температуры.

В дальнейшей перспективе планируется моделирование фазового перехода в рассматриваемых системах для определения факторов влияющих на интенсивность протекающих процессов и нахождения пути влияния на эти факторы.

#### СПИСОК ЛИТЕРАТУРЫ

1. Пряхин В.Н. Использование математических моделей двухфазных потоков для анализа теплогидравлических процессов на АЭС // Теплоэнергетика. – 1994. – № 5. – С. 40–42. – EDN AIUPGP.
2. Ташлыков О.Л., Наумов А.А., Щеклеин С.Е. Моделирование процесса замораживания натрия в трубопроводах с целью оптимизации ремонта реакторных установок на быстрых нейтронах // Известия высших учебных заведений. Ядерная энергетика. – 2013. – № 2. – С. 21–26.
3. Tashlykov O.L., Bessonov I.A., Lezov A.D., Chalpanov S.V., Smykov M.S., Skvortsov G.I., Klimova V.A. Computational and experimental studies into the hydrodynamic operation conditions of container filters for ion-selective treatment // Nuclear Energy and Technology. – 2022. – V. 8(3). – P. 197–202. – URL: <https://doi.org/10.3897/nucet.8.94105>
4. Kurteev A.V., Klimova V.A., Sevastyanov M.M., Tashlykov O L. Numerical simulation of residual heat removal from the spent fuel assemblies storage pit // AIP Conference Proceedings. – December 2019. – 2174(1). – P 020170.

## ОЦЕНКА ЛЕСНОЙ ПОЖАРНОЙ ОПАСНОСТИ, ОБУСЛОВЛЕННОЙ ИНФРАСТРУКТУРОЙ ЖЕЛЕЗНОЙ ДОРОГИ, С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

А.О. Малинин

Томский политехнический университет, ИШЭ, НОЦ И.Н. Бутакова, группа АЗ-13

Научный руководитель: Н.В. Барановский, к.ф.-м.н., доцент НОЦ И.Н. Бутакова ИШЭ ТПУ

Своевременное предсказание возникновения очагов пожаров и прогнозирование динамики горения, непосредственно влияет на масштаб распространения пожаров, степень материального и экологического ущерба. Большое значение имеет возможность заблаговременного предсказания наличия очагов пожара, обеспечивая необходимое время для реализации противопожарных мероприятий и релокации соответствующей техники [1]. Целью физико-математических и прогностических моделей является: предсказание вероятности возникно-

вения пожаров, скорости и динамики их распространения в зависимости от различных экологических и техногенных факторов [2]. Искусственные нейронные сети могут применяться, например для детекции возгорания лесного массива, предсказания динамики его развития, площади потенциального пожара и точки его появления [3–13].

По данным ИСДМ Рослесхоз были построены векторные слои с локациями пожаров с 2011 по 2020 г. Каждый слой имеет соответствующую атрибутивную таблицу, содержащую для каждой пожарной точки: координаты, муниципальное образование, на территории которого произошел лесной пожар, наименование ближайшего населённого пункта, расстояние до него в км, площадь в га, год, дата и др. Метеоданные были получены из открытого архива метеостанции.

Исходный набор данных включал в себя 1398 точек очагов в период с 2000 по 2020 г.

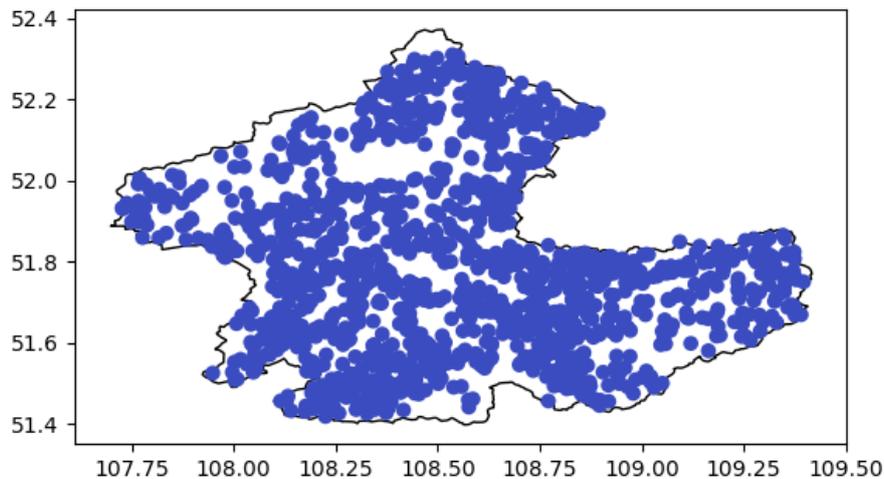


Рис. 1. Распределение очагов по местности

Для получения равномерно распределенных в границах района точек были построены сетки точек с шагом 1 км (6641 точек), 2 км (1657 точек) и 5 км (265 точек).

Данные были разделены на обучающую и тестовую выборки в соотношении 0,75 обучающая выборка, 0,25 тестовая выборка. В процессе обучения данные были распределены на пакеты по 200 точек, из которых 25 % забиралось для валидации модели.

Для ускорения обучения данные были нормализованы функцией MinMaxScaler библиотеки sklearn:

$$\hat{X}_i = \frac{X_i - X_{i_{min}}}{X_{i_{max}} - X_{i_{min}}}, \quad (1)$$

где  $X_{i_{min}}$  и  $X_{i_{max}}$  – минимальное и максимальное значение  $i$ -й входной величины;  $X_i$  – значение входной величины.

На внутренних слоях в качестве функции активации применялась функция ReLU («выпрямитель»):

$$f_t(x) = \max(0, x). \quad (2)$$

В качестве функции активации на выходном слое применялась функция сигмоида:

$$f_p(x) = \frac{1}{1 + \exp(-x)}. \quad (3)$$

Была разработана нейронная сеть прямого распространения для определения вероятности возникновения очага в точке пространства с применением языка высокого уровня Python 3.8, библиотеки Keras с ядром TensorFlow.

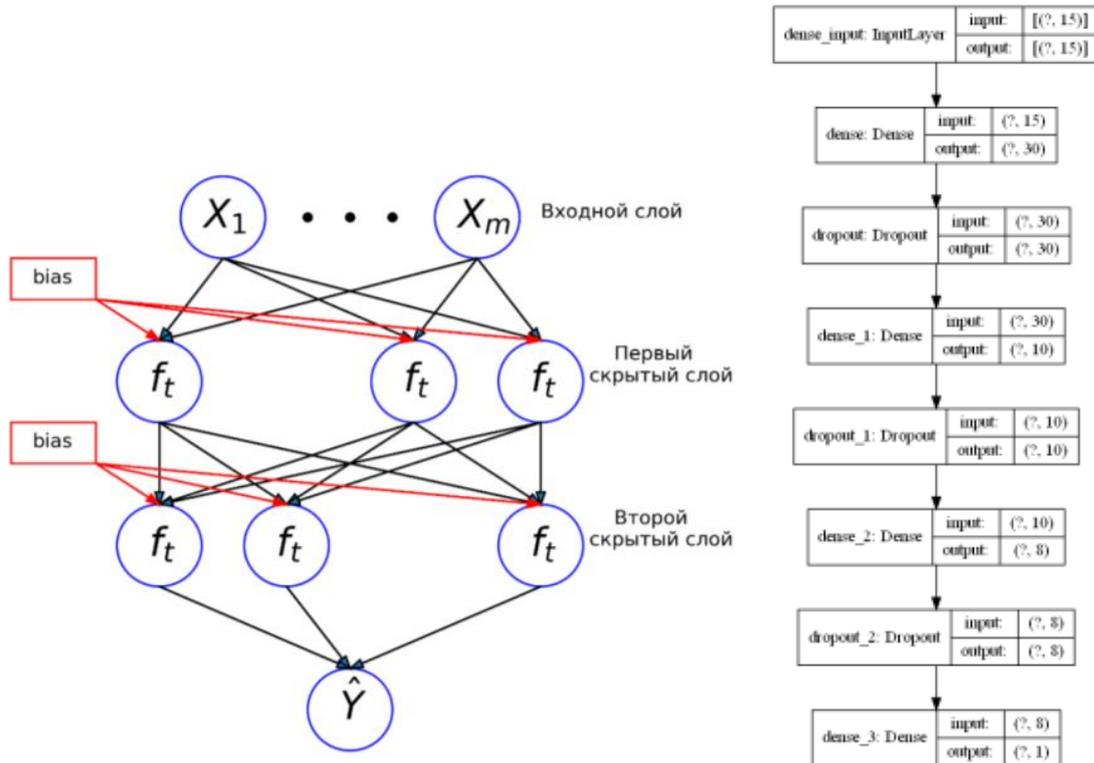


Рис. 2. Схема нейронной сети для прогнозирования пожарной опасности региона с совместным учетом метеоданных и геоданных. Трехслойная полносвязная нейросеть с 1 входным слоем, 2 скрытыми слоями и 1 выходным слоем

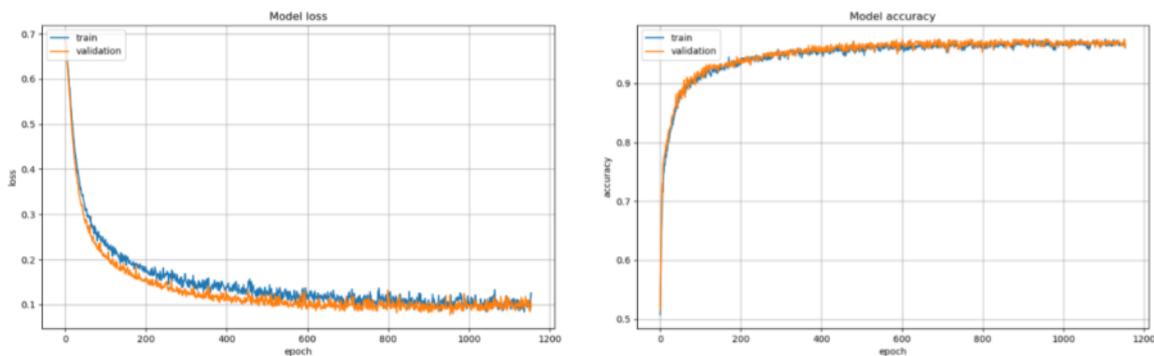


Рис. 3. График ошибки и точности обучения

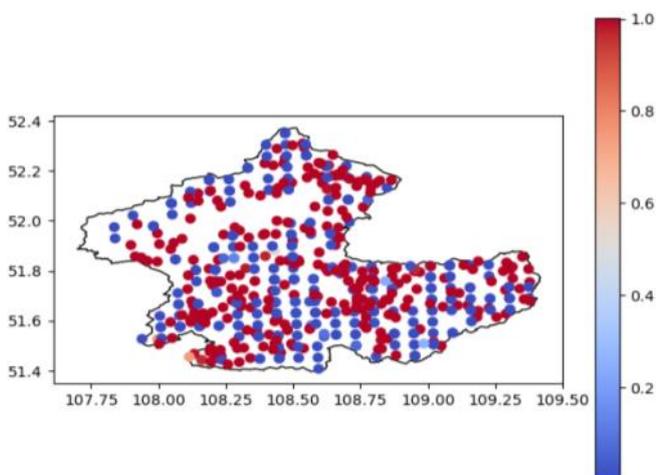


Рис. 4. Карта очагов, полученная в результате прогнозирования тестовой выборки

В данной работе была предпринята попытка применить нейросети и алгоритмы глубокого обучения для прогнозирования вероятности возникновения очага лесного пожара в Заиграевском районе.

В результате при совместном учете погодных условий в день очага и географического положения очага удалось добиться точности при обучении около 97 % на обучающей и 95 % на тестовой выборке.

Хотя в обучении модель с совместным учетом метео- и геоданных дает высокие значения точности, при прогнозировании на ранее не виданных данных не дает необходимого результата. Сеть переобучается на погодных данных и может дать хоть сколько-нибудь точный прогноз. Наиболее вероятная причина этого состоит в том, что расстояние между точками минимум 1 км. Наличие данных только с одной метеостанции не может достоверно отобразить локальные погодные условия в точке возникновения очага пламени. Значения температуры, влажности воздуха и давления окружающей среды и т. д. могут значительно колебаться на расстоянии даже в 1 км, это обусловлено характером растительности, дистанцией до водоема, локальным затенением от облаков и т. д. В связи с чем можно сделать вывод что такая задача реализуема районах с высокой плотностью размещения метеостанции, либо при значительном увеличении масштаба исследования.

### СПИСОК ЛИТЕРАТУРЫ

1. Kuznetsov G.V., Baranovskii N.V., Forecast of forest fires and their ecological consequences. – Novosibirsk: Publishing House of the Siberian Branch of the Russian Academy of Sciences, 2009.
2. Ходаков В.Е., Жарикова М., Лесные пожары: методы и исследования. – Херсон: Гринь ДС, 2011.
3. Alanis Y., Arana-Daniel N., Lopez-Franco C. Artificial neural networks for engineering applications. – St. Louis, Missouri: Elsevier, 2019.
4. Singh K.R., Neethu K.P., Madhurekaa K., Harita A., Mohan P. A Comparison of Different Methodologies for Predicting Forest Fires // Cognitive Informatics and Soft Computing. – Т. 1317.
5. Mallick P.K., Bhoi A.K., Marques G., Hugo V., de Albuquerque C. Singapore: Springer Singapore, 2021, P. 157–166. doi: 10.1007/978-981-16-1056-1\_14.
6. Rao G.N., Rao P.J., Duvvuru R. A Drone Remote Sensing for Virtual Reality Simulation System for Forest Fires: Semantic Neural Network Approach // IOP Conf. Ser. Mater. Sci. Eng. – 2016. – V. 149. – P. 012011. doi: 10.1088/1757-899X/149/1/012011.
7. Safi Y., Bouroumi A., Bouroumi A. A neural network approach for predicting forest fires // 2011 International Conference on Multimedia Computing and Systems, Ouarzazate, Morocco. – 2011. – P. 1–5. doi: 10.1109/ICMCS.2011.5945716.
8. Lall S., Mathibela B. The application of artificial neural networks for wildfire risk prediction // 2016 International Conference on Robotics and Automation for Humanitarian Applications (RAHA), Amritapuri, Kollam, Kerala, India. – 2016. – P. 1–6. doi: 10.1109/RAHA.2016.7931880.
9. Li Y., Feng Z., Chen S., Zhao Z., Wang F. Application of the Artificial Neural Network and Support Vector Machines in Forest Fire Prediction in the Guangxi Autonomous Region, China // Discrete Dyn. Nat. Soc. – 2020. – V. 2020. – P. 1–14. doi: 10.1155/2020/5612650.
10. Stankevich T.S. Development of an Intelligent System for Predicting the Forest Fire Development Based on Convolutional Neural Networks // Advances in Artificial Systems for Medicine and Education III. – V. 1126.
11. Hu Z., Petoukhov S., He M. // Cham: Springer International Publishing. – 2020. – P. 3–12. doi: 10.1007/978-3-030-39162-1\_1.
12. Khryashchev V., Pavlov V., Ostrovskaya A., Larionov R. Forest Areas Segmentation on Aerial Images by Deep Learning // 2019 IEEE East-West Design & Test Symposium (EWDTS), Batumi, Georgia. – 2019. – P. 1–5. doi: 10.1109/EWDTS.2019.8884406.
13. Ghali R., Akhloufi M.A., Jmal M., Mseddi W.S., Attia R. Forest Fires Segmentation using Deep Convolutional Neural Networks // 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Melbourne, Australia. – 2021. – P. 2109–2114. doi: 10.1109/SMC52423.2021.9658905.
14. Luo Y. et al. Forest fire detection using spiking neural networks // Proceedings of the 15th ACM International Conference on Computing Frontiers, Ischia Italy. – 2018. – P. 371–375. doi: 10.1145/3203217.3203231.
15. Satir O., Berberoglu S., Donmez C. Mapping regional forest fire probability using artificial neural network model in a Mediterranean forest ecosystem // Geomat. Nat. Hazards Risk. – 2016. – V. 7, no. 5. – P. 1645–1658. doi: 10.1080/19475705.2015.1084541.