

ИНФОРМАЦИОННО-АНАЛИТИЧЕСКАЯ СИСТЕМА СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ НЕЙРО-НЕЧЕТКОГО ПОДХОДА

М. В. Бобырь¹ [0000-0002-5400-6817], Б. А. Бондаренко² [0000-0001-5415-9015]

^{1, 2}Юго-Западный государственный университет, Курск, 305040, Россия

¹maxbobyrgmail.com, ²sikersinko@gmail.com

Аннотация

Представлена информационно-аналитическая система (ИАС) для высокоскоростной сегментации изображений в градациях серого, основанной на модифицированном методе дефаззификации с использованием треугольных функций принадлежности. Цель исследования заключается в анализе влияния упрощения формулы дефаззификации на точность и контрастность выделения объектов. Предложенный подход включает адаптивное обучение весового коэффициента, позволяющее динамически корректировать процесс дефаззификации в зависимости от целевых значений. Проведено сравнение базового метода усреднения значений принадлежности и модифицированного варианта с учетом нелинейных весов. Эксперименты, проведенные на изображениях формата 1024x720, продемонстрировали, что разработанная ИАС обеспечивает высокую точность сегментации и улучшенную контрастность объектов при минимальных вычислительных затратах. Результаты подтверждают превосходство предложенного метода над традиционными подходами, подчеркивая перспективы применения искусственного интеллекта в задачах компьютерного зрения.

Ключевые слова: ИАС, нейро-нечеткий алгоритм, сегментация изображений, дефаззификация, искусственный интеллект, метод отношения площадей.

ВВЕДЕНИЕ

В последние годы обработка изображений стала одной из ключевых областей применения искусственного интеллекта и компьютерного зрения. Особое внимание уделяется методам сегментации изображений, которые позволяют выделять значимые объекты или области на основе их характеристик [1, 2]. Одним

из популярных подходов к решению задачи обработки изображений является использование нечеткой логики, которая эффективно справляется с неопределенностью и переходными состояниями в данных. Центральным этапом в таких системах является дефаззификация – процесс преобразования нечетких значений принадлежности в четкие выходные результаты. Традиционные методы дефаззификации, такие как вычисление центра тяжести или среднего значения, часто требуют компромисса между точностью и вычислительной сложностью [3].

В настоящей работе рассмотрено влияние упрощения формулы дефаззификации на результаты сегментации изображений с использованием треугольных функций принадлежности [4–6]. Проведено сравнение двух подходов: базового метода, основанного на усреднении значений принадлежности, и модифицированного варианта с учетом нелинейных весов. Кроме того, предложен алгоритм с адаптивным обучением весового коэффициента, который позволяет динамически корректировать процесс дефаззификации в зависимости от целевых значений. На основе экспериментов с реальными изображениями проведен анализ, как такие изменения сказываются на контрастности и точности выделения объектов, а также оценена практическая применимость разработанных программных решений. Результаты исследования будут полезны для дальнейшего совершенствования методов нечеткой сегментации в задачах компьютерного зрения.

В настоящей работе представлена модель нейро-нечеткого алгоритма для высокоскоростной сегментации изображений в градации серого. Эксперименты на изображениях формата 1024x720 показали эффективность предлагаемого метода. Реализованный искусственный интеллект (ИИ) подчёркивает потенциал применения ИИ в задачах сегментации изображений с минимальными вычислительными затратами [7].

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ НЕЙРО-НЕЧЕТКОГО АЛГОРИТМА СЕГМЕНТАЦИИ

Для вычисления результирующей переменной в алгоритме сегментации используем нейро-нечеткую модель обучения с дефаззификатором на основе модифицированного метода отношения площадей [8]. Рассмотрим этапы построения этого метода дефаззификации.




Рис. 1. Упрощение процесса вычисления верхнего основания усеченной функции принадлежности

Шаг 1. Определим общую площадь фигуры $S_{общ}$, описывающую выходную нечеткую переменную (рис. 2, а):

$$S_{общ} = \frac{nb_1\omega_i}{2}, \quad (1)$$

где n – число термов выходной нечеткой переменной ($n = 5$), b_1 – длина нижнего основания выходных ФП, ω_i – весовой коэффициент, i – номер термина ($i = 1, \dots, n$).

Шаг 2. Проведем усечение термов выходной ФП (см. рис. 2, б):

$$\mu(\alpha)' = \min_{i=1}^n [\mu(\alpha_i); h_i], \quad (2)$$

где $\mu(\alpha_i)$ – термы выходной ФП (см. рис. 2, а), $\min$ – мягкая операция нечеткого минимума, h_i – высота усеченного термина (см. рис. 1).

Шаг 3. Найдем площадь каждого из усеченных термов:

$$S_i = \begin{cases} 0, & \text{если } h_i = 0; \\ \frac{b_1}{2}, & \text{если } h_i = 1; \\ \frac{h_i}{2}(b_1 + b_2), & \text{если } h_i \in (0,1), \end{cases} \quad (3a)$$

$$(3b)$$

$$(3b)$$

где b_2 – длина верхнего основания усеченных термов выходной нечеткой переменной. Параметры треугольной функций принадлежности (ФП) приведены на рис. 1.

Шаг 4. Рассчитаем общую суммарную площадь $S_{\text{общ.сум.пл}}$ усеченных термов выходной нечеткой переменной:

$$S_{\text{общ.сум.пл}} = \sum_{i=1}^n S_i. \quad (4)$$

Шаг 5. Вычислим отношение площади усеченных термов к общей площади:

$$D = \frac{S_{\text{общ.сум.пл}}}{S_{\text{общ}}}. \quad (5)$$

Шаг 6. Определим дефаззификацию четкого значения выходной переменной на основе линейной функции:

$$\text{MAR} = [D(\alpha_K - \alpha_H)] + \alpha_H, \quad (6)$$

где α_H , α_K – соответственно начальное и конечное значения суппорта выходной переменной ($\alpha_H=0,4$; $\alpha_K=1$, см. рис. 2, а).




Рис. 2. Выходная нечеткая переменная: а – функции принадлежности; б – усеченные термы

Путем экспериментальных исследований метода отношения площадей установлено, что формула (3в) – самая трудоемкая операция. Поэтому проведем следующие модификации.

Шаг 7. Предположим, что усеченные термы выходной переменной после агрегации имеют вид треугольной функции и не зависят от длины верхнего основания усеченного терма b_2 (см. рис. 2, б, нижняя проекция). Тогда формулу (3в) сведем к виду

$$S_i = \frac{h_i b_1}{2}. \quad (7)$$

Шаг 8. Подставим формулу (7) в уравнение (4) и получим выражение для нахождения суммарной площади $S_{\text{общ. сум. пл}}$ усеченных термов выходной нечеткой переменной:

$$S_{\text{общ. сум. пл}} = \frac{\sum_{i=1}^n h_i b_1}{2}. \quad (8)$$

Шаг 9. Подставим формулы (1) и (8) в выражение (5) и получим формулу расчета отношения общей площади к суммарной площади усеченных термов:

$$D = \frac{\sum_{i=1}^n h_i}{n \omega_i}. \quad (9)$$

Шаг 10. Подставим уравнение (9) в формулу (6) и получим уравнение для нахождения четкой величины выходной переменной:

$$\text{MAR2} = \left[\frac{\sum_{i=1}^n h_i}{n \omega_i} (\alpha_{\kappa} - \alpha_{\mu}) \right] + \alpha_{\mu} \quad (10)$$

Шаг 11. После процесса дефаззификации выполняется обучение системы. Выходное значение после обучения определяется по формуле (11):

$$\begin{aligned} \omega_{i+1} &= \omega_i + ([\text{MAR2} - \alpha_{\text{target}}] \times \text{Mult}), \\ &\text{until } |\text{MAR2} - \alpha_{\text{target}}| \leq T, \end{aligned} \quad (11)$$

где Mult – скорость обучения (по умолчанию 0.04), T – пороговый коэффициент (по умолчанию 0.01), α_{target} – ожидаемое выходное значение после дефаззификации. Таким образом, выполняется i итераций, пока значение ω_{i+1} не достигнет целевого значения.

ОНТОЛОГИЧЕСКАЯ МОДЕЛЬ

Онтологическая модель нейро-нечеткой сегментации изображений с функцией обучения (рис. 2) предоставляет собой ИАС, позволяющую сегментировать объект и фон на изображении посредством нечеткой логики.




Рис. 2. Онтологическая модель ИАС сегментации изображений с функцией обучения

Онтологическая модель нейро-нечеткой сегментации изображений с функцией обучения состоит из набора понятий и отношений между ними. Ниже приведены таблицы описания онтологии объектов (табл. 1), онтологии атрибутов (табл. 2) и онтологии процессов (табл. 3).

Таблица 1. Онтология объектов

№	Название	Описание	Взаимосвязь
1.	Изображение (Image)	Двумерный массив пикселей, загружаемый из файла Подтипы: - Исходное изображение (OriginalImage): Входное изображение в градациях серого - Результирующее изображение (ResultImage): Выходное изображение после обработки	Пиксель (Pixel), Сегментация (Segmentation)
2.	Пиксель (Pixel)	Элемент изображения с определенной интенсивностью	Треугольная функция принадлежности
3.	Треугольная функция принадлежности (TriangularMembership Function)	Математическая функция для вычисления степени принадлежности пикселя к нечеткому множеству	Дефаззификация
4.	Дефаззификация (Defuzzification)	Процесс преобразования нечетких значений в четкое значение	Весовой коэффициент
5.	Весовой коэффициент (Learn _i)	Адаптивный параметр, обновляемый для минимизации ошибки сегментации	Ошибка
6.	Сегментация (Segmentation)	Процесс разделения изображения на фон и объект	Дефаззификация, Изображение

Таблица 2. Онтология атрибутов

№	Название объекта	Атрибут	Описание
1.	Изображение (Image)	Ширина (Width)	Количество пикселей по горизонтали
		Высота (Height)	Количество пикселей по вертикали
		Значение пикселя (PixelValue)	Интенсивность пикселя в градациях серого
2.	Пиксель (Pixel)	Координаты (Coordinates)	Позиция (i, j) в изображении
		Интенсивность (Intensity)	Значение от 0 до 255 (pixel_value)
		Принадлежность (Membership)	Степень принадлежности к нечеткому множеству (рассчитывается функцией triangular_membership)
3.	Треугольная функция принадлежности	x	Нижняя граница треугольника
		y	Вершина треугольника (максимальная принадлежность)
		z	Верхняя граница треугольника
4.	Дефаззификация (Defuzzification)	ymin	Минимальное выходное значение (0)
		ymax	Максимальное выходное значение (255)
		learn _i	Весовой коэффициент обучения
5.	Весовой коэффициент (Learn _i)	Текущее значение (CurrentValue)	Значение learn _i в диапазоне [0.001, 10]
		Целевое значение (TargetValue)	Ожидаемое значение для объекта (ytarget)

		Ошибка (Error)	Разница между $mar1$ и y_{target}
6.	Сегментация (Segmentation)	Параметры (Parameters)	Список параметров треугольных функций принадлежности ($triangular_params$)
		Метод (Method):	Нечеткая логика с дефаззификацией

Таблица 3. Онтология процессов

№	Название	Описание	Взаимосвязь
1.	Загрузка изображения	Вход: Файл изображения Выход: <code>OriginalImage</code>	Исходное изображение (<code>OriginalImage</code>)
2.	Обработка пикселей	Вход: <code>OriginalImage</code> Выход: <code>ResultImage</code> Действия: • Вычисление принадлежности ($triangular_membership$) • Дефаззификация ($defuzzification$) • Обновление <code>learn1</code> ($update_learn1$)	Пиксель (<code>Pixel</code>)
3.	Нормализация	Вход: <code>ResultImage</code> (тип <code>float32</code>) Выход: <code>ResultImage</code> (тип <code>uint8</code> , диапазон 0–255)	Результирующее изображение (<code>ResultImage</code>)
4.	Отображение	Вход: <code>OriginalImage</code> , <code>ResultImage</code> . Действие: Вывод на экран с помощью <code>cv2.imshow</code>	Изображение (<code>Image</code>)

Для наглядности приведем псевдокод для моделирования онтологической модели сегментации изображений:

1. // Функция вычисления треугольной принадлежности
2. функция `TriangularMembership(s, x, y, z)`:
3. если $s < x$ ИЛИ $s > z$:
4. вернуть 0
5. иначе если $x \leq s \leq y$:
6. вернуть $(s - x) / (y - x)$
7. иначе:
8. вернуть $(z - s) / (z - y)$
- 9.
10. // Функция дефаззификации
11. функция `Defuzzification(memberships, ymin=0, ymax=255, learni=1)`:
12. $n = \text{длина}(\text{memberships})$
13. $\text{term} = \text{сумма}(\text{memberships}) / (n * \text{learni})$
14. $\text{result} = \text{term} * (\text{ymax} - \text{ymin}) + \text{ymin}$
15. вернуть `ограничить(result, 0, 255)`
- 16.
17. // Функция обновления весового коэффициента
18. функция `UpdateLearni(learni, mar1, ytarget, w=0.004, t=0.01)`:
19. если `абсолютная_разница(mar1, ytarget) > t`:
20. $\text{learni_new} = \text{learni} + w * (\text{ytarget} - \text{mar1})$
21. вернуть `ограничить(learni_new, 0.001, 10)`
22. вернуть `learni`
- 23.
24. // Основной алгоритм
25. начало:
26. загрузить изображение в градациях серого как `image`
- 27.
28. задать параметры треугольных функций:
29. $\text{params} = [(0, 85, 170), (85, 170, 255)]$
- 30.
31. создать пустое изображение `result_image` такого же размера, как `image`
- 32.
33. установить начальные параметры:
34. $\text{learni} = 1$
35. $\text{ytarget} = 170$
- 36.

```
37. для каждого пикселя (i,j) в изображении:
38.     pixel_value = image[i,j]
39.
40.     memberships = []
41.     для каждого набора параметров в params:
42.         добавить TriangularMembership(pixel_value, params) в memberships
43.
44.     mar1 = Defuzzification(memberships, 0, 255, learni)
45.     learni = UpdateLearni(learni, mar1, ytarget)
46.     result_image[i,j] = mar1
47.
48. нормализовать result_image в диапазон [0, 255]
49. преобразовать result_image в 8-битный формат
50.
51. показать оригинальное изображение
52. показать сегментированное изображение
53. конец
```

Разработанная онтологическая модель нейро-нечеткой сегментации изображений с функцией обучения представляет собой структурированное и формализованное описание системы, включающее ключевые объекты, их атрибуты и процессы взаимодействия. Предложенные онтологии объектов, атрибутов и процессов обеспечивают четкое представление взаимосвязей между элементами системы, такими как изображение, пиксели, треугольные функции принадлежности, дефаззификация и адаптивный весовой коэффициент. Это позволяет не только концептуально описать алгоритм сегментации, но и заложить основу для его дальнейшей программной реализации и анализа. Псевдокод, приведенный в разделе, отражает практическую реализацию онтологической модели, демонстрируя последовательность шагов обработки данных и их соответствие теоретическим положениям. Таким образом, онтологическая модель служит связующим звеном между математической основой метода и его прикладным применением, подчеркивая системный подход к решению задачи сегментации изображений и потенциал для масштабирования алгоритма в более сложных задачах компьютерного зрения.

ЭКСПЕРИМЕНТЫ

Были проведены две серии экспериментов (с разными изображениями) для наглядного представления результатов работы предложенной модели. На рис. 2–4 представлена первая серия экспериментов, на рис. 5–7 – вторая серия экспериментов. Для этих серий экспериментов была поставлена цель – сегментировать объект от остального фона. В ходе экспериментов также было проведено сравнение разработанной модели с модифицированным методом отношения площадей; модели со стандартным методом отношения площадей.



Рис. 2. а) Оригинальное изображение; б) в градации серого



Рис. 3. Изображение, обработанное с помощью:
а) метода отношения площадей;
б) модифицированного метода отношения площадей




Рис. 4. Изображение, обработанное с помощью нейро-нечеткой системы обучения на основе: а) метода отношения площадей; б) модифицированного метода отношения площадей




Рис. 5. а) Оригинальное изображение; б) в градации серого



а)

б)

Рис. 6. Изображение, обработанное с помощью:
а) метода отношения площадей;
б) модифицированного метода отношения площадей



Рис. 7. Изображение, обработанное с помощью нейро-нечеткой системы обучения на основе: а) метода отношения площадей;
б) модифицированного метода отношения площадей

На основе полученных результатов был рассчитан коэффициент Дайса по формуле

$$\text{Dice} = \frac{2|A \cap B|}{|A| + |B|},$$

где $|A \cap B|$ – количество общих элементов в наборах A и B , $|A|$ – количество элементов в наборе A , $|B|$ – количество элементов в наборе B . Он позволяет количественно оценить степень пересечения элементов в исследуемых выборках. Этот показатель, варьирующийся от 0 до 1, где 1 означает полное совпадение, а 0 – полное отсутствие общих элементов, оказался полезным инструментом для ин-

терпретации данных. Эксперименты включали обработку реальных наборов данных (интенсивность пикселей), что обеспечило надежность и применимость полученных выводов в дальнейшем анализе. Результаты расчетов представлены в табл. 4.

Таблица 4. Результаты экспериментов

		MAR	MAR2	MAR + обучение	MAR2 + обучение
Dice	1-й эксперимент	0.4255	0.7776	0.7558	0.9226
	2-й эксперимент	0.4375	0.5468	0.4545	0.6635

На основании результатов экспериментов можно сделать следующие выводы.

1. Для первого эксперимента значение коэффициента Дайса при использовании метода MAR составило 0.4255, а при методе MAR2 — 0.7776. При добавлении обучения (MAR+обучение) значение увеличилось до 0.7558, а с комбинацией MAR2+обучение достигло максимального значения 0.9226. Это подтверждает, что обучение значительно улучшает результаты, особенно в сочетании с методом MAR2.

2. Для второго эксперимента начальное значение коэффициента Дайса при методе MAR равно 0.4375, а при MAR2 – 0.5468. С добавлением обучения (MAR+обучение) результат повысился до 0.4545, а при использовании MAR2+обучение достиг наивысшего значения 0.6635 среди всех вариантов для этого эксперимента.

Общий анализ показал, что метод MAR2 в комбинации с обучением обеспечивает наилучшие значения коэффициента Дайса по сравнению с традиционным MAR. Наибольший прирост эффективности наблюдался в первом эксперименте. Во втором эксперименте прирост также значительный, но менее выраженный.

Таким образом, что комбинация метода MAR2 с обучением является наиболее эффективной стратегией для повышения значений коэффициента Дайса в обоих проведенных экспериментах.

ЗАКЛЮЧЕНИЕ

Разработанный нейро-нечеткий алгоритм для высокоскоростной сегментации изображений в градациях серого с функцией обучения демонстрирует значительные преимущества по сравнению с традиционными методами. Экспериментальные результаты, полученные на изображениях формата 1024x720, подтвердили, что использование модифицированного метода отношения площадей с адаптивным обучением весового коэффициента позволяет достичь высокой точности сегментации и улучшенной контрастности объектов при минимальных вычислительных затратах. Сравнение с базовым методом отношения площадей установило превосходство предложенного подхода в задачах выделения объектов, таких как сегментация воды на фоне. Эти результаты подтверждают перспективность применения искусственного интеллекта и нечеткой логики в области компьютерного зрения. В дальнейшем планируется расширение исследования путем интеграции алгоритма с многослойными нейронными сетями и тестирования на более сложных наборах данных, что может повысить его универсальность и эффективность в реальных приложениях.

Благодарности

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

СПИСОК ЛИТЕРАТУРЫ

1. *Bobyry M.V., Milostnaya N.A., Bulatnikov V.A.* The fuzzy filter based on the method of areas' ratio // *Applied Soft Computing*, V. 117, 2022, 108449, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2022.108449>
2. *Бобырь М.В., Архипов А.Е., Милостная Н.А.* МЕТОД РАСЧЕТА КАРТЫ ГЛУБИН НА ОСНОВЕ МЯГКИХ ОПЕРАТОРОВ // *Системы и средства информатики*. 2019. Т. 29. № 2. С. 71–84. <https://doi.org/10.14357/08696527190207>
3. *Lee D.H., Chen P.Y., Yang F.J. et al.* "High-Efficient Low-Cost VLSI Implementation for Canny Edge Detection" // *Journal of Information Science & Engineering*, 2020. Vol. 36, no. 3. P. 34–57.

4. Koohi H., Kiani K. User Based Collaborative Filtering Using Fuzzy C-Means // Measurement. 2016. V. 91. P. 134–139. <https://doi.org/10.1016/j.measurement.2016.05.058>
5. Yang Q., Sun L. A Fuzzy Complementary Kalman Filter Based on Visual and IMU Data for UAV Landing // Intern. Journal for Light and Electron Optics. 2018. V. 173. P. 279–291. <https://doi.org/10.1016/j.ijleo.2018.08.011>.
6. S. Eti, S. Yüksel, H. Dinçer. A machine learning and fuzzy logic model for optimizing digital transformation in renewable energy: Insights into industrial information integration // Journal of Industrial Information Integration. 2024. V. 42. P. 100734. <https://doi.org/10.1016/j.jii.2024.100734>. EDN MFEAPI.
7. Romanov A.A., Filippov A.A., Yarushkina N.G. Adaptive Fuzzy Predictive Approach in Control // Mathematics. 2023. V. 11, No. 4. P. 875. <https://doi.org/10.3390/math11040875>. EDN LRGVQT.
8. Bobyr M., Bondarenko B., Malyshev A. High-speed Fuzzy Inference Machine Learning Device Based on Single-Layer Area Ratio Defuzzifier // Intelligence Enabled Research: Proceedings of the 2024 Sixth Doctoral Symposium on Intelligence Enabled Research (DoSIER 2024), Dhupguri, Jalpaiguri, West Bengal, India, November 28–29, 2024. Jalpaiguri, West Bengal, India, 2025. P. 15–25. EDN FXFCKM.
9. Зимичев Е.А., Казанский Н.Л., Серафимов П.Г. Пространственная классификация путем интеграции изображений с использованием метода кластеризации k-means ++ // Компьютерная оптика. 2014. Т. 38, № 2. С. 281–286. <https://doi.org/10.18287/01342452-2014-38-2-281-286>
10. Pereyra M., McLaughlin S. Fast Unsupervised Bayesian Image Segmentation with Adaptive Spatial Regularisation // IEEE Transactions on Image Processing, 2017. V. 26, No. 6. P. 2577–2587. <https://doi.org/10.1109/TIP.2017.2675165>

NEURO-FUZZY IMAGE SEGMENTATION WITH LEARNING FUNCTION

M. V. Bobyr¹ [0000-0002-5400-6817], B. A. Bondarenko² [0000-0001-5415-9015]

^{1, 2}South-West State University, Kursk, 305040, Russia

¹maxboby@gmail.com, ²sikersinko@gmail.com

Abstract

This paper presents a neuro-fuzzy algorithm for high-speed grayscale image segmentation based on a modified defuzzification method using triangular membership functions. The aim of the study is to analyze the effect of simplifying the defuzzification formula on the accuracy and contrast of object selection. The proposed approach includes adaptive learning of the weight coefficient, which allows dynamically adjusting the defuzzification process depending on the target values. The paper compares the basic method of averaging membership values and a modified version taking into account nonlinear weights. Experiments conducted on 1024x720 images demonstrate that the developed algorithm provides high segmentation accuracy and improved object contrast with minimal computational costs. The results confirm the superiority of the proposed method over traditional approaches, emphasizing the prospects for applying artificial intelligence in computer vision problems.

Keywords: IAS, neuro-fuzzy algorithm, image segmentation, defuzzification, artificial intelligence, area ratio method.

REFERENCES

1. Bobyr M.V., Milostnaya N.A., Bulatnikov V.A. The fuzzy filter based on the method of areas' ratio // Applied Soft Computing, Volume 117, 2022, 108449, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2022.108449>
2. Bobyr' M.V., Arkhipov A.Ye., Milostnaya N.A. Metod rascheta karty glubin na osnove myagkikh operatorov // Sistemy i sredstva informatiki. 2019. T. 29. № 2. S. 71–84, <https://doi.org/10.14357/08696527190207>
3. Lee D.H., Chen P.Y., Yang F.J. et al. "High-Efficient Low-Cost VLSI Implementation for Canny Edge Detection" // Journal of Information Science & Engineering, 2020. Vol. 36, No. 3. P. 34–57.

4. Koohi H., Kiani K. User Based Collaborative Filtering Using Fuzzy C-Means // Measurement. 2016. V. 91. P. 134–139.
<https://doi.org/10.1016/j.measurement.2016.05.058>
 5. Yang Q., Sun L. A Fuzzy Complementary Kalman Filter Based on Visual and IMU Data for UAV Landing // Intern. Journal for Light and Electron Optics. 2018. V. 173. P. 279–291. <https://doi.org/10.1016/j.ijleo.2018.08.011>.
 6. S. Eti, S. Yüksel, H. Dinçer. A machine learning and fuzzy logic model for optimizing digital transformation in renewable energy: Insights into industrial information integration // Journal of Industrial Information Integration. 2024. Vol. 42. P. 100734. <https://doi.org/10.1016/j.jii.2024.100734>. EDN MFEAPI.
 7. Romanov A.A., Filippov A.A., Yarushkina N.G. Adaptive Fuzzy Predictive Approach in Control // Mathematics. 2023. Vol. 11, No. 4. P. 875.
<https://doi.org/10.3390/math11040875>. EDN LRGVQT.
 8. Bobyr M., Bondarenko B., Malyshev A. High-speed Fuzzy Inference Machine Learning Device Based on Single-Layer Area Ratio Defuzzifier // Intelligence Enabled Research: Proceedings of the 2024 Sixth Doctoral Symposium on Intelligence Enabled Research (DoSIER 2024), Dhupguri, Jalpaiguri, West Bengal, India, November 28–29, 2024. Jalpaiguri, West Bengal, India, 2025. P. 15–25. EDN FXFCKM.
 9. Zimichev E.A., Kazanskiy N.L., Serafimov P.G. Prostranstvennaya klassifikatsiya putem integratsii izobrazheniy s ispol'zovaniyem metoda klasterizatsii k-means ++ // Komp'yuternaya optika. 2014. T. 38, No. 2. S. 281–286.
<https://doi.org/10.18287/01342452-2014-38-2-281-286>
 10. 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>
-

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



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

Материал поступил в редакцию 26 марта 2025 года