



Онтологическая модель сегментации изображений пожаров с помощью адаптивной нейро-нечёткой сети

© 2026, М.В. Бобырь✉, Б.А. Бондаренко

Юго-Западный государственный университет (ЮЗГУ), Курск, Россия

Аннотация

Сегментация изображений пожаров является важной задачей для систем раннего обнаружения и мониторинга чрезвычайных ситуаций. Традиционные методы, такие как пороговая обработка и сложные вычислительные модели, имеют ограничения по скорости и точности в условиях реального времени. Цель исследования – обеспечение процесса сегментации изображений в режиме, близком к реальному времени. В статье представлена онтологическая модель сегментации изображений пожаров, основанная на адаптивной нейро-нечёткой системе с оптимизированным дефаззификатором метода отношения площадей. В модели структурируются процессы обработки данных, включая преобразование изображений в цветовое пространство оттенка, насыщенности и яркости, использование треугольных функций принадлежности и адаптивную настройку параметров для выделения очагов возгорания. В онтологии систематизированы классы, процессы и их взаимосвязи, обеспечивая модульность и гибкость решения. Эксперименты на изображениях ночных пожаров с дымом показали, что предложенная модель достигает высокой точности и скорости, превосходя сравниваемые методы сегментации, и содержит потенциал для применения в системах мониторинга в реальном времени.

Ключевые слова: онтология, нейро-нечёткий алгоритм, сегментация изображений, дефаззификация, искусственный интеллект.

Цитирование: Бобырь М.В., Бондаренко Б.А. Онтологическая модель сегментации изображений пожаров с помощью адаптивной нейро-нечёткой сети. *Онтология проектирования*. 2026. Т.16, №1(59). С.60-73. DOI:10.18287/2223-9537-2026-16-1-60-73.

Финансирование: работа выполнена при поддержке государственного задания №075-03-2025-526.

Вклад авторов: Бобырь М.В. – концепция нейро-нечёткой сети сегментации изображений; Бондаренко Б.А. – разработка онтологической модели сегментации изображений пожаров и проведение экспериментов.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Введение

Обнаружение и локализация пожаров – важнейшие задачи в области безопасности и мониторинга окружающей среды, особенно в условиях роста числа лесных пожаров и техногенных катастроф. Пожар, как сущность, обладает нечёткими, динамичными и контекстно-зависимыми свойствами и может быть смоделирована в рамках нечёткой онтологии, где границы объектов и принадлежность к классу градуальны, а не бинарны. Применяемые методы сегментации не эффективны в связи с высокой вариативностью и неопределённостью визуальных признаков пожара, а глубокие нейросети не обеспечивают интерпретируемости. Использование тепловых датчиков и визуального наблюдения [1] часто ограничено по скорости реакции и точности, особенно в сложных условиях, включая ночное время, сильный дым или горную местность [2]. Онтологии, как инструмент структурирования знаний, позволяют формализовать процессы и данные для анализа динамичных ситуаций. Разработка онтологий является трудной задачей для точной формализации сложной предметной области, при необ-

ходимости адаптации к реальным условиям и нехватке стандартизированных инструментов для объединения онтологий с вычислительными системами. Это затрудняет их практическое применение в задачах мониторинга пожаров и делает актуальным продолжение исследований. Развитие методов обработки изображений позволяет автоматизировать процесс обнаружения очагов возгорания через сегментацию изображений, обеспечивая оперативное выделение зон огня даже при ограниченной видимости [3, 4].

Исследования в области локализации пожаров активно развиваются. Например, в [5] предложено применение адаптивных нейро-нечётких систем вывода (*Adaptive Neuro-Fuzzy Inference System, ANFIS*) для моделирования процессов, связанных с пожарами, что может быть использовано для анализа распространения огня с высокой точностью. В [6] представлены мультимодальные наборы данных, включая изображения пожаров, для разработки моделей сегментации. В [7] описан метод анализа пожароопасных ситуаций с использованием сложных вычислительных моделей и отмечена их высокая вычислительная сложность. В [8] показана необходимость разработки методов с минимальной зависимостью от больших объёмов данных.

Современные вычислительные модели, такие как *U-Net* [9] и *Mask R-CNN* [10], показали высокую эффективность в задачах сегментации изображений пожаров [11, 12], но их применение ограничено необходимостью значительных вычислительных ресурсов и больших объёмов размеченных данных [13]. В [14] отмечается, что такие модели требуют десятков тысяч изображений для обучения, что затрудняет их использование в условиях реального времени. В [15] предлагаются гибридные подходы на основе генетических алгоритмов для оптимизации пороговой сегментации, которые сложны в настройке.

Пороговая сегментация в цветовом пространстве – тон, насыщенность, яркость (*Hue, Saturation, Brightness, HSV*) – простой и быстрый метод [16], однако его точность снижается при наличии дыма или переменного освещения. В [17] предложен подход с динамической адаптацией порогов *HSV* для обнаружения огня в условиях лесных пожаров, но он уступает по точности более сложным методам. Нейро-нечёткие системы (например, *ANFIS*) эффективно сочетают адаптивность и точность при меньшей зависимости от данных [18, 19].

В данной статье представлена онтологическая модель (ОМ) сегментации изображений пожаров, адаптированная для условий ночного освещения с дымом на фоне гор. Модель структурирует процессы обработки данных и включает преобразование изображений в цветовое пространство *HSV*, использование треугольных функций принадлежности и адаптивную настройку параметров для выделения очагов возгорания. В онтологии систематизированы классы, процессы и их взаимосвязи, обеспечивая модульность и гибкость решения. Исследования [20–24] подтверждают актуальность таких подходов для мониторинга пожаров и автоматизации анализа данных в чрезвычайных ситуациях.

1 Онтологическая модель сегментации

ОМ сегментации изображений (см. рисунок 1) представляет собой структурированное описание концепций, объектов, процессов и их взаимосвязей задаётся в виде кортежа:

$$O = \left\langle \begin{matrix} 7 & 6 & 9 & 5 \\ O_c & O_i & O_p & O_a \end{matrix} \right\rangle, \quad (1)$$

$$\left. \begin{matrix} k = 1 & a = 1 & d = 1 & x = 1 \end{matrix} \right\}$$

где O_c – ОМ классов объектов ($c = 1 \dots 7$, где c – количество классов объектов); O_i – ОМ изображения ($i = 1 \dots 6$, где i – количество подклассов изображения); O_p – ОМ процесса ($p = 1 \dots 9$, где p – количество подклассов процесса); O_a – ОМ атрибутов ($a = 1 \dots 5$, где a – количество атрибутов). Данные модели описаны в таблицах 1-4.

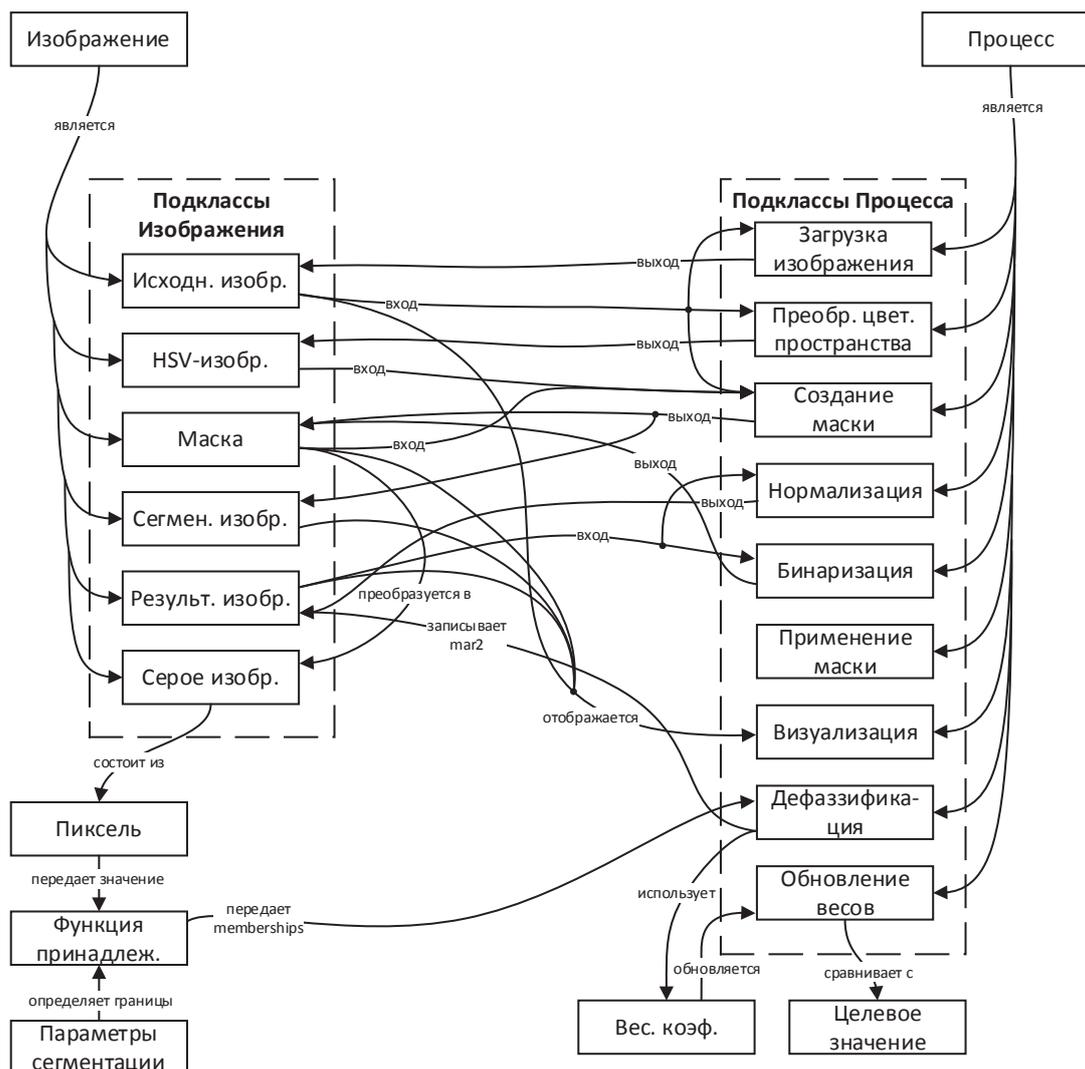


Рисунок 1 – Онтологическая модель сегментации изображений

Таблица 1 – Онтология классов модели сегментации изображений

| № | Онтология классов | | |
|----|------------------------|--|----------------------------------|
| | Название класса | Описание | Взаимосвязь |
| 1. | Изображение | Представляет входные и выходные изображения, с которыми работает программа. | Процесс, Пиксель |
| 2. | Пиксель | Элементарная единица изображения, характеризуется значением интенсивности (в RGB, HSV или градациях серого). | Функция принадлежности |
| 3. | Функция принадлежности | Математическая модель для оценки степени принадлежности пикселя к определённой категории (например, фон или вода). | Дефаззификация, Формула (1) |
| 4. | Параметры сегментации | Набор значений, определяющих границы для функций принадлежности (например, triangular_params) | Функция принадлежности |
| 5. | Весовой коэффициент | Адаптивный параметр, используемый для настройки дефаззификации | Дефаззификация, Обновление весов |
| 6. | Целевое значение | Значение (например, ytarget), к которому стремится результат сегментации | Обновление весов |
| 7. | Процесс | Операции, выполняемые программой для достижения цели сегментации | Изображение |

Таблица 2 – Онтология класса «Изображение» модели сегментации изображений

| № | Онтология изображения | | |
|----|------------------------------|--|---|
| | Название подкласса | Описание | Взаимосвязь |
| 1. | Исходное изображение | Цветное изображение, загружаемое из файла (<i>RGB</i>) | Загрузка изображения, Преобразование цветового пространства, Создание маски, Визуализация |
| 2. | <i>HSV</i> -изображение | Преобразованное изображение в цветовом пространстве <i>HSV</i> | Преобразование цветового пространства, Создание маски |
| 3. | Маска | Бинарное изображение, выделяющее объект (например, воду) | Создание маски, Бинаризация, Серое изображение, Визуализация |
| 4. | Сегментированное изображение | Результат применения маски к исходному изображению | Создание маски, Визуализация |
| 5. | Серое изображение | Промежуточное изображение в градациях серого | Пиксель, Маска |
| 6. | Результирующее изображение | Выходное изображение после дефаззификации | Нормализация, Дефаззификация, Бинаризация, Визуализация |

Таблица 3 – Онтология класса «Процесс» модели сегментации изображений

| № | Онтология процессов | | |
|----|---------------------------------------|--|-------------------------------------|
| | Название подкласса | Описание | Взаимосвязь |
| 1. | Загрузка изображения | Отвечает за чтение исходного изображения из файла в память программы. Вход: путь к файлу (<i>image_path</i>). Выход: объект <i>OriginalImage</i> . | Функция <i>Load Image</i> |
| 2. | Преобразование цветового пространства | Преобразует изображение из цветового пространства <i>RGB</i> в <i>HSV</i> для упрощения анализа цветов. Вход: <i>OriginalImage</i> . Выход: <i>HSVImage</i> . | Функция <i>Convert</i> |
| 3. | Создание маски | Создаёт начальную бинарную маску для выделения объекта (например, воды) на основе цветовых диапазонов. Вход: <i>HSVImage</i> , границы цвета (<i>lower_blue</i> , <i>upper_blue</i>). Выход: <i>Mask</i> . | Функция <i>Create Mask</i> |
| 4. | Дефаззификация | Преобразует нечёткие значения принадлежности пикселей в чёткие значения интенсивности. Вход: список <i>memberships</i> , <i>learn1</i> , границы (<i>ymin</i> , <i>ymax</i>). Выход: результирующее значение <i>mar1</i> . | Формула (2), функция <i>defuzzy</i> |
| 5. | Обновление весов | Адаптивно корректирует весовой коэффициент <i>learn1</i> на основе ошибки между результатом дефаззификации и целевым значением. Вход: <i>learn1</i> , <i>mar1</i> , <i>utarget</i> , параметры обучения (<i>w</i> , <i>t</i>). Выход: обновлённое значение <i>learn1</i> . | Формула (3) |
| 6. | Нормализация | Приводит значения результирующего изображения к стандартному диапазону [0, 255]. Вход: <i>ResultImage</i> . Выход: нормализованное изображение. | Функция <i>Normalize</i> |
| 7. | Бинаризация | Преобразует нормализованное изображение в бинарную маску с чёткими границами объекта. Вход: нормализованное изображение, порог (50). Выход: <i>BinaryMask</i> . | Функция <i>Binarize</i> |
| 8. | Применение маски | Выделяет сегментированную область на исходном изображении с использованием бинарной маски. Вход: <i>OriginalImage</i> , <i>BinaryMask</i> . Выход: <i>SegmentedImage</i> . | Функция <i>Apply Mask</i> |
| 9. | Визуализация | Отображает промежуточные и финальные результаты сегментации на экране. Вход: различные изображения (<i>OriginalImage</i> , <i>ResultImage</i> , <i>BinaryMask</i> , <i>SegmentedImage</i>). Выход: отображение на экране. | Функция <i>Output</i> |

Таблица 4 – Онтология атрибутов модели сегментации изображений

| № | Онтология атрибутов | | |
|----|------------------------|---------------------------------|--|
| | Название класса | Атрибут | Описание |
| 1. | Изображение | <i>path</i> (строка) | Путь к файлу изображения |
| | | <i>data</i> (массив) | данные изображения (<i>RGB</i> , <i>HSV</i> , маска и т.д.). |
| | | <i>shape</i> (кортеж) | размеры изображения (высота, ширина, каналы). |
| 2. | Пиксель | <i>value</i> (число) | интенсивность пикселя (например, в градациях серого или <i>HSV</i>) |
| | | <i>coordinates</i> (кортеж) | позиция пикселя (<i>i, j</i>) |
| 3. | Функция принадлежности | <i>parameters</i> (кортеж) | границы треугольной функции (<i>x, y, z</i>) |
| | | <i>membership_value</i> (число) | степень принадлежности (от 0 до 1) |
| 4. | Весовой коэффициент | <i>value</i> (число) | текущее значение <i>learn</i> |
| | | <i>min_value</i> (число) | минимально допустимое значение (0.001) |
| | | <i>max_value</i> (число) | максимально допустимое значение (10) |
| 5. | Целевое значение | <i>value</i> (число) | целевая интенсивность (например, 170) |

Разработанная ОМ сегментации изображения представляет собой структурированное описание ключевых сущностей, процессов и их взаимосвязей, используемых для выделения объектов на изображении с применением нейро-нечёткого подхода. Модель включает основные классы, такие как *Изображение*, *Пиксель*, *Функция принадлежности*, *Весовой коэффициент*, *Параметры сегментации*, *Целевое значение* и *Процесс*, а также их подклассы, детализирующие этапы обработки данных. Процессы, такие как *Загрузка изображения*, *Преобразование цветового пространства*, *Дефаззификация*, *Обновление весов* и другие, формируют последовательный поток обработки, начиная с ввода исходного изображения и заканчивая визуализацией сегментированного результата.

Особенностью модели является её ориентация на онтологическую структуру, использующую нечёткие функции принадлежности для представления процессов сегментации изображений пожаров. Визуализация модели в виде графа упрощает анализ и модификацию ОМ.

2 Математическая модель

Работа нейро-нечёткой модели состоит из трёх шагов.

Шаг 1. Фаззификация – формирование треугольной функции принадлежности:

$$\mu(s, x, y, z) = \begin{cases} \frac{s-x}{y-x}, & \text{если } x < s \leq y; \\ \frac{z-s}{z-y}, & \text{если } y < s < z; \\ 0, & \text{иначе,} \end{cases} \quad (2)$$

где *s* – входящий сигнал, в данном случае значение интенсивности пикселя изображения; *x, y, z* – метки функций принадлежности, задаваемые разработчиком. Переменные *x, y, z* подбираются в зависимости от требуемого вида треугольной функции принадлежности. В результате операции фаззификации формируются две функции принадлежности (рисунок 2).

Степень активации нечётких правил определяется на основе функций принадлежности. При этом *max-min* композиция, основанная на правилах Заде (нечёткая импликация Мамдани [25]), исключена благодаря применению модифицированного метода отношения площадей в дефаззификаторе, что повышает быстродействие предложенного нечётко-логического вывода. Значения степеней активации, соответствующие классам «Фон» и «Объект», включены в структуру дефаззификатора, что обеспечивает обработку данных без дополнительных промежуточных этапов.

Шаг 2. Дефаззификация – определение выходного значения на основе модифицированного метода отношения площадей:

$$\text{MAR2} = \left[\frac{\sum_{i=1}^n M_i}{n \times \text{Learn}_{i+1}} \cdot (Y_{\max} - Y_{\min}) \right] + Y_{\min}, \quad (3)$$

где M_i – значение, полученное из функций принадлежности $\mu(s, x, y, z)$, n – число выходных нечётких функций принадлежности, Learn_{i+1} – весовой коэффициент (по умолчанию 1), Y_{\max} – максимальное значение ядра, Y_{\min} – минимальное значение ядра.

Шаг 3. Процесс обучения – определение выходного значения после обучения:

$$\text{Learn}_{i+1} = \text{Learn}_i + ([\text{MAR2} - Y_{\text{target}}] \times w), \text{ until } |\text{MAR2} - Y_{\text{target}}| \leq T, \quad (4)$$

где Learn_i – весовой коэффициент (значение равно Learn_{i+1} с этапа дефаззификации); w – скорость обучения (по умолчанию 0.04); T – пороговый коэффициент (по умолчанию 0.01); Y_{target} – ожидаемое выходное значение после дефаззификации.

3 Метод адаптивной нейро-нечёткой сегментации изображений

На основе ОМ разработанный метод нейро-нечёткой сегментации изображений *ANFIS-OMAR* (*Adaptive Neuro-Fuzzy Inference System – Optimized Method Area Ratio*) включает девять этапов.

- 1) получение изображения в формате *RGB* (*Red, Green, Blue* – красный, зелёный, синий) с оптико-электронного прибора или из базы данных, где визуальная информация фиксируется в виде трёхканального массива (*RGB*).
- 2) преобразование изображения в формат *HSV* для определения параметров насыщенности, что улучшает выделение цветовых диапазонов при изменении освещённости благодаря интуитивным характеристикам цвета.
- 3) создание и применение маски по заданным цветовым значениям с последующим обнулением или подавлением пикселей, не соответствующих цвету, что фокусирует обработку на интересующих объектах.
- 4) преобразование в градации серого с использованием взвешенного среднего значений каналов *RGB*, упрощающее анализ текстуры и интенсивности пикселей для подачи в нечёткую систему.
- 5) фаззификация входных и выходных переменных с двумя треугольными функциями («Фон», «Объект») и выходными значениями, адаптируемыми в зависимости от условий.
- 6) дефаззификация результирующего значения, определяющая принадлежность пикселя к искомому классу на основе выходов нечёткой системы.
- 7) обучение системы, где результат сравнивается с эталонным значением, а весовые коэффициенты корректируются итерационно для повышения точности сегментации.
- 8) нормализация изображения после нечёткого вывода, приводящая значения к стандартной шкале.

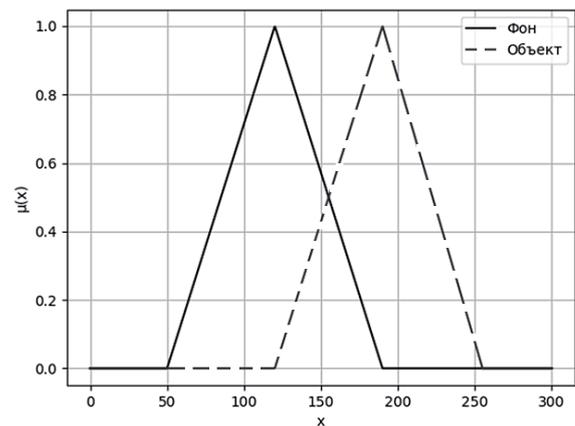


Рисунок 2 – Функции принадлежности «Фон» и «Объект»

9) формирование итогового сегментированного изображения, где маска визуализирует классификацию пикселей и пригодна для анализа, сегментации, распознавания или дальнейшей обработки.

Представленный метод адаптивной нейро-нечёткой сегментации изображений позволяет эффективно объединить нечёткие механизмы логического вывода с элементами машинного обучения.

4 Программа сегментации изображений

С целью воспроизводимости предложенного метода разработан программный код для реализации ОМ. На входе в программу поступают изображения, выходными данными являются обработанные изображения, на которых детектируемый объект выделен маской.

Алгоритм сегментации изображений пожаров с использованием модели *ANFIS-OMAR*, содержит следующие основные этапы.

1. Загрузка данных (строки 1-6): Алгоритм принимает входное изображение *I* в формате *RGB* размером 1024x720 пикселей и эталонную маску *GT*. Проверяется успешность загрузки файлов *fire1.jpg* и *fire1_mask.jpg*.
2. Преобразование в *HSV* (строки 7-20): Изображение преобразуется из формата *RGB* в цветовое пространство *HSV* для анализа оттенка (*H*), насыщенности (*S*) и яркости (*V*). Задаётся диапазон *HSV* (*lower_red* = [0, 40, 70], *upper_red* = [50, 255, 255]), соответствующий цветам огня (красные и оранжевые оттенки). Создаётся начальная маска огня (*Mask*), где пиксели в заданном диапазоне получают значение 255, остальные – 0.
3. Применение маски и преобразование в градации серого (строки 21-22): Маска применяется к исходному изображению для выделения области огня (*FireRegion*), после чего изображение преобразуется в градации серого (*GrayMask*) с использованием стандартных весов (0.114, 0.587, 0.299).
4. Инициализация параметров (строки 23-32): Создаётся выходное изображение *ResultImage* размером с *GrayMask*, заполненное нулями. Определяются параметры модели.
 - 4.1. *triangular_params* = [(50, 130, 255), (130, 190, 255)] – две треугольные функции принадлежности для классификации пикселей (огонь/фон).
 - 4.2. *Learn_i* – массив весовых коэффициентов, изначально заполненный единицами.
 - 4.3. *Y_{target}* = 180 – целевая интенсивность для адаптации.
 - 4.4. *w* = 0.004 – скорость обучения.
 - 4.5. *T* = 0.01 – порог ошибки для обновления *Learn_i*.
 - 4.6. *Y_{min}* = 0, *Y_{max}* = 255 – суппорт ядра выходной переменной.
 - 4.7. *threshold* = 30 – порог для бинаризации.
5. Обработка пикселей (строки 33-47). Для каждого пикселя (*x, y*) в *GrayMask*.
 - 5.1. Вычисляется интенсивность пикселей в маске *s*.
 - 5.2. Определяются степени принадлежности *h₁* и *h₂* к двум треугольным функциям в цикле из 4 итераций.
 - 5.2.1. Вычисляется дефазифицированное значение *defuzzy* с использованием оптимизированного метода отношения площадей (3).
 - 5.2.2. Значение ограничивается диапазоном [*Y_{min}*, *Y_{max}*].
 - 5.2.3. Если ошибка между *defuzzy* и *Y_{target}* превышает *T*, обновляется *Learn_i(x, y)* с использованием градиентного спуска (4), ограничивая его в пределах [0.001, 10].
 - 5.2.4. Результат записывается в *ResultImage(x, y)*.
6. Нормализация и бинаризация (строки 48-56): *ResultImage* нормализуется в диапазон [0, 255] по формуле минимакс-нормализации. Затем создаётся бинарная маска *BinaryMask*, где пиксели с интенсивностью выше порога (30) получают значение 255, остальные – 0.
7. Формирование результата (строки 57-58): Бинарная маска применяется к исходному изображению для получения сегментированного изображения *SegmentedImage*, которое выводится как результат.

Ниже представлен псевдокод разработанной программы.

```

Algorithm ANFIS-OMAR Image Segmentation
Require: Image I, GroundTruth GT
Ensure: SegmentedImage
1. Load Image I from file "fire1.jpg"
2. Load GroundTruth GT from file "fire1_mask.jpg"
3. If I or GT is not loaded then
4.   Output "Error loading image or mask"
    
```

```

5.   Exit
6. End If
7. Convert I from BGR to HSV: H, S, V = BGR_to_HSV(I)
8. Define HSV range:
9.   lower_red = [0, 40, 70]
10.  upper_red = [50, 255, 255]
11. Create Mask:
12.  For each pixel (x, y) do
13.    If lower_red[0] ≤ H(x, y) ≤ upper_red[0] and
14.      lower_red[1] ≤ S(x, y) ≤ upper_red[1] and
15.      lower_red[2] ≤ V(x, y) ≤ upper_red[2] then
16.      Mask(x, y) = 255
17.    Else
18.      Mask(x, y) = 0
19.    End If
20.  End For
21. Apply Mask: FireRegion = I * (Mask / 255)
22. Convert to grayscale: GrayMask = 0.114 * FireRegion_B + 0.587 * FireRegion_G + 0.299 * FireRegion_R
23. Initialize ResultImage = zeros_like(GrayMask)
24. Set Parameters:
25.   triangular_params = [(50, 130, 255), (130, 190, 255)]
26.   learni = ones_like(GrayMask)
27.   ytarget = 180
28.   w = 0.004
29.   t = 0.01
30.   ymin = 0
31.   ymax = 255
32.   threshold = 30
33. For each pixel (x, y) in GrayMask do
34.   s = GrayMask(x, y)
35.   h_1 = TriangularMembership(s, triangular_params[0][0], triangular_params[0][1], triangular_params[0][2])
36.   h_2 = TriangularMembership(s, triangular_params[1][0], triangular_params[1][1], triangular_params[1][2])
37.   memberships = [h_1, h_2]
38.   For i = 1 to 6 do
39.     defuzzy = (sum(memberships[j] * (2 - memberships[j]) for j in range(2)) / (2 * learni(x, y))) *
(ymax - ymin) + ymin
40.     defuzzy = max(ymin, min(defuzzy, ymax))
41.     If |defuzzy - ytarget| > t then
42.       learni(x, y) = learni(x, y) + w * (ytarget - defuzzy)
43.       learni(x, y) = max(0.001, min(learni(x, y), 10))
44.     End If
45.     ResultImage(x, y) = defuzzy
46.   End For
47. End For
48. Normalize ResultImage: ResultImage = (ResultImage - min(ResultImage)) / (max(ResultImage) -
min(ResultImage)) * 255
49. Binarize ResultImage:
50.  For each pixel (x, y) do
51.    If ResultImage(x, y) > threshold then
52.      BinaryMask(x, y) = 255
53.    Else
54.      BinaryMask(x, y) = 0
55.    End If
56.  End For
57. Apply BinaryMask: SegmentedImage = I * (BinaryMask / 255)
58. Output SegmentedImage
End Algorithm

```

5 Экспериментальные исследования

Эксперименты проведены для оценки эффективности модели *ANFIS-OMAR* в задаче высокоскоростной сегментации изображений пожаров в сравнении с методами *HSV* и *U-Net*. В ходе экспериментов использовались четыре изображения формата 1024x720 пикселей, представляющие ночные пожары с дымом на фоне гор. Каждое изображение сопровождалось эталонной маской, созданной вручную для обозначения областей огня. Цель экспериментов

– определение способности методов сегментировать начинающиеся очаги возгорания при сохранении высокой скорости обработки, что важно для задач мониторинга пожаров в реальном времени. Результаты экспериментов представлены на рисунках 3-6.

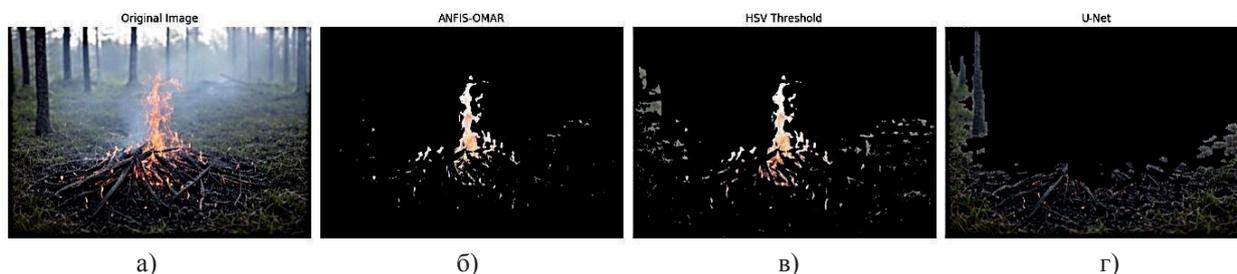


Рисунок 3 – Результаты эксперимента 1: а) оригинальное изображение, б) сегментированное моделью *ANFIS-OMAR*, в) сегментированное методом *HSV Threshold*, г) сегментированное моделью *U-Net*

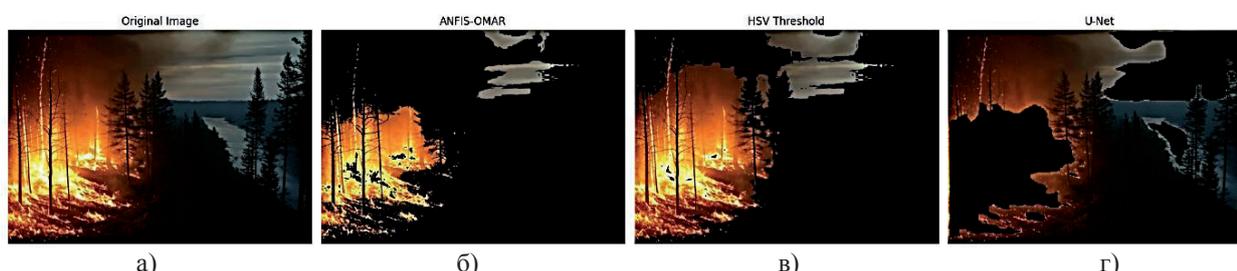


Рисунок 4 – Результаты эксперимента 2: а) оригинальное изображение, б) сегментированное моделью *ANFIS-OMAR*, в) сегментированное методом *HSV Threshold*, г) сегментированное моделью *U-Net*



Рисунок 5 – Результаты эксперимента 3: а) оригинальное изображение, б) сегментированное моделью *ANFIS-OMAR*, в) сегментированное методом *HSV Threshold*, г) сегментированное моделью *U-Net*

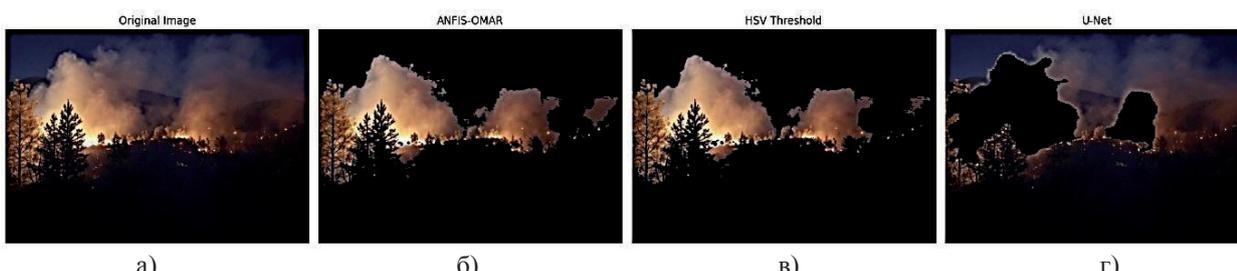


Рисунок 6 – Результаты эксперимента 4: а) оригинальное изображение, б) сегментированное моделью *ANFIS-OMAR*, в) сегментированное методом *HSV Threshold*, г) сегментированное моделью *U-Net*

ANFIS-OMAR: Использовалась адаптивная нейро-нечёткая система вывода с оптимизированным дефазификатором метода отношения площадей. Параметры: диапазон *HSV* (*lower_red* = [0, 40, 70], *upper_red* = [50, 255, 255]), треугольные функции принадлежности $((50, 130, 255), (130, 190, 255))$, целевая интенсивность $Y_{target} = 180$, порог бинаризации 30.

HSV: Пороговая сегментация в том же диапазоне *HSV* (*lower_red* = [0, 40, 70], *upper_red* = [50, 255, 255]) без дополнительной обработки.

U-Net: Упрощённая свёрточная сеть с предварительным обучением на 300 изображениях (30 эпох), входное изображение масштабировалось до 256x256, порог бинаризации 0.1.

Оценка производилась по метрикам: время выполнения (*Time, s*), среднеквадратичная ошибка (*RMSE*), коэффициент пересечения и объединения (*IoU*), коэффициент *Dice* и средняя абсолютная процентная ошибка (*MAPE*). Результаты представлены в таблице 5. Анализ результатов показал следующее.

Таблица 5 – Результаты экспериментов

| | <i>Time, s</i> | <i>RMSE</i> | <i>IoU</i> | <i>Dice</i> | <i>MAPE</i> |
|-------------------|----------------|-------------|------------|-------------|-------------|
| Эксперимент 1 | | | | | |
| <i>ANFIS-OMAR</i> | 0.1466 | 0.8877 | 0.3783 | 0.5489 | 72.8 |
| <i>HSV</i> | 0.0020 | 0.8978 | 0.2813 | 0.4390 | 70.5 |
| <i>U-Net</i> | 2.4721 | 2.2161 | 0.0004 | 0.0008 | 142.6 |
| Эксперимент 2 | | | | | |
| <i>ANFIS-OMAR</i> | 0.1576 | 0.9699 | 0.2243 | 0.3664 | 69.8 |
| <i>HSV</i> | 0.0020 | 1.0564 | 0.1306 | 0.2311 | 64.8 |
| <i>U-Net</i> | 2.3706 | 2.0598 | 0.0002 | 0.0004 | 158.6 |
| Эксперимент 3 | | | | | |
| <i>ANFIS-OMAR</i> | 0.1596 | 0.7448 | 0.4041 | 0.5756 | 42.1 |
| <i>HSV</i> | 0.0030 | 0.7873 | 0.2947 | 0.4553 | 27.7 |
| <i>U-Net</i> | 2.3321 | 1.8794 | 0.0663 | 0.1243 | 67.1 |
| Эксперимент 4 | | | | | |
| <i>ANFIS-OMAR</i> | 0.1359 | 0.7464 | 0.0781 | 0.1448 | 50.1 |
| <i>HSV</i> | 0.0020 | 0.7381 | 0.0756 | 0.1406 | 54.8 |
| <i>U-Net</i> | 2.3563 | 1.6388 | 0.0086 | 0.0171 | 135.5 |

U-Net – неэффективен ($IoU=0.0086$).

ANFIS-OMAR различал огонь и фон (дым, горы), минимизируя ложноположительные пиксели, в отличие от *HSV*, который чаще включал дым, и от *U-Net*, который переобучался. Время выполнения *ANFIS-OMAR* (~0.14–0.16 с) значительно ниже *U-Net* (~2.3–2.5 с), но больше *HSV* (~0.002–0.003 с). Это подтверждает пригодность *ANFIS-OMAR* для реального времени.

Заключение

Исследование показало эффективность ОМ сегментации изображений пожаров на основе *ANFIS-OMAR* в условиях ночного освещения с дымом на фоне гор. В разработанной ОМ систематизированы ключевые сущности, процессы и их взаимосвязи, включая преобразование изображений в цветовое пространство оттенка, насыщенности и яркости, использование треугольных функций принадлежности и адаптивную настройку параметров с оптимизированным дефаззификатором метода отношения площадей. Модель структурирует процессы обработки данных для выделения очагов возгорания. Эксперименты на четырёх изображениях формата 1024x720 подтвердили, что *ANFIS-OMAR* превосходит методы *HSV* и *U-Net* по ключевым метрикам (*IoU* и *Dice*), особенно в сложных условиях с переменной интенсивностью огня и дымом. *HSV* быстрее (~0.002 с), но уступает по точности (*IoU* до 0.2947), а *U-Net* (~2.3 с) демонстрирует низкую эффективность (*IoU* до 0.0663) из-за ограниченного обучения.

Малое время обработки *ANFIS-OMAR* (0.14-0.16 с.) делает модель пригодной для мониторинга пожаров в реальном времени. Онтологический подход, лежащий в основе *ANFIS-OMAR*, обеспечивает чёткое описание классов, процессов и атрибутов, упрощая анализ и модификацию алгоритма.

Эксперимент 1: ANFIS-OMAR показал лучшее качество сегментации ($IoU=0.3783$, $Dice=0.5489$) по сравнению с *HSV* ($IoU=0.2813$, $Dice=0.4390$), хотя *MAPE* остался выше (72.8% против 70.5%). *U-Net* показал низкую точность ($IoU=0.0004$, $Dice=0.0008$) из-за переобучения на одном изображении.

Эксперимент 2: ANFIS-OMAR сохранил преимущество по *IoU* (0.2243) и *Dice* (0.3664) над *HSV* (0.1306 и 0.2311), но *MAPE* ухудшился (69.8% против 64.8%). *U-Net* показал низкие результаты ($IoU=0.0002$).

Эксперимент 3: ANFIS-OMAR достиг наилучших показателей ($IoU=0.4041$, $Dice=0.5756$, $MAPE=42.1099\%$), значительно превосходя *HSV* ($IoU=0.2947$, $Dice=0.4553$, $MAPE=27.7\%$). *U-Net* улучшился ($IoU=0.0663$).

Эксперимент 4: ANFIS-OMAR и *HSV* показали схожие низкие результаты ($IoU=0.07-0.08$, $Dice=0.14$), вероятно из-за малого раз-

СПИСОК ИСТОЧНИКОВ

- [1] **Kanand T., Kemper G., König R., Kemper H.** Wildfire detection and disaster monitoring system using uas and sensor fusion technologies. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 2020, XLIII-B3-2020, 1671–1675, DOI: 10.5194/isprs-archives-XLIII-B3-2020-1671-2020.
- [2] **Шваров Н.Н., Хасан Я., Фахми Ш.С.** Метод автоматизированного обнаружения и исследования лесных пожаров. *Наука настоящего и будущего*. 2018. Т.1. С.119-123. EDN: VAREEB.
- [3] **Abdusalomov A., Baratov N., Kutlimuratov A., Whangbo T. K.** An improvement of the fire detection and classification method using YOLOv3 for surveillance systems. *Sensors*, 2021, 21(19). DOI: 10.3390/s21196519.
- [4] **Алиев И.Р., Павлов В.А.** Применение алгоритмов компьютерного зрения для обнаружения и локализации пожаров на аэрофотоснимках. *СПбНТОРЭС: труды ежегодной HTK*. 2020. №1(75). С.225-228.
- [5] **Станкевич Т.С., Далнер Д., Трчка М., Томитчек А.** Оперативное прогнозирование теплового потока при пожаре в вертикальном стальном резервуаре с защитной стенкой с использованием ANFIS. *Пожаровзрывобезопасность*. 2020. Т.29, №5. С.13-39. DOI: 10.22227/PVB.2020.29.05.13-39.
- [6] **Doborjeh Z., Hemmington N., Doborjeh M., Kasabov N.** Artificial intelligence: a systematic review of methods and applications in hospitality and tourism. *International Journal of Contemporary Hospitality Management*, 2022, 34(3), 1154–1176. DOI: 10.1108/IJCHM-06-2021-0767
- [7] **Станкевич Т.С.** Применение сверточных нейронных сетей для решения задачи оперативного прогнозирования динамики распространения лесных пожаров. *Бизнес-информатика*. 2018. №4(46). С.17-27. DOI: 10.17323/1998-0663.2018.4.17.27.
- [8] **Yang S.Y., Zhong Y.D., Zhong B.C., Lin Y.Y.** Enhancing Flooding Depth Forecasting Accuracy in an Urban Area Using a Novel Trend Forecasting Method. *Water Resources Management*, 2024, 38(4), P.1359–1380. DOI: 10.1007/s11269-023-03725-4.
- [9] **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. P.741–745)*. European Signal Processing Conference, 2021, EUSIPCO. DOI: 10.23919/EUSIPCO54536.2021.9616026.
- [10] **Guan Z., Miao X., Mu Y., Sun Q., Ye Q., Gao D.** Forest Fire Segmentation from Aerial Imagery Data Using an Improved Instance Segmentation Model. *Remote Sensing*, 2022, 14(13). DOI: 10.3390/rs14133159.
- [11] **Ghali R., Akhloofi M. A.** Deep Learning Approaches for Wildland Fires Remote Sensing: Classification, Detection, and Segmentation. *Remote Sensing*, 2023. 15(3). DOI: 10.3390/rs15071821.
- [12] **Бочков В.С., Катаева Л.Ю., Масленников Д.А.** Точная многоклассовая сегментация пожаров: подходы, нейронные сети, схемы сегментации. *Искусственный интеллект и принятие решений*. 2024. №3. С.71-86. DOI 10.14357/20718594240306.
- [13] **Saponara S., Elhanashi A., Gagliardi A.** Real-time video fire/smoke detection based on CNN in antifire surveillance systems. *Journal of Real-Time Image Processing*. 2021, 18(3), 889–900. DOI:10.1007/s11554-020-01044-0.
- [14] **Jonnalagadda A.V., Hashim H.A.** SegNet: A segmented deep learning based Convolutional Neural Network approach for drones wildfire detection. *Remote Sensing Applications: Society and Environment*, 2024, 34. DOI: 10.1016/j.rsase.2024.101181.
- [15] **Феоктистова О.В., Горбачев И.В.** Выявление участков улучшенных свойств пласта, основанное на анализе результатов сегментации сейсмических данных с помощью генетических алгоритмов. *Геофизика*. 2021. №4. С.40-50. EDN: CKHVFT.
- [16] **Zarkasi A., Nurmaini S., Stiawan D., Firdaus, Abdurahman, Deri Amanda C.** Implementation of fire image processing for land fire detection using color filtering method. In *Journal of Physics: Conference Series*. Institute of Physics Publishing, 2019. Vol. 1196., DOI: 10.1088/1742-6596/1196/1/012003.
- [17] **Mon Arjay F. Malbog, Alvin Sarraga Alon, Cherry D. Casuat, Rufo I. Marasigan Jr., Joshua S. Gulmatico.** Hybrid-FireID: Fire Identification using Hybrid Features Extraction for Combustible and Fluid Fire Segmentation. *International Journal of Emerging Trends in Engineering Research*, 2020, 8(2). P.471-475. DOI: 10.30534/ijeter/2020/35822020.
- [18] **Chen G., Chen C., Yuan Y., Xu L.** Control strategy of injection rail pressure of diesel engine based on T-S model and adaptive neural fuzzy inference system. *UPB Scientific Bulletin, Series D: Mechanical Engineering*, 2021, 83(1). P.67-82.
- [19] **Alghamdi M.I.** Neutrosophic set with Adaptive Neuro-Fuzzy Inference System for Liver Tumor Segmentation and Classification Model. *International Journal of Neutrosophic Science*, 2022, 18(2). P.174-185. DOI: 10.54216/IJNS.180202.
- [20] **Yandouzi M., Grari M., Berrahal M., Idrissi I., Moussaoui O., Azizi M., Elmiad A.K.** Investigation of combining deep learning object recognition with drones for forest fire detection and monitoring. *International Journal of Advanced Computer Science and Applications*, 2023, 14(3). P.377–384. DOI: 10.14569/IJACSA.2023.0140342.

- [21] **Корабошев О.З.** Анализ и перспективы применения методов машинного обучения для чрезвычайных ситуаций. *Интеллектуальные технологии на транспорте*. 2024. №1(37). С.12-17. DOI 10.20295/2413-2527-2024-137-12-17.
- [22] **Fahmy A.** Opportunities and challenges of applying artificial intelligence in healthcare. *Premier Journal of Artificial Intelligence*. 2024. P.67-82. DOI 10.70389/pjai.100003.
- [23] **Малыхина Г.Ф., Жиракова П.С., Милицын А.В.** Проектирование интеллектуальной противопожарной системы. *Онтология проектирования*. 2024. Т.14, №2(52). С.217-229. DOI: 10.18287/2223-9537-2024-14-2-217-229.
- [24] **Шошина К.В., Алешко Р.А., Березовский В.В.** Тематическое дешифрирование аэроснимков лесных территорий на основе концептуального моделирования. *Онтология проектирования*. 2023. Т.13, № 3(49). С.437-454. DOI: 10.18287/2223-9537-2023-13-3-437-454.
- [25] **Пегат А.** Нечёткое моделирование и управление. Пер. с англ. М.: БИНОМ. Лаборат. знаний, 2011. 798 с.

Сведения об авторах



Бобырь Максим Владимирович, 1978 г. рождения. Окончил Курский государственный технический университет в 2000 г., к.т.н. (2003 г.). Д.т.н., профессор кафедры программной инженерии ЮЗГУ. Председатель первого в России диссертационного совета ЮЗГУ по специальности «Когнитивное моделирование» (технические науки). В списке научных трудов более 450 работ в области систем управления сложными объектами на основе интеллектуальных систем технического зрения. Author ID (РИНЦ): 276211; Author ID (Scopus): 57191724301; Researcher ID (WoS): G-2604-2013; ORCID: 0000-0002-5400-6817. maxbobyry@gmail.com ✉.



Бондаренко Богдан Андреевич, 1997 г. рождения. Аспирант кафедры программной инженерии ЮЗГУ по специальности 05.13.06 Автоматизация и управление технологическими процессами и производствами. Область научных интересов: обучающие нечётко-логические системы, распознавание образов. Author ID (РИНЦ): 1176529; Researcher ID (WoS): HGV-0751-2022; ORCID: 0000-0001-5415-9015. sikersinko@gmail.com

Поступила в редакцию 27.03.2025, после рецензирования 15.10.2025. Принята к публикации 11.12.2025.



Scientific article

DOI: 10.18287/2223-9537-2026-16-1-60-73

Ontological model for fire image segmentation using an adaptive neuro-fuzzy network

© 2026, М.В. Бобырь ✉, В.А. Бондаренко

Southwest State University, Kursk, Russia

Abstract

Fire image segmentation is a critical task for early detection and emergency monitoring systems. Traditional methods, such as thresholding and complex computational models, face limitations in terms of speed and accuracy under real-time conditions. The objective of this study is to enable an image segmentation process operating in near real-time. This paper presents an ontological model for fire image segmentation based on an adaptive neuro-fuzzy system with an optimized defuzzifier employing the area ratio method. The proposed model structures data processing workflows, including image transformation into the hue-saturation-brightness color space, the use of triangular membership functions, and adaptive parameter tuning for identifying fire regions. The ontology systematizes classes, processes, and their interrelationships, thereby ensuring modularity and flexibility of the solution. Experiments on images of nighttime fires with smoke showed that the proposed model achieves high accuracy and speed, outperforming the compared segmentation methods, and demonstrates potential for application in real-time monitoring systems.

Keywords: *ontology, neuro-fuzzy algorithm, image segmentation, defuzzification, artificial intelligence.*

For citation: *Bobyry MV, Bondarenko BA. Ontological model for fire image segmentation using an adaptive neuro-fuzzy network [In Russian]. Ontology of designing. 2026; 16(1): 60-73. DOI:10.18287/2223-9537-2026-16-1-60-73.*

Financial Support: The work was carried out with the support of State Assignment No. 075-03-2025-526.

Authors' contributions: *Bobyry MV.* – development of the concept of a neuro-fuzzy network for image segmentation; *Bondarenko BA.* – development of the ontological model for fire image segmentation and conducting experiments.

Conflict of interest: The authors declare no conflict of interest.

List of figures and tables

Figure 1 – Ontological model of image segmentation

Figure 2 – Membership functions "Background" and "Object"

Figure 3 – Results of Experiment 1: a) original image, b) segmented using the ANFIS-OMAR model, c) segmented using the HSV Threshold method, d) segmented using the U-Net model

Figure 4 – Results of Experiment 2: a) original image, b) segmented using the ANFIS-OMAR model, c) segmented using the HSV Threshold method, d) segmented using the U-Net model

Figure 5 – Results of Experiment 3: a) original image, b) segmented using the ANFIS-OMAR model, c) segmented using the HSV Threshold method, d) segmented using the U-Net model

Figure 6 – Results of Experiment 4: a) original image, b) segmented using the ANFIS-OMAR model, c) segmented using the HSV Threshold method, d) segmented using the U-Net model

Table 1 – Ontology of classes of the image segmentation model

Table 2 – Ontology of the "Image" class of the image segmentation model

Table 3 – Ontology of the "Process" class of the image segmentation model

Table 4 – Ontology of attributes of the image segmentation model

Table 5 – Experimental results

References

- [1] **Kanand T, Kemper G, König R, Kemper H.** Wildfire detection and disaster monitoring system using uas and sensor fusion technologies. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 2020, XLIII-B3-2020, 1671–1675, DOI: 10.5194/isprs-archives-XLIII-B3-2020-1671-2020.
- [2] **Shvarov NN, Hasan Ya, Fahmi ShS.** A method for automated detection and analysis of forest fires [In Russian]. *Science of the present and future.* 2018; 1: 119-123.
- [3] **Abdusalomov A, Baratov N, Kutlimuratov A, Whangbo TK.** An improvement of the fire detection and classification method using YOLOv3 for surveillance systems. *Sensors*, 2021, 21(19). DOI: 10.3390/s21196519.
- [4] **Aliyev IR, Pavlov VA.** Application of computer vision algorithms for detection and localization of fires on aerial photographs [In Russian]. *SPbNTORES: proceedings of the annual STC.* 2020; 1(75): 225-228.
- [5] **Stankevich TS, Dalner D, Trčka M, Tomitschek A.** Operational forecasting of heat flow in a fire in a vertical steel tank with a protective wall using ANFIS [In Russian]. *Fire and explosion safety.* 2020; 29(5): 13-39. DOI: 10.22227/PVB.2020.29.05.13-39.
- [6] **Doborjeh Z, Hemmington N, Doborjeh M, Kasabov N.** Artificial intelligence: a systematic review of methods and applications in hospitality and tourism. *International Journal of Contemporary Hospitality Management*, 2022, 34(3), 1154–1176. DOI: 10.1108/IJCHM-06-2021-0767.
- [7] **Stankevich TS.** Application of convolutional neural networks to solve the problem of operational forecasting of the dynamics of forest fire spread [In Russian]. *Business informatics.* 2018; 4(46): 17-27. DOI: 10.17323/1998-0663.2018.4.17.27.
- [8] **Yang SY, Zhong YD, Zhong BC, Lin YY.** Enhancing flooding depth forecasting accuracy in an urban area using a novel trend forecasting method. *Water Resources Management*, 2024, 38(4), 1359–1380. DOI: 10.1007/s11269-023-03725-4.
- [9] **Mseddi WS, Ghali R, Jmal M, Attia R.** Fire Detection and Segmentation using YOLOv5 and U-NET. In European Signal Processing Conference. *European Signal Processing Conference*, 2021; Vol.2021-August: 741–745. EUSIPCO. DOI: 10.23919/EUSIPCO54536.2021.9616026.
- [10] **Guan Z, Miao X, Mu Y, Sun Q, Ye Q, Gao D.** Forest fire segmentation from aerial imagery data using an improved instance segmentation model. *Remote Sensing*, 2022, 14(13). DOI: 10.3390/rs14133159.
- [11] **Ghali R, Akhloofi MA.** Deep Learning Approaches for Wildland Fires Remote Sensing: Classification, Detection, and Segmentation. *Remote Sensing*, 2023. MDPI. DOI: 10.3390/rs15071821.

- [12] **Bochkov VS, Kataeva LYu, Maslennikov DA.** Accurate multi-class segmentation of fires: approaches, neural networks, segmentation schemes [In Russian]. *Artificial Intelligence and Decision Making*. 2024; 3: 71-86. DOI: 10.14357/20718594240306.
- [13] **Saponara S, Elhanashi A, Gagliardi A.** Real-time video fire/smoke detection based on CNN in antifire surveillance systems. *Journal of Real-Time Image Processing*, 2021, 18(3), 889–900. DOI:10.1007/s11554-020-01044-0.
- [14] **Jonnalagadda AV, Hashim HA.** SegNet: A segmented deep learning based Convolutional Neural Network approach for drones wildfire detection. *Remote Sensing Applications: Society and Environment*, 2024; 34. DOI: 10.1016/j.rsase.2024.101181.
- [15] **Feoktistova OV, Gorbachev IV.** Identification of areas with improved reservoir properties based on the analysis of seismic data segmentation results using genetic algorithms [In Russian]. *Geophysics*. 2021; 4: 40-50.
- [16] **Zarkasi A, Nurmaini S, Stiawan D, Firdaus A, Deri AC.** Implementation of fire image processing for land fire detection using color filtering method. In *Journal of Physics: Conference Series (Vol. 1196)*. Institute of Physics Publishing, 2019. DOI: 10.1088/1742-6596/1196/1/012003.
- [17] **Mon Arjay F, Malbog, Alvin Sarraga Alon, Cherry D, Casuat, Rufo I, Marasigan Jr., Joshua S. Gulmatico.** Hybrid-FireID: Fire identification using hybrid features extraction for combustible and fluid fire segmentation. *International Journal of Emerging Trends in Engineering Research*, 2020; 8(2): 471–475. DOI: 10.30534/ijeter/2020/35822020.
- [18] **Chen G, Chen C, Yuan Y, Xu L.** Control strategy of injection rail pressure of diesel engine based on T-S model and adaptive neural fuzzy inference system. *UPB Scientific Bulletin, Series D: Mechanical Engineering*, 2021; 83(1): 67–82.
- [19] **Alghamdi MI.** Neutrosophic set with Adaptive Neuro-Fuzzy Inference System for Liver Tumor Segmentation and Classification Model. *International Journal of Neutrosophic Science*. 2022; 18(2): 174–185. DOI: 10.54216/IJNS.180202.
- [20] **Yandouzi M, Grari M, Berrahal M, Idrissi I, Moussaoui O, Azizi M, Elmiad AK.** Investigation of combining deep learning object recognition with drones for forest fire detection and monitoring. *International Journal of Advanced Computer Science and Applications*. 2023; 14(3): 377–384. DOI: 10.14569/IJACSA.2023.0140342.
- [21] **Koraboshev OZ.** Analysis and prospects of application of machine learning methods for emergency situations [In Russian]. *Intelligent Technologies in Transport*. 2024; 1(37): 12-17. DOI: 10.20295/2413-2527-2024-137-12-17.
- [22] **Fahmy A.** Opportunities and challenges of applying artificial intelligence in healthcare. *Premier Journal of Artificial Intelligence*. 2024. P.67-82. DOI: 10.70389/pjai.100003.
- [23] **Malykhina GF, Zhirakova PS, Militsyn AV.** Design of an intelligent fire protection system [In Russian]. *Ontology of designing*. 2024; 14(2): 217-229. DOI: 10.18287/2223-9537-2024-14-2-217-229.
- [24] **Shoshina KV, Aleshko RA, Berezovsky VV.** Thematic interpretation of aerial photographs of forest areas based on conceptual modeling [In Russian]. *Ontology of designing*. 2023; 13(3): 437-454. DOI: 10.18287/2223-9537-2023-13-3-437-454.
- [25] **Pegat A.** Fuzzy modeling and control [In Russian]. Trans. from English. Moscow: BINOM. Laboratory of knowledge, 2011. 798 p.

About the authors

Maxim Vladimirovich Bobyr (b. 1978) graduated from Kursk State Technical University (KSTU) in 2000, Ph.D in Engineering (2003). Doctor of Technical Sciences, Professor of the Department of Software Engineering at Southwest State University. Chair of the first dissertation council in Russia at Southwest State University in the specialty "Cognitive modeling" (Engineering Sciences). The list of scientific papers includes more than 450 works in the field of control systems for complex objects based on intelligent vision systems. Author ID (RSCI): 276211; Author ID (Scopus): 57191724301; Researcher ID (WoS): G-2604-2013; ORCID: 0000-0002-5400-6817. maxbobyr@gmail.com. ✉

Bogdan Andreevich Bondarenko (b. 1997) is a postgraduate student at the Department of Software Engineering, Southwest State University, majoring in 05.13.06 Automation and Control of Technological Processes and Production. Research interests include trainable fuzzy logic systems and pattern recognition. Author ID (RSCI): 1176529; Researcher ID (WoS): HGV-0751-2022; ORCID: 0000-0001-5415-9015. sikersinko@gmail.com

Received March 27, 2025. Revised October 15, 2025. Accepted December 11, 2025.