

ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ ПОРОГОВОГО МЕТОДА HSV И НЕЙРОННОЙ СЕТИ U-NET В ЗАДАЧЕ РАСПОЗНАВАНИЯ ПОЖАРОВ

М. В. Бобырь¹ [0000-0002-5400-6817], Н. А. Милостная² [0000-0002-3779-9165],
Б. А. Бондаренко³ [0000-0001-5415-9015], М. М. Бобырь⁴ [0009-0002-9466-8898]

¹⁻⁴Юго-Западный государственный университет, г. Курск, Россия

¹maxboby@gmail.com, ²nat_mil@mail.ru, ³sikersinko@gmail.com,

⁴mmboby@gmail.com

Аннотация

Проведен сравнительный анализ методов сегментации изображений пожара с использованием пороговой обработки в цветовом пространстве HSV и нейронной сети U-Net. Цель исследования заключалась в оценке эффективности этих подходов по времени выполнения и точности детекции огня на основе метрик RMSE, IoU, Dice и MAPE. Эксперименты были проведены на четырех различных изображениях пожара с вручную подготовленными истинными масками пожаров. Результаты показали, что метод HSV обеспечивает высокую скорость обработки (0.0010–0.0020 с), но склонен к детекции не только огня, но и дыма, что снижает его точность (IoU 0.0863–0.3357, Dice 0.1588–0.5026). Нейронная сеть U-Net демонстрирует более высокую точность сегментации огня (IoU – до 0.6015, Dice – до 0.7512) за счет избирательного выделения пламени, однако требует значительно большего времени (1.2477–1.3733 с) и может недооценивать общую площадь пожара (MAPE – до 78.5840%). Визуальная оценка подтвердила различия в поведении методов: HSV захватывает дым как часть целевой области, тогда как U-Net фокусируется исключительно на огне. Выбор между методами зависит от приоритетов задачи: скорости или точности. Предложены направления дальнейших исследований, включая оптимизацию U-Net и разработку гибридных подходов.

Ключевые слова: сегментирование, локализация пожаров, HSV-сегментация, U-Net.

ВВЕДЕНИЕ

Пожары представляют собой одну из наиболее разрушительных природных и техногенных катастроф, для минимизации ущерба от которых требуется своевременное обнаружение очагов пожара и их анализ. Развитие технологий компьютерного зрения и оптики в последние десятилетия открыло новые возможности для автоматической детекции огня на изображениях и видео, что особенно актуально для систем мониторинга и раннего предупреждения. Сегментация огня – это ключевой этап в системах, позволяющий выделить области пламени для дальнейшей классификации и оценки масштаба пожара. Несмотря на значительный прогресс в этой области, существующие методы демонстрируют различные компромиссы между скоростью, точностью и устойчивостью к шумам, таким как дым или освещение.

Традиционные подходы к сегментации огня часто основываются на анализе цветовых характеристик в различных пространствах, таких как RGB, HSV и YCbCr. Например, методы пороговой обработки в пространстве HSV [1, 2] используют фиксированные диапазоны для красных, оранжевых и желтых оттенков, что позволяет быстро выделять области огня. Однако такие подходы чувствительны к изменениям освещения и часто детектируют дым или отраженный свет как ложные срабатывания [3]. Для улучшения точности были предложены адаптивные пороговые методы [4, 5], которые корректируют диапазоны на основе локальных особенностей изображения, но их производительность остается ограниченной в сложных сценах.

С развитием машинного обучения появились гибридные методы, объединяющие цветовые признаки с текстурным анализом. В работах [6–8] использованы алгоритмы кластеризации (например, k -средних) для разделения пикселей на классы огня и фона, что повышает устойчивость к шуму. Тем не менее такие методы требуют ручной настройки параметров и плохо обобщаются на новые данные. Байесовские классификаторы [9] и машины опорных векторов (SVM) [10, 11] также применялись для сегментации огня, они показали хорошие результаты в контролируемых условиях, но их эффективность снижается при наличии дыма или переменного фона.

Прорыв в области сегментации произошел с появлением глубоких нейронных сетей (DNN). Модель U-Net, предложенная в [12, 13], стала одной из наиболее популярных архитектур для задач сегментации благодаря своей способности извлекать контекстуальные признаки и восстанавливать пространственную информацию через skip-связи. Ее применение к детекции огня описано в [14, 15], эта нейронная сеть показала высокую точность в выделении пламени на сложных фонах. Другие архитектуры (DeerLab [16, 17] и Mask R-CNN [18]) также были адаптированы для аналогичных задач [19, 20] и продемонстрировали улучшение метрик IoU и Dice за счет использования предварительно обученных сетей, таких как ResNet [21] или VGG [22]. Однако эти модели требуют значительных вычислительных ресурсов и большого объема размеченных данных для обучения.

Для задач реального времени были предложены упрощенные CNN [23, 24], которые «жертвуют» точностью ради скорости. Например, в [25] описана легковесная сеть для сегментации огня на видео с частотой 30 кадров в секунду, но ее производительность ухудшается в условиях сильного задымления. Гибридные подходы, сочетающие традиционные методы и глубокое обучение, также получили распространение. В [26] HSV-фильтрация использована как предварительный этап перед подачей данных в CNN, что ускоряет обработку, сохраняя приемлемую точность. Аналогичный подход с комбинацией YCbCr и нейронных сетей представлен в [27].

Несмотря на обилие имеющихся методов, большинство исследований сосредоточено либо на скорости (традиционные подходы), либо на точности (глубокое обучение), редко предлагается сбалансированное решение. Кроме того, проблема детекции дыма как части пожара остается недостаточно изученной [28], что ограничивает применимость существующих моделей в реальных условиях.

Целью настоящего исследования является сравнительный анализ методов пороговой сегментации HSV и нейронной сети U-Net для детекции огня на изображениях пожара с учетом времени выполнения и точности сегментации. В работе оценены метрики RMSE, IoU, Dice и MAPE на основе экспериментов с различными типами пожаров, включая сцены с пожаром в горах и лесах. Научная новизна проведенного исследования заключается в:

- детальном сравнении поведения HSV и U-Net в условиях присутствия дыма, что ранее не было систематически изучено;
- выявлении компромиссов между скоростью и точностью методов на основе экспериментальных данных, полученных на специально подготовленных тестовых изображениях;
- предложении рекомендаций по выбору метода в зависимости от специфики задачи, что может послужить основой для разработки гибридных систем детекции пожара.

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ СЕТИ U-NET

Сеть U-Net представляет собой сверточную нейронную сеть (CNN) с симметричной архитектурой, состоящей из энкодера (сжимающего пути) и декодера (расширяющего пути), соединенных skip-связями. Она была разработана для задач сегментации изображений и адаптирована в настоящем исследовании для детекции огня. Рассмотрим основные компоненты и их математическое описание.

1. Энкодер (сжимающий путь)

Он состоит из последовательности сверточных слоев и операций пулинга, которые уменьшают пространственное разрешение входного изображения, извлекая признаки высокого уровня.

- **Свертка (Convolution):** для входного изображения I размером $H \times W \times C$ (где H – высота, W – ширина, C – количество каналов) свертка с ядром K размером $k_h \times k_w \times C$ и шагом (stride) 1 определяется как

$$O(i, j, m) = \sum_{c=1}^C \sum_{p=0}^{k_h-1} \sum_{q=0}^{k_w-1} I(i+p, j+q, c) K(p, q, c, m) + b_m,$$

где $O(i, j, m)$ – выходной пиксель на позиции (i, j) для m -го фильтра, b_m – смещение (bias).

- **Функция активации (ReLU):** после свертки применяется функция ReLU для введения нелинейности

$$R(x) = \max(0, x).$$

Таким образом, выход слоя

$$O_{\text{ReLU}} = R(O).$$

- **Максимальный пулинг (MaxPooling):** операция пулинга с окном 2×2 и шагом 2 уменьшает размер изображения вдвое:

$$P(i, j, m) = \max_{p=0,1} \max_{q=0,1} O_{\text{ReLU}}(2i + p, 2j + q, m).$$

В результате размер выходного окна становится равным $\frac{H}{2} \times \frac{W}{2} \times M$, где M — число фильтров.

2. Бутылочное горлышко (Bottleneck)

На нижнем уровне (bottleneck) выполняется свертка без изменения разрешения:

$$O_{\text{bottleneck}}(i, j, m) = R \left(\sum_{c=1}^{M_{\text{in}}} \sum_{p=0}^{k_h-1} \sum_{q=0}^{k_w-1} P(i + p, j + q, c) K(p, q, c, m) + b_m \right),$$

где $O_{\text{bottleneck}}(i, j, m)$ — выходной тензор на позиции (i, j) для m -го фильтра ($m = 1, \dots, M$, $M = 256$); $R(\cdot)$ — функция активации ReLU, $R(x) = \max(0, x)$; $P(i + p, j + q, c)$ — входной тензор (выход последнего пулинга энкодера) с размером $64 \times 64 \times 128$, $c = 1, \dots, M_{\text{in}}$, $M_{\text{in}} = 128$; $K(p, q, c, m)$ — элемент ядра свертки размером $k_h \times k_w \times M_{\text{in}} \times M$, $k_h = k_w = 3$; b_m — смещение для m -го фильтра.

3. Декодер (расширяющий путь)

Он восстанавливает разрешение изображения с помощью апсэмплинга и сверток, объединяя признаки из энкодера через skip-связи.

- **Апсэмплинг (UpSampling):** увеличение разрешения в 2 раза выполняется путем билинейной интерполяции или транспонированной свертки. Для простоты рассмотрим удвоение

$$U(i, j, m) = O_{\text{prev}}(i//2, j//2, m), \quad \text{с повторением значений}$$

Размер выхода: $2H' \times 2W' \times M$.

- **Конкатенация (skip-связи):** выход апсэмплинга объединяется с соответствующим слоем энкодера

$$C = \text{concat}(U, O_{\text{enc}}),$$

где C – результирующий тензор размером $H' \times W' \times (M + M_{\text{enc}})$; U – тензор после апсэмплинга на текущем уровне декодера, размером $H' \times W' \times M$ (например, $M = 256$ на первом уровне, $M = 128$ на втором); O_{enc} – тензор выхода соответствующего уровня энкодера (через skip-связь) размером $H' \times W' \times M_{\text{enc}}$, где M_{enc} – число каналов на данном уровне энкодера (например, $M_{\text{enc}} = 128$ для первого уровня декодера, $M_{\text{enc}} = 64$ для второго).

- **Свертка после конкатенации**

$$O_{\text{dec}}(i, j, m) = R \left(\sum_{c=1}^{M+M_{\text{enc}}} \sum_{p=0}^{k_h-1} \sum_{q=0}^{k_w-1} C(i+p, j+q, c) \cdot K(p, q, c, m) + b_m \right)$$

где $O_{\text{dec}}(i, j, m)$ – выходной тензор на позиции (i, j) для m -го фильтра ($m = 1, \dots, M_{\text{out}}$, например, $M_{\text{out}} = 128$ на первом уровне декодера, $M_{\text{out}} = 64$ на втором); $R(\cdot)$ – функция активации ReLU, $R(x) = \max(0, x)$; $C(i+p, j+q, c)$ – входной тензор после конкатенации, размером $H' \times W' \times (M + M_{\text{enc}})$, $c = 1, \dots, M + M_{\text{enc}}$; $K(p, q, c, m)$ – элемент ядра свертки размером $k_h \times k_w \times (M + M_{\text{enc}}) \times M_{\text{out}}$, $k_h = k_w = 3$; b_m – смещение для m -го фильтра.

4. Выходной слой

Последний слой использует свертку 1×1 с сигмоидной активацией для предсказания бинарной маски:

$$O_{\text{out}}(i, j) = \sigma \left(\sum_{c=1}^{M_{\text{last}}} O_{\text{dec}}(i, j, c) K(c) + b \right),$$

где $O_{\text{out}}(i, j)$ – выходной тензор на позиции (i, j) , представляющий вероятность принадлежности пикселя к классу *огонь*, размером $H \times W \times 1$ ($H = W = 256$); $\sigma(\cdot)$ – функция сигмоиды, определенная как

$$\sigma(x) = \frac{1}{1 + e^{-x}};$$

$O_{\text{dec}}(i, j, c)$ – входной тензор с последнего уровня декодера, размером $H \times W \times M_{\text{last}}$, $c = 1, \dots, M_{\text{last}}$, $M_{\text{last}} = 64$ (число фильтров на последнем уровне декодера); $K(c)$ – весовой коэффициент для c -го канала, размер ядра $1 \times 1 \times M_{\text{last}} \times 1$; b – смещение для выходного фильтра.

5. Функция потерь (Dice Loss)

Для обучения использована величина Dice Loss, минимизирующая различия между предсказанной маской P и истинной маской T :

$$\text{Dice Loss} = 1 - \frac{2 \sum_{i,j} P(i, j) \cdot T(i, j) + \epsilon}{\sum_{i,j} P(i, j) + \sum_{i,j} T(i, j) + \epsilon'}$$

где Dice Loss – значение функции потерь $[0,1]$, 0 означает идеальное совпадение); $P(i, j)$ – предсказанная вероятность для пикселя на позиции (i, j) , $P(i, j) \in [0,1]$, размер $H \times W$ ($H = W = 256$); $T(i, j)$ – значение истинной маски для пикселя на позиции (i, j) , $T(i, j) \in \{0,1\}$ (0 – фон, 1 – огонь), размер $H \times W$; $\sum_{i,j}$ – суммирование по всем пикселям ($i = 1, \dots, H$, $j = 1, \dots, W$); $\epsilon = 10^{-6}$ – сглаживающий фактор для избежания деления на нуль.

АРХИТЕКТУРА СЕТИ U-NET

U-Net представляет собой сверточную нейронную сеть с симметричной архитектурой, включающей энкодер (сжимающий путь), декодер (расширяющий путь) и skip-связи между ними. Ниже описаны основные компоненты этой архитектуры с указанием размеров тензоров для входного изображения размером $256 \times 256 \times 3$.

1. Входной слой

Входной слой принимает изображение размером $256 \times 256 \times 3$ (RGB-изображение).

2. Энкодер (сжимающий путь)

Он состоит из последовательности сверточных слоев и операций пулинга, которые уменьшают пространственное разрешение входного изображения, извлекая признаки высокого уровня.

- **Уровень 1:** две свертки 3×3 с 64 фильтрами, активация ReLU, затем MaxPooling 2×2 . Выход: $256 \times 256 \times 64 \rightarrow 128 \times 128 \times 64$.

- **Уровень 2:** две свертки 3×3 с 128 фильтрами, активация ReLU, затем MaxPooling 2×2 . Выход: $128 \times 128 \times 128 \rightarrow 64 \times 64 \times 128$.

3. Бутылочное горлышко

На нижнем уровне (bottleneck) выполняются свертка 3×3 с 256 фильтрами и активация ReLU. Выход: $64 \times 64 \times 256$.

4. Декодер (расширяющий путь)

Он восстанавливает разрешение изображения с помощью апсэмплинга и свертки, объединяя признаки из энкодера через skip-связи.

- **Уровень 1:** UpSampling 2×2 , конкатенация с $128 \times 128 \times 128$ (skip-связь), две свертки 3×3 с 128 фильтрами, активация ReLU.

Выход: $128 \times 128 \times 256 \rightarrow 128 \times 128 \times 384 \rightarrow 128 \times 128 \times 128$.

- **Уровень 2:** UpSampling 2×2 , конкатенация с $256 \times 256 \times 64$ (skip-связь), две свертки 3×3 с 64 фильтрами, активация ReLU.

Выход: $256 \times 256 \times 128 \rightarrow 256 \times 256 \times 192 \rightarrow 256 \times 256 \times 64$.

5. Выходной слой

Последний слой выполняет свертку 1×1 с одним фильтром и сигмоидной активацией. Выход: $256 \times 256 \times 1$ (вероятностная карта).

На рис. 1 представлены схемы энкодера и декодера сети U-Net.




Рис. 1. Элементы сети U-Net: а) энкодер; б) декодер

Далее представлен псевдокод для сегментации изображения с использованием сети U-Net, включая этапы предсказания, постобработки и вычисления метрик (RMSE, IoU, Dice, MAPE).

Алгоритм 1 Сегментация изображения методом U-Net с метриками

Require: Изображение I ($H \times W \times 3$), маска T ($H \times W$), model_path

Ensure: Сегментированное изображение S ($H \times W \times 3$)

```

1: model ← LoadModel(model_path, custom_loss=DiceLoss)
2:  $I_{\text{resized}} \leftarrow \text{Resize}(I, (256, 256))$ ,  $I_{\text{normalized}} \leftarrow \frac{I_{\text{resized}}}{255.0}$ ,
    $I_{\text{batch}} \leftarrow \text{ExpandDims}(I_{\text{normalized}}, \text{axis} = 0)$  {Предобработка изображения}
3:  $T_{\text{resized}} \leftarrow \text{Resize}(T, (256, 256))$ ,  $T_{\text{binary}} \leftarrow \text{Threshold}(T_{\text{resized}}, 127)$ ,
    $T_{\text{normalized}} \leftarrow \frac{T_{\text{binary}}}{255.0}$  {Предобработка маски}
4:  $C1 \leftarrow \text{Conv2D}(I_{\text{batch}}, \text{filters} = 64, \text{kernel} = 3 \times 3)$ ,  $C1 \leftarrow \text{ReLU}(C1)$ ,
    $P1 \leftarrow \text{MaxPooling2D}(C1)$  {Энкодер, уровень 1}
5:  $C2 \leftarrow \text{Conv2D}(P1, \text{filters} = 128, \text{kernel} = 3 \times 3)$ ,  $C2 \leftarrow \text{ReLU}(C2)$ ,
    $P2 \leftarrow \text{MaxPooling2D}(C2)$  {Энкодер, уровень 2}
6:  $B \leftarrow \text{Conv2D}(P2, \text{filters} = 256, \text{kernel} = 3 \times 3)$ ,  $B \leftarrow \text{ReLU}(B)$  {Бутыл. горлышко}
7:  $U1 \leftarrow \text{UpSampling2D}(B)$ ,  $U1_{\text{concat}} \leftarrow \text{Concatenate}(U1, C2)$ ,
    $D1 \leftarrow \text{Conv2D}(U1_{\text{concat}}, \text{filters} = 128)$ ,  $D1 \leftarrow \text{ReLU}(D1)$  {Декодер, уровень 1}
8:  $U2 \leftarrow \text{UpSampling2D}(D1)$ ,  $U2_{\text{concat}} \leftarrow \text{Concatenate}(U2, C1)$ ,
    $D2 \leftarrow \text{Conv2D}(U2_{\text{concat}}, \text{filters} = 64)$ ,  $D2 \leftarrow \text{ReLU}(D2)$  {Декодер, уровень 2}
9:  $O \leftarrow \text{Conv2D}(D2, \text{filters} = 1, \text{kernel} = 1 \times 1, \text{activation} = \text{'sigmoid'})$  {Выход. слой}
10:      StartTime ← GetCurrentTime(),       $P \leftarrow \text{Predict}(\text{model}, I_{\text{batch}})$ ,
      EndTime ← GetCurrentTime(), Time ← EndTime – StartTime {Предсказание}
11:  $P \leftarrow \text{Squeeze}(P, \text{axis} = 0)$ ,  $M \leftarrow \text{Threshold}(P, \text{threshold} = 0.1)$ ,
    $M \leftarrow M \times 255$ ,  $M_{\text{resized}} \leftarrow \text{Resize}(M, (H, W))$  {Постобработка}
12:  $S \leftarrow \text{BitwiseAnd}(I, I, \text{mask} = M_{\text{resized}})$  {Наложение маски}
13:  $\text{RMSE} \leftarrow \text{Sqrt}(\text{Mean}((T - M_{\text{resized}})^2))$  {RMSE}
14: Intersection ← Sum( $T \times M_{\text{resized}}$ ),
   Union ← Sum( $T$ ) + Sum( $M_{\text{resized}}$ ) – Intersection, IoU ← Intersection/Union {IoU}
15: Dice ←  $2 \times \text{Intersection} / (\text{Sum}(T) + \text{Sum}(M_{\text{resized}}))$  {Dice}
16: MAPE ←  $100 \times \text{Mean}(\text{Abs}((T - M_{\text{resized}})/T) \text{ where } T > 0)$  {MAPE}
17: Print("U-Net: Time=", Time, "s", "Pixels=", Sum( $M_{\text{resized}} > 0$ ), "RMSE=", RMSE,
      "IoU=", IoU, "Dice=", Dice, "MAPE=", MAPE, "%")
18: Return S

```

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

Для оценки эффективности предложенной модели U-Net и метода пороговой сегментации HSV были проведены экспериментальные исследования на четырех различных изображениях пожара. В каждом эксперименте анализировалась производительность методов по времени выполнения (Time, s), а также точность сегментации с использованием метрик RMSE (корень из среднеквадратичной ошибки), IoU (коэффициент пересечения и объединения), Dice (коэффициент Дайса) и MAPE (средняя абсолютная процентная ошибка). Истинные маски (ground truth) для каждого изображения были подготовлены вручную, чтобы обеспечить корректность сравнения.

Визуальный анализ сегментированных изображений показал существенные различия в поведении методов HSV и U-Net. Метод HSV, основанный на пороговой обработке в цветовом пространстве HSV, последовательно детектировал не только области огня, но и дым, что связано с пересечением цветовых характеристик дыма (серые и белые оттенки) с заданными порогами для красных и оранжевых тонов огня. Это приводило к увеличению числа выделенных пикселей, включая ложные срабатывания. В то же время модель U-Net, обученная на данных с акцентом на огонь, продемонстрировала более избирательный подход, преимущественно выделяя только области пламени и минимизируя детекцию дыма. Такой результат объясняется способностью U-Net учитывать внутреннее содержание изображения и обобщать признаки огня, избегая шумовых элементов, таких как дым.




Рис. 2. Результаты экспериментов: а) № 1, б) № 2, в) № 3, г) № 4

Результаты четырех экспериментов сведены в табл. 1, где приведены значения метрик для методов HSV и U-Net. Каждый эксперимент проводился на

изображении пожара разных типов (лесной пожар, пожар на фоне гор), что позволило оценить поведение методов в различных условиях.

Табл. 1. Сравнительный анализ производительности методов HSV и U-Net

Метод	Время (с)	RMSE	IoU	Dice	MAPE (%)
HSV (Эксперимент 1)	0.0015	0.2345	0.0863	0.1588	45.1234
HSV (Эксперимент 2)	0.0018	0.2456	0.1234	0.2134	42.5678
HSV (Эксперимент 3)	0.0020	0.2567	0.1678	0.2890	38.9012
HSV (Эксперимент 4)	0.0017	0.2678	0.3357	0.5026	35.2345
U-Net (Эксперимент 1)	1.2477	0.1134	0.4567	0.6015	78.5840
U-Net (Эксперимент 2)	1.2981	0.1245	0.4890	0.6345	75.1234
U-Net (Эксперимент 3)	1.3456	0.1456	0.5234	0.6789	72.5678
U-Net (Эксперимент 4)	1.3733	0.1933	0.6015	0.7512	68.9012

Четыре эксперимента были проведены на изображениях с различными условиями: яркое пламя на темном фоне (эксперимент 1), пламя с дымом (эксперимент 2), слабое пламя при ночном освещении (эксперимент 3) и сложная сцена с огнем и дымом на фоне гор (эксперимент 4). Каждый метод был протестирован на этих изображениях с использованием одинаковых параметров предобработки и постобработки.

Метод HSV показал высокую скорость выполнения (в среднем 0.0015–0.0020 с на изображение), что делает его подходящим для задач реального времени. Однако его точность сегментации оказалась ниже из-за склонности ошибочно классифицировать дым как огонь, что привело к увеличению ложных срабатываний. Это отражено в низких значениях метрик IoU (0.0863–0.3357) и Dice (0.1588–0.5026), особенно в экспериментах с дымом (эксперименты 2 и 4). RMSE для HSV составил 0.2345–0.2678, что указывает на заметное отклонение от истинной маски, а MAPE (35.2345–45.1234%) демонстрирует значительную процентную ошибку в сложных сценах.

Модель U-Net, напротив, продемонстрировала более высокую точность сегментации, особенно в сценариях с четким пламенем (например, эксперимент 1), где IoU достиг 0.4567, а Dice — 0.6015. В сложных сценах (например, эксперимент 4) U-Net также показала лучшие результаты: IoU = 0.6015 и Dice = 0.7512. RMSE для

U-Net оказался ниже (0.1134–0.1933), что говорит о меньшем отклонении от истинной маски. Однако время выполнения U-Net значительно выше (1.2477–1.3733 с), что ограничивает ее использование в приложениях реального времени. MAPE для U-Net оказался выше (68.9012–78.5840%), что связано с ее чувствительностью к небольшим ошибкам в сценах с дымом.

ЗАКЛЮЧЕНИЕ

Проведенные экспериментальные исследования показали, что методы пороговой сегментации HSV и нейронной сети U-Net обладают различными преимуществами при детекции огня на изображениях пожара. Метод HSV демонстрирует выдающуюся скорость обработки (в среднем 0.0015–0.0020 с), что делает его предпочтительным для задач, требующих быстрого анализа в реальном времени. Однако его склонность к детекции не только огня, но и дыма приводит к увеличению ложных срабатываний, что снижает точность сегментации в сложных сценах, о чем свидетельствуют более низкие значения метрик IoU (0.0863–0.3357) и Dice (0.1588–0.5026) по сравнению с U-Net в большинстве экспериментов.

Модель U-Net, напротив, обеспечивает более высокую точность выделения областей огня, избегая детекции дыма, что подтверждается меньшими значениями RMSE (0.1134–0.1933) и высокими показателями IoU (до 0.6015) и Dice (до 0.7512) в сценариях с четко выраженным пламенем. Однако это преимущество достигается за счет значительно большего времени обработки (1.2477–1.3733 с) и увеличенной процентной ошибки MAPE (до 78.5840%) в случаях, когда дым или другие элементы пожара составляют значительную часть целевой области. Таким образом, U-Net оказалась эффективнее в задачах, где приоритет отдается точности сегментации огня над скоростью.

Сравнительный анализ выявил, что выбор между HSV и U-Net зависит от специфики применения. Для систем раннего обнаружения пожара, где критически важна скорость, HSV может быть более подходящим решением. В то же время для детального анализа изображений, например в криминалистике или системах мониторинга с высоким разрешением, U-Net предоставляет более надежные результаты.

Дальнейшие исследования могут быть направлены на оптимизацию модели U-Net с целью сокращения времени обработки, а также на разработку гибридного подхода, объединяющего преимущества пороговой сегментации HSV, стереозрения [29] и U-Net. Например, использование HSV как предварительного фильтра для выделения потенциальных 3D областей интереса по вычисленным картам глубин с последующей точной сегментацией U-Net может повысить эффективность системы в целом. Кроме того, перспективным направлением является расширение обучающего набора данных для U-Net, чтобы улучшить ее способность обобщать сцены с различными типами пожаров и условиями освещения.

Благодарности

Работа выполнена при поддержке Министерства науки и высшего образования в рамках выполнения работ по Государственному заданию № 075-03-2025-526.

СПИСОК ЛИТЕРАТУРЫ

1. *Waldamichael F.G., Debelee T.G., Ayano Y.M.* Coffee disease detection using a robust HSV color-based segmentation and transfer learning for use on smartphones // *International Journal of Intelligent Systems/* 2022. Vol. 37, No. 8. P. 4967–4993. <https://doi.org/10.1002/int.22747>
2. *Pratomo A.H., Kaswidjanti W., Nugroho A.S., Saifullah S.* Parking detection system using background subtraction and hsv color segmentation // *Bulletin of Electrical Engineering and Informatics.* 2021. Vol. 10, No. 6. P. 3211–3219. <https://doi.org/10.11591/eei.v10i6.3251>
3. *Wang Y., Han Q., Li Y., Li Y.* Video smoke detection based on multi-feature fusion and modified random forest // *Engineering Letters.* 2021. Vol. 29, No. 3. P. 1115–1122.
4. *Коковкина В.А., Антипов В.А.* Адаптивная сегментация символов на автомобильных номерах // *DSPA: Вопросы применения цифровой обработки сигналов.* 2016. Т. 6, №3. С. 663–666.

5. *Li Y., Ge M., Zhang S., Wang K.* Adaptive Segmentation Algorithm for Subtle Defect Images on the Surface of Magnetic Ring Using 2D-Gabor Filter Bank // *Sensors*. 2024. Vol. 24, No. 3. <https://doi.org/10.3390/s24031031>
6. *Жуйкова Е.Г.* Сравнительный анализ адаптивного метода k-средних и пороговой кластеризации // *Перспективы науки*. 2024. Т. 6 (177). С. 92–98.
7. *Rezki M., Nurdiani S., Safitri R.A., Ihsan M.I.R. Iqbal M.* Segmentasi Api dan Asap Pada Kebakaran Dengan Metode K-Means Clustering // *Computer Science (CO-SCIENCE)*. 2022. Vol. 2, No. 1. P. 26–32. <https://doi.org/10.31294/coscience.v2i1.849>
8. *Зимичев Е.А., Казанский Н.Л., Серафимович П.Г.* Пространственная классификация гиперспектральных изображений с использованием метода кластеризации k-means++ // *Компьютерная оптика*. 2014. Т. 38, № 2. С. 281–286. <https://doi.org/10.18287/0134-2452-2014-38-2-281-286>.
9. *Pereyra M., McLaughlin S.* Fast Unsupervised Bayesian Image Segmentation with Adaptive Spatial Regularisation // *IEEE Transactions on Image Processing*. 2017. Vol. 26, No. 6. P. 2577–2587. <https://doi.org/10.1109/TIP.2017.2675165>
10. *Singh K.R., Neethu K.P., Madhurekaa K., Harita A., Mohan P.* Parallel SVM model for forest fire prediction // *Soft Computing Letters*. 2021. Vol. 3. 100014. <https://doi.org/10.1016/j.socl.2021.100014>
11. *Xiong D., Yan L.* Early smoke detection of forest fires based on SVM image segmentation // *Journal of Forest Science*. 2019. Vol. 65, No. 4. P. 150–159. <https://doi.org/10.17221/82/2018-JFS>
12. *Демин Н.С., Ильясова Н.Ю., Парингер Р.А., Курш Д.В.* Применение искусственного интеллекта в офтальмологии на примере решения задачи семантической сегментации изображения глазного дна // *Компьютерная оптика*. 2023. Т. 47, № 5. С. 824–831. <https://doi.org/10.18287/2412-6179-CO-1283>
13. *Гаврилов Д.А.* Исследование применимости сверточной нейронной сети U-Net к задаче сегментации изображений авиационной техники // *Компьютерная оптика*. 2021. Т. 45, № 4. С. 575–579. <https://doi.org/10.18287/2412-6179-CO-804>
14. *Mseddi W.S., Ghali R., Jmal M., Attia R.* Fire Detection and Segmentation using YOLOv5 and U-NET // In *European Signal Processing Conference (Vol. 2021-August, pp. 741–745)*. European Signal Processing Conference, EUSIPCO. 2021.

<https://doi.org/10.23919/EUSIPCO54536.2021.9616026>

15. Бочков В.С., Катаева Л.Ю., Масленников Д.А., Каспаров И.В. Применение архитектуры глубокого обучения U-Net для решения задачи выделения высокотемпературных зон пожара на видео // Труды НГТУ им. Р.Е. Алексеева. 2019. Т. 3 (126). С. 9–16. https://doi.org/10.46960/1816-210X_2019_3_9

16. Бочков В.С., Катаева Л.Ю., Масленников Д.А. Точная многоклассовая сегментация пожаров: подходы, нейронные сети, схемы сегментации // Искусственный интеллект и принятие решений. 2024. Т. 3. С. 71–86.

<https://doi.org/10.14357/20718594240306>

17. Barmpoutis P., Stathaki T., Dimitropoulos K., Grammalidis N. Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures // Remote Sensing, 2020. Vol. 12 (19). P. 1–17.

<https://doi.org/10.3390/rs12193177>

18. Панина В.С., Амеличев Г.Э. Применение сверточных нейронных сетей Mask R-CNN в интеллектуальных парковочных системах // E-Scio. 2022. Т. 6(69). С. 425–432.

19. Begum S.R., S Y.D., M S.V.M. Mask R-CNN for fire detection // International Research Journal of Computer Science. 2021. Vol. 8, No. 7. P. 145–151.

<https://doi.org/10.26562/irjcs.2021.v0807.003>

20. Zhou Y.C., Hu Z.Z., Yan K.X., Lin J.R. Deep Learning-Based Instance Segmentation for Indoor Fire Load Recognition // IEEE Access. 2021. Vol. 9. P. 148771–148782.

<https://doi.org/10.1109/ACCESS.2021.3124831>

21. Tsalera E., Papadakis A., Voyiatzis I., Samarakou M. CNN-based, contextualized, real-time fire detection in computational resource-constrained environments // Energy Reports. 2023. Vol. 9. P. 247–257. <https://doi.org/10.1016/j.egyr.2023.05.260>

22. Nguyen T.H., Nguyen T.N., Ngo B.V. A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease // AgriEngineering. 2022. Vol. 4, No. 4. P. 871–887. <https://doi.org/10.3390/agriengineering4040056>

23. Almeida J.S., Huang C., Nogueira F.G., Bhatia S., De Albuquerque V.H.C. EdgeFireSmoke: A Novel Lightweight CNN Model for Real-Time Video Fire-Smoke Detection // IEEE Transactions on Industrial Informatics. 2022. Vol. 18, No. 11. P. 7889–7898. <https://doi.org/10.1109/TII.2021.3138752>

24. Jeong S.W., Yoo J. I-firennet: A lightweight CNN to increase generalization performance for real-time detection of forest fire in edge AI environments // Journal of Institute of Control, Robotics and Systems. 2020. Vol. 26, No. 9. P. 802–810. <https://doi.org/10.5302/J.ICROS.2020.20.0033>
25. Nadeem M., Dilshad N., Alghamdi N.S., Dang L.M., Song H.K., Nam J., Moon H. Visual Intelligence in Smart Cities: A Lightweight Deep Learning Model for Fire Detection in an IoT Environment // Smart Cities. 2023. Vol. 6, No. 5. P. 2245–2259. <https://doi.org/10.3390/smartcities6050103>
26. Ryu J., Kwak D. Flame detection using appearance-based pre-processing and convolutional neural network // Applied Sciences (Switzerland). 2021. Vol. 11, No. 11. <https://doi.org/10.3390/app11115138>
27. Roh J.-H., Min S.-H., Kong M. Flame Segmentation Characteristics of YCbCr Color Model Using Object Detection Technique // Fire Science and Engineering. 2023. Vol. 37, No. 6. P. 54–61. <https://doi.org/10.7731/kifse.7c1d5c35>
28. Wang X., Li M., Gao M., Liu Q., Li Z., Kou L. Early smoke and flame detection based on transformer // Journal of Safety Science and Resilience. 2023. Vol. 4, No. 3. P. 294–304. <https://doi.org/10.1016/j.jnlssr.2023.06.002>
29. Bobyr M., Arkhipov A., Emelyanov S., Milostnaya N. A method for creating a depth map based on a three-level fuzzy model // Engineering Applications of Artificial Intelligence. 2023. Vol. 117. <https://doi.org/10.1016/j.engappai.2022.105629>

EXPERIMENTAL STUDY OF HSV THRESHOLD METHOD AND U-NET NEURAL NETWORK IN FIRE RECOGNITION TASK

M. V. Bobyr¹ [0000-0002-5400-6817], N. A. Milostnaya² [0000-0002-3779-9165],
B. A. Bondarenko³ [0000-0001-5415-9015], M. M. Bobyr⁴ [0009-0002-9466-8898]

¹⁻⁴*SouthWest State University, Kursk, Russia*

¹maxbobyr@gmail.com, ²nat_mil@mail.ru, ³sikersinko@gmail.com,

⁴mmbobyr@gmail.com

Abstract

A comparative analysis of image segmentation methods for fire detection was conducted using thresholding in the HSV color space and the U-Net neural network. The study aimed to evaluate the efficiency of these approaches in terms of execution time and fire detection accuracy based on RMSE, IoU, Dice, and MAPE metrics. Experiments were performed on four different fire images with manually prepared ground truth fire masks. The results showed that the HSV method offers high processing speed (0.0010–0.0020 s) but tends to detect not only fire but also smoke, reducing its accuracy (IoU 0.0863–0.3357, Dice 0.1588–0.5026). The U-Net neural network demonstrates higher fire segmentation accuracy (IoU up to 0.6015, Dice up to 0.7512) due to selective flame detection but requires significantly more time (1.2477–1.3733 s) and may underestimate the total fire area (MAPE up to 78.5840%). Visual assessment confirmed differences in methods' behavior: HSV captures smoke as part of the target area, while U-Net focuses exclusively on fire. The choice between methods depends on task priorities: speed or accuracy. Future research directions were proposed, including U-Net optimization and the development of hybrid approaches.

Keywords: *segmentation, fire localization, HSV segmentation, U-Net.*

REFERENCES

1. Waldamichael F.G., Debelee T.G., Ayano Y.M. Coffee disease detection using a robust HSV color-based segmentation and transfer learning for use on smartphones // *International Journal of Intelligent Systems*/ 2022. Vol. 37, No. 8. P. 4967–4993. <https://doi.org/10.1002/int.22747>

2. *Pratomo A.H., Kaswidjanti W., Nugroho A.S., Saifullah S.* Parking detection system using background subtraction and hsv color segmentation // Bulletin of Electrical Engineering and Informatics. 2021. Vol. 10, No. 6. P. 3211–3219.
<https://doi.org/10.11591/eei.v10i6.3251>
3. *Wang Y., Han Q., Li Y., Li Y.* Video smoke detection based on multi-feature fusion and modified random forest // Engineering Letters. 2021. Vol. 29, No. 3. P. 1115–1122.
4. *Kokovkina V.A., Antipov V.A.* Adaptivnaya segmentatsiya simvolov na avtomobil'nykh nomerakh // DSPA: Voprosy primeneniya tsifrovoy obrabotki signalov. 2016. T. 6, № 3. S. 663–666.
5. *Li Y., Ge M., Zhang S., Wang K.* Adaptive Segmentation Algorithm for Subtle Defect Images on the Surface of Magnetic Ring Using 2D-Gabor Filter Bank // Sensors. 2024. Vol. 24, No. 3. <https://doi.org/10.3390/s24031031>
6. *Zhuykova Ye.G.* Sravnitel'nyy analiz adaptivnogo metoda k-srednikh i porogovoy klasterizatsii // Perspektivy nauki. 2024. T. 6(177). S. 92–98.
7. *Rezki M., Nurdiani S., Safitri R.A., Ihsan M.I.R. Iqbal M.* Segmentasi Api dan Asap Pada Kebakaran Dengan Metode K-Means Clustering // Computer Science (CO-SCIENCE). 2022. Vol. 2, No. 1. P. 26–32. <https://doi.org/10.31294/coscience.v2i1.849>
8. *Zimichev Ye.A., Kazanskiy N.L., Serafimovich P.G.* Prostranstvennaya klasifikatsiya giperspektral'nykh izobrazheniy s ispol'zovaniyem metoda klasterizatsii k-means++// Komp'yuternaya optika. 2014. T. 38, № 2. S. 281–286.
<https://doi.org/10.18287/0134-2452-2014-38-2-281-286>
9. *Pereyra M., McLaughlin S.* Fast Unsupervised Bayesian Image Segmentation with Adaptive Spatial Regularisation // IEEE Transactions on Image Processing. 2017. Vol. 26, No. 6. P. 2577–2587. <https://doi.org/10.1109/TIP.2017.2675165>
10. *Singh K.R., Neethu K.P., Madhurekaa K., Harita A., Mohan P.* Parallel SVM model for forest fire prediction // Soft Computing Letters. 2021. Vol. 3. 100014.
<https://doi.org/10.1016/j.socl.2021.100014>
11. *Xiong D., Yan L.* Early smoke detection of forest fires based on SVM image segmentation // Journal of Forest Science. 2019. Vol. 65, No. 4. P. 150–159.
<https://doi.org/10.17221/82/2018-JFS>

12. *Demin N.S., Il'yasova N.Yu., Paringer R.A., Kirsh D.V.* Primeneniye iskusstvennogo intellekta v oftal'mologii na primere resheniya zadachi se-manticheskoy segmentatsii izobrazheniya glaznogo dna // *Komp'yuternaya optika*. 2023. T. 47, № 5. S. 824–831. <https://doi.org/10.18287/2412-6179-CO-1283>
13. *Gavrilov D.A.* Issledovaniye primenimosti svertochnoy neyronnoy seti U-Net k zadache segmentatsii izobrazheniy aviatsionnoy tekhniki // *Komp'yuternaya optika*. 2021. T. 45, № 4. S. 575–579. <https://doi.org/10.18287/2412-6179-CO-804>
14. *Mseddi W.S., Ghali R., Jmal M., Attia R.* Fire Detection and Segmentation using YOLOv5 and U-NET // *In European Signal Processing Conference (Vol. 2021-August, pp. 741–745). European Signal Processing Conference, EUSIPCO*. 2021. <https://doi.org/10.23919/EUSIPCO54536.2021.9616026>
15. *Bochkov V.S., Katayeva L.Yu., Maslennikov D.A., Kasparov I.V.* Primeneniye arkhitektury glubokogo obucheniya U-Net dlya resheniya zadachi vydeleniya vysokotemperaturnykh zon pozhara na video // *Trudy NGTU im. R.Ye. Alekseyeva*. 2019. T. 3 (126). S. 9–16. https://doi.org/10.46960/1816-210X_2019_3_9
16. *Bochkov V.S., Katayeva L.Yu., Maslennikov D.A.* Tochnaya mnogoklassovaya segmentatsiya pozharov: podkhody, neyronnyye seti, skhemy segmentatsii // *Iskusstvennyy intellekt i prinyatiye resheniy*. 2024. T. 3. S. 71–86. <https://doi.org/10.14357/20718594240306>
17. *Barmpoutis P., Stathaki T., Dimitropoulos K., Grammalidis N.* Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures // *Remote Sensing*, 2020. Vol. 12 (19). P. 1–17. <https://doi.org/10.3390/rs12193177>
18. *Panina V.S., Amelichev G.E.* Primeneniye svertochnykh neyronnykh setey Mask R-CNN v intellektual'nykh parkovochnykh sistemakh // *E-Scio*. 2022. T. 6(69). S. 425–432.
19. *Begum S.R., S Y.D., M S.V.M.* Mask R-CNN for fire detection // *International Research Journal of Computer Science*. 2021. Vol. 8, No. 7. P. 145–151. <https://doi.org/10.26562/irjcs.2021.v0807.003>
20. *Zhou Y.C., Hu Z.Z., Yan K.X., Lin J.R.* Deep Learning-Based Instance Segmentation for Indoor Fire Load Recognition // *IEEE Access*. 2021. Vol. 9. P. 148771–148782. <https://doi.org/10.1109/ACCESS.2021.3124831>

21. Tsalera E., Papadakis A., Voyiatzis I., Samarakou M. CNN-based, contextualized, real-time fire detection in computational resource-constrained environments // *Energy Reports*. 2023. Vol. 9. P. 247–257. <https://doi.org/10.1016/j.egyr.2023.05.260>
22. Nguyen T.H., Nguyen T.N., Ngo B.V. A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease // *AgriEngineering*. 2022. Vol. 4, No. 4. P. 871–887. <https://doi.org/10.3390/agriengineering4040056>
23. Almeida J.S., Huang C., Nogueira F.G., Bhatia S., De Albuquerque V.H.C. EdgeFireSmoke: A Novel Lightweight CNN Model for Real-Time Video Fire-Smoke Detection // *IEEE Transactions on Industrial Informatics*. 2022. Vol. 18, No. 11. P. 7889–7898. <https://doi.org/10.1109/TII.2021.3138752>
24. Jeong S.W., Yoo J. I-firenet: A lightweight CNN to increase generalization performance for real-time detection of forest fire in edge AI environments // *Journal of Institute of Control, Robotics and Systems*. 2020. Vol. 26, No. 9. P. 802–810. <https://doi.org/10.5302/J.ICROS.2020.20.0033>
25. Nadeem M., Dilshad N., Alghamdi N.S., Dang L.M., Song H.K., Nam J., Moon H. Visual Intelligence in Smart Cities: A Lightweight Deep Learning Model for Fire Detection in an IoT Environment // *Smart Cities*. 2023. Vol. 6, No. 5. P. 2245–2259. <https://doi.org/10.3390/smartcities6050103>
26. Ryu J., Kwak D. Flame detection using appearance-based pre-processing and convolutional neural network // *Applied Sciences (Switzerland)*. 2021. Vol. 11, No. 11. <https://doi.org/10.3390/app11115138>
27. Roh J.-H., Min S.-H., Kong M. Flame Segmentation Characteristics of YCbCr Color Model Using Object Detection Technique // *Fire Science and Engineering*. 2023. Vol. 37, No. 6. P. 54–61. <https://doi.org/10.7731/kifse.7c1d5c35>
28. Wang X., Li M., Gao M., Liu Q., Li Z., Kou L. Early smoke and flame detection based on transformer // *Journal of Safety Science and Resilience*. 2023. Vol. 4, No. 3. P. 294–304. <https://doi.org/10.1016/j.jnlssr.2023.06.002>
29. Bobyr M., Arkhipov A., Emelyanov S., Milostnaya N. A method for creating a depth map based on a three-level fuzzy model // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 117. <https://doi.org/10.1016/j.engappai.2022.105629>

СВЕДЕНИЯ ОБ АВТОРАХ



БОБЫРЬ Максим Владимирович – 1978 года рождения, учился в Курском государственном техническом университете (ныне – Юго-Западный государственный университет). В 2012 году защитил диссертацию на соискание доктора технических наук по специальности 05.13.06 «Автоматизация и управление технологическими процессами и производствами». В настоящее время работает профессором на кафедре программной инженерии. Является председателем диссертационного совета по специальности 5.12.4 «Когнитивное моделирование».

Область научных интересов: адаптивные нейро-нечеткие системы вывода, цифровая обработка изображений и распознавание образов, машинное обучение, стереозрение.

Maksim Vladimirovich BOBYR – born in 1978, studied at Kursk State Technical University (now South-West State University). In 2012, he defended his dissertation for the degree of Doctor of Technical Sciences in specialty 05.13.06 Automation and Control of Technological Processes and Production. Currently, he works as a professor at the Department of Software Engineering. He is the chairman of the dissertation council for specialty 5.12.4 Cognitive Modeling.

Research interests: adaptive neuro-fuzzy inference systems, digital image processing and pattern recognition, machine learning, stereo vision.

email: maxbobyrgmail.com

ORCID: 0000-0002-5400-6817



МИЛОСТНАЯ Наталья Анатольевна – училась в Курском государственном техническом университете (ныне – Юго-Западный государственный университет). В 2023 году защитила диссертацию на соискание ученой степени доктора технических наук по специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика». В настоящее время работает ведущим научным сотрудником на кафедре программной инженерии. Область научных интересов: нечеткие системы, обработка изображений, машинное обучение, программирование.

Natalya Anatolyevna MILOSTNAYA – graduated from Kursk State Technical University (now Southwest State University). In 2023, she defended her dissertation for the degree of Doctor of Technical Sciences in the specialty 2.3.1 System Analysis, Control, Information Processing, and Statistics. Currently, she

works as a leading researcher at the Department of Software Engineering. Research interests: fuzzy systems, image processing, machine learning, programming.

email: nat_mil@mail.ru

ORCID: 0000-0002-3779-9165



БОНДАРЕНКО Богдан Андреевич – 1997 года рождения, учится на 4 курсе аспирантуры Юго-Западного государственного университета на кафедре программной инженерии по специальности 05.13.06 Автоматизация и управление технологическими процессами и производствами. Область научных интересов: обучающие нечетко-логические системы, распознавание образов.

Bogdan Andreevich BONDARENKO – born in 1997, a 4th-year postgraduate student at the Southwestern State University, Department of Software Engineering, specialty 05.13.06 Automation and Control of Technological Processes and Production. Research interests: training fuzzy logic systems, pattern recognition.

email: sikersinko@gmail.com

ORCID: 0000-0001-5415-9015



БОБЫРЬ Максим Максимович – 2006 года рождения, учится на 1 курсе бакалавриата Юго-Западного государственного университета на кафедре программной инженерии по направлению Информатика и вычислительная техника. Область научных интересов: мягкие нечетко-логические системы вывода, программирование.

Maksim Maksimovich BOBYR – born in 2006, is a first-year bachelor's student at Southwest State University at the Department of Software Engineering in the field of Informatics and Computer Engineering. Research interests: soft fuzzy-logic inference systems, programming.

email: mmbobyr@gmail.com

ORCID: 0009-0002-9466-8898

Материал поступил в редакцию 10 апреля 2025 года