

2. Головки В. А. Нейросетевые методы обработки хаотических процессов // VII Всероссийская научно-техническая конференция «Нейроинформатика. – 2005. – С. 43-91.

3. Головки, В. А. Нейросетевые технологии обработки данных : учебное пособие / В. А. Головки, В. В. Краснопрошин. – Минск : Белорусский государственный университет, 2017. – 263 с. – (Классическое университетское издание). – ISBN 978-985-566-467-4. – EDN GLVGIE.

4. Charu C. Aggarwal Outlier Analysis. - 2 изд. - New York: Springer International Publishing AG, 2017. - 465 с.

УДК 004.932

АНАЛИЗ КЛАССИЧЕСКИХ И НЕЙРОСЕТЕВЫХ МЕТОДОВ ОБНАРУЖЕНИЯ ДЫМА НА ВИДЕОИЗОБРАЖЕНИЯХ

Е. Р. Адамовский

Полоцкий государственный университет имени Евфросинии Полоцкой,
Новополоцк, Беларусь, e.adamovsky@psu.by

The paper reviews existing methods for detecting smoke in video images, taking into account accuracy and performance. Smoke images and their sequences have visual features: specific brightness and color characteristics, indefinite shape, directed low-speed movement, reduction in the energy of high-frequency background components. Approaches that use and combine these features to achieve high accuracy of smoke detection are analyzed, and their advantages and disadvantages are highlighted.

Компьютерное зрение широко применяется в различных прикладных направлениях и позволяет успешно автоматизировать многие задачи. Среди них высокую актуальность имеет автоматическое детектирование дыма, в том числе, в условиях открытого пространства, где применение традиционных датчиков дыма не представляется возможным. Для решения этой задачи перспективен анализ данных видеонаблюдения.

Дым визуально характеризуется: широким диапазоном яркостно-цветовых характеристик; различной плотностью, в зависимости от которой изменяется видимость объектов на динамической сцене; неопределенностью формы; медленным движением [1, 2]. При видеонаблюдении происходит преобразование трехмерного реального изображения в отображаемое на кадре двухмерное, что приводит к потере важной информации при выделении признаков. Данные особенности и ограниченность вычислительных ресурсов аппаратных средств привели к созданию ряда подходов обнаружения с учетом анализируемой динамической сцены и решаемой задачи.

В работе [3] алгоритм требует анализа видеокадров путем выделения связанных областей по признакам движения и цвета в пространстве YUV с применением морфологической обработки. Результирующие области обрабатываются мультискертной системой. Авторы отмечают точность детектирования около 90%, которая может быть повышена за счет анализа большего количества признаков.

В работе [2] предложен частотный анализ для получения дополнительных признаков путем вейвлет-преобразования исходных кадров с целью выделения областей, для которых выполняется условие падения энергии высокочастотных (ВЧ) компонент. Кроме этого, в [2] анализируется поведение границ дыма с помощью скрытой марковской модели. Особенностью алгоритма является то, что дым с его помощью может быть обнаружен с высокой степенью вероятности, когда он возникает перед детализированными объектами.

Частотный анализ способен повысить точность детектирования при его комбинации с другими методами. Такой алгоритм описан в [4], он использует признаки уменьшения резкости объектов, движения, направления, цвета, и реализует оценку направления движения связанных областей, что позволило улучшить точность обнаружения, поскольку дым состоит из продуктов горения, которые, как правило, увлекаются восходящими потоками воздуха от источника возгорания. Общим недостатком работ [3, 4] является ограниченная оценка направления движения дыма, которая может определить его только в одном из трех направлений: вертикально и под углами $\pm 45^\circ$.

В [5] предложен подход, при котором анализируются цвет, форма и пиксельная структура границ связанных объектов. Авторы рассматривают актуальную проблему низкой производительности многоэтапных алгоритмов детектирования и предлагают использовать для ускорения обработки технологию параллельных вычислений CUDA на графических процессорах, с помощью которой показано повышение скорости в несколько раз по сравнению с вычислениями на центральном процессоре, обеспечив режим работы алгоритма в реальном времени. Однако специфика многих алгоритмов детектирования не всегда позволяет эффективно разделять их шаги на параллельные потоки.

Для обнаружения областей дыма применяются сверточные нейронные сети (СНС), включая архитектуры ResNet, DenseNet, а также специальные архитектуры [6, 7], которые направлены на уменьшение размера обучаемых моделей с целью повышения их быстродействия. В работе [6] предлагаемая искусственная нейронная сеть (ИНС) имеет три слоя свертки (convolution) и четыре полносвязных слоя (dense), а обученная модель занимает объем памяти всего 8 МБ. Также в области визуального детектирования пожаров применяются СНС класса YOLOv2 [8], YOLOv3-v8 [9] с покадровым анализом видеоданных. Общим недостатком алгоритмов на основе ИНС является необходимость в большой базе данных с реальными изображениями, полученными в различных условиях и фоновых вариациях [9, 10]. Кроме этого, необходимо учитывать признаки движения объектов, что приводит к значительному усложнению архитектур СНС и увеличению времени обработки и обучения. Соответственно, для эффективного применения в режиме реального времени СНС используются автономные специализированные вычислители или нейроускорители.

Обучаемые классификаторы применяются после алгоритмического выделения признаков. В работе [11] используются фильтр Калмана и СНС, детекторы движения и цветовых характеристик. Однако такой подход не демонстрирует высокую точность по сравнению с аналогичными решениями и обладает низкой производительностью. Работа [12] посвящена развитию алгоритма из [11] и включает дополнительно контурный и пространственно-временной анализ, что позволяет исключить не содержащие дым области на первых этапах алгоритма с целью снижения нагрузки на классификаторы. Описанный алгоритм позволяет достичь большей точности детектирования дыма по сравнению с подходом из [11], однако не способен обеспечить работу в режиме реального времени на одноплатных компьютерах Raspberry Pi или Jetson Nano (JN), которые перспективны для реализации дополнительных функций в распределенных системах компьютерного зрения без изменения их архитектуры [7].

Алгоритмы, направленные на одновременное обнаружение визуальных признаков пожара, дыма и пламени [13, 14], позволяют уменьшить общие вычислительные затраты, однако характеризуются меньшей точностью детектирования. Напротив, учитывающие множество признаков методы способны достигать высоких значений точности, но имеют низкую производительность [15]. Поэтому алгоритмы, выполняющие детектирование дыма, должны обладать хорошими качественными характеристиками, которые могут быть обеспечены только при учете многих признаков для раннего обнаружения, и низкими вычислительными затратами.

Сравнение точности и производительности рассмотренных алгоритмов представлено в таблице. Указаны стандартные метрики: процент ложноположительных (FP) и ложноотрицательных (FN) срабатываний, ассгау (ACC), recall (REC), precision (PREC) и F₁-score.

Таблица – Сравнение характеристик существующих алгоритмов детектирования дыма в реальном времени

Метод	Метрики точности, %						Производительность, к/с
	FP	FN	ACC	REC	PREC	F ₁	
LBP-SVM [15]	0	2.2	97.8	-	-	-	0.2 (240p, Xeon E5-1620)
Wavelet-k-NN [15]	0.5	2	97.4	-	-	-	
Lightweight CNN [7]	1.9	0.8	97.9	97.2	98.3	97.7	24 (Pi4)
FireNet [6]	1.2	2.3	96.5	97.5	95.5	96.5	-
YOLOv2 [8]	3.4	2.9	96.8	97	97	95.4	21 (1080p, JN)
R-CNN [8]	8.5	0	96.5	-	-	-	-
De-Lascio et al. [3, 8]	13.3	0	92.9	-	-	-	-
Fu et al. [8, 10]	14	8	91	-	-	-	-

Продолжение таблицы

Метод	Метрики точности, %						Производительность, к/с
	FP	FN	ACC	REC	PREC	F ₁	
Filonenko et al. [5, 8]	-	-	85	96	85	90	-
CWC-YO-LO v5s [9]	-	-	-	88.1	91.8	90	43 (GTx1050)
Gagliardi et al. [11]	-	-	84.4	-	86.4	88.4	3 (480p, Pi3) 18 (480p, JN)
Advised [11, 12]	-	-	85	-	88.9	87.5	1 (720p, Pi3)
YOLO v5s [9]	-	-	-	83.5	90.4	87	46 (GTx1050)
YOLOv8 [9]	-	-	-	77.1	91.2	84	41 (GTx1050)
SSD [9]	-	-	-	81.3	85.3	83	52 (GTx1050)
YOLOv3 [9]	-	-	-	77.1	75.5	76	50 (GTx1050)
YOLOv7 [9]	-	-	-	69.1	73.4	71	12 (GTx1050)

Таким образом, с учетом минимизации вычислительных затрат и обеспечения высокой точности обнаружения с низким уровнем ложных тревог является построение алгоритма, включающего этапы: детектирование движения; пространственно-временной анализ для движущихся областей; цветовая сегментация с целью выделения предварительных областей, которые могут содержать дым. Данные шаги направлены на обеспечение минимизации пропуска областей с дымом, не допуская вероятности ложного обнаружения.

Затем для таких областей может быть применен анализ наличия ВЧ компонент и изменения контраста на кадрах видеопоследовательности с учетом фона контролируемой динамической сцены. Такой подход позволит выявить регионы, в которых элементы фона подвергаются скрытию дымовой завесой. С учетом характеристик дыма, перспективным является применение оценки направления движения в выявленных областях и анализа изменения направленности движущихся областей во времени.

Список использованной литературы

1. Hashemzadeh M. Smoke detection in video using convolutional neural networks and efficient spatio-temporal features / M. Hashemzadeh, N. Farajzadeh, M. Heydari // *Applied Soft Computing*. – 2022.– P. 128.
2. *Methods and Techniques for Fire Detection: Signal, Image and Video Processing Perspectives* / A. Cetin et al. // Elsevier. – 2016.
3. Di Lascio R. Improving Fire Detection Reliability by a Combination of Video-analytics / R. Di Lascio et al. // 11th International Conference on Image Analysis and Recognition, ICIAR. – 2014.

4. Bohush R. Smoke and flame detection in video sequences based on static and dynamic features / R Bohush, N. Brouka // *Signal Processing Algorithms, Architectures, Arrangements, and Applications Proceedings (SPA)*. Proc. of the Conference, Poznan, 26-28th September 2013. – P.20–25.
5. Filonenko A. Fast Smoke Detection for Video Surveillance Using CUDA / A. Filonenko, D. C. Hernández, Jo. Kang-Hyun // *IEEE Transactions on Industrial Informatics*. – 2018. – №14. – P. 725–733.
6. Jadon A. FireNet: A Specialized Lightweight Fire & Smoke Detection Model for Real-Time IoT Applications / A. Jadon et al. // 10.48550/arXiv.1905.11922. – 2019.
7. Sankarasubramanian P. Realtime Pipeline Fire & Smoke Detection Using a Lightweight CNN Model / P. Sankarasubramanian, V. Kumar // *IEEE International Conference on Machine Learning and Applied Network Technologies (ICMLANT)*, Soyapango, El Salvador. – 2021.
8. Saponara S. Real-time video fire/smoke detection based on CNN in antifire surveillance systems / S. Saponara, A. Elhanashi, A. Gagliardi // *Journal of Real-Time Image Processing*. – 2021.
9. Zou Y. Smoke Detection of Marine Engine Room Based on a Machine Vision Model (CWC-Yolov5s) / Y. Zou et al. // *Journal of Marine Science and Engineering*. – 2023. – №11(8). – P. 1564.
10. Fu T. J. Forest Fire Recognition Based on Deep Convolutional Neural Network Under Complex Background / T. J. Fu et al. // *Computer and Modernization*. – 2019.
11. Gagliardi, A. A real-time video smoke detection algorithm based on Kalman filter and CNN / A. Gagliardi, F. Gioia, S. Saponara // *Journal of Real-Time Image Processing*. – 2021. – №18(5).
12. Gagliardi A. AdViSED: Advanced Video Smoke Detection for Real-Time Measurements in Antifire Indoor and Outdoor Systems / A. Gagliardi, S. Saponara // *Energies*. – 2020. – №13(8). – P. 2098.
13. Богуш, Р.П. Алгоритм комплексного обнаружения дыма и пламени на основе анализа данных систем видеонаблюдения/ Р.П. Богуш, Д.А. Тычко // *Доклады БГУИР*. – 2015. – №6(92). – С. 65–71.
14. Ye Sh. An Effective Algorithm to Detect Both Smoke and Flame Using Color and Wavelet Analysis / Sh. Ye, Zh. Bai, H. Chen, R. Bohush and S. Ablameyko // *Pattern Recognition and Image Analysis*. – 2017. – Vol. 27. – №1. – P. 131–138.
15. Park K. Smoke detection in ship's engine room based on video images / K. Park, C. Bae // *IET Image Processing*. – 2020.