

Marek SZCZEPAŃSKI
Politechnika Śląska

WPROWADZENIE DO PROBLEMU DETEKcji ŹRÓDEŁ NISKIEJ EMISJI NA TERENACH WIEJSKICH Z WYKORZYSTANIEM BEZZAŁOGOWYCH STATKÓW POWIETRZNYCH

Streszczenie. W pracy omówiono problem detekcji źródeł emisji zanieczyszczeń w obszarze niskiej zabudowy z wykorzystaniem bezzałogowych statków powietrznych. Dokonano analizy problemu i przedstawiono metody jego rozwiązania. Przeanalizowane zostały różne scenariusze akwizycji danych oraz ich wpływ na możliwości realizacji zadania.

INTRODUCTION TO THE PROBLEM OF DETECTION OF LOW EMISSION SOURCES IN RURAL AREAS USING UNMANNED AERIAL VEHICLES

Summary. The paper discusses the problem of detecting emission sources in a low buildings area using unmanned aerial vehicles. The problem was analyzed and methods of solving it were presented. Various data acquisition scenarios and their impact on the feasibility of the task were analyzed.

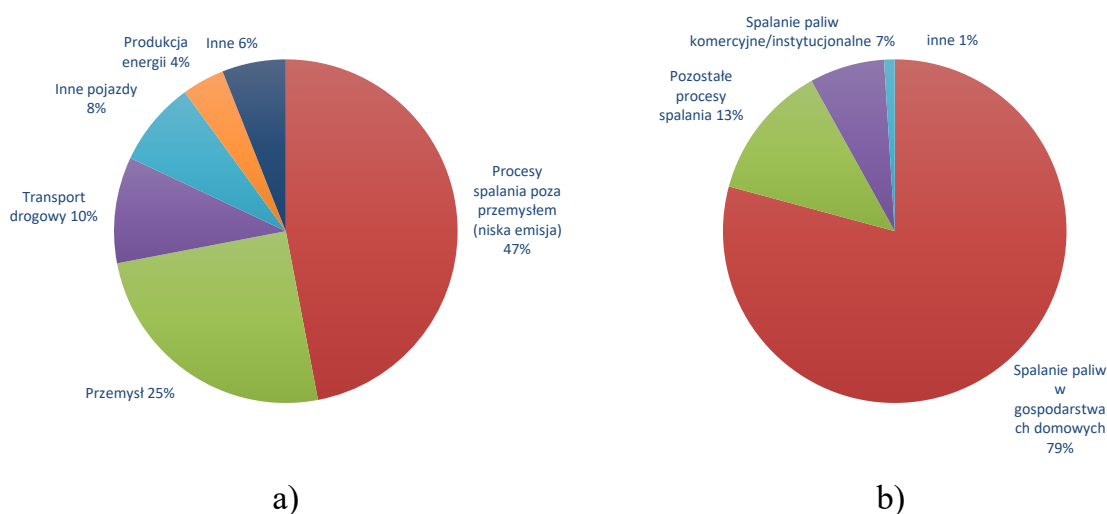
1. Wprowadzenie

1.1. Zanieczyszczenie powietrza i jego wpływ na nasze zdrowie

Zanieczyszczenie powietrza jest bardzo poważnym problemem we współczesnym świecie, przykładowo, emisja gazów cieplarnianych wpływa na katastrofalne w skutkach globalne zmiany klimatyczne. Wg informacji przedstawionych w raporcie Europejskiej Agencji Środowiska [4] zanieczyszczenie powietrza jest główną przyczyną przedwczesnych zgonów i chorób oraz stanowi największe środowiskowe zagrożenie dla zdrowia w Europie, jest odpowiedzialne za około 400 000 przedwczesnych zgonów rocznie w Europejskim Obszarze Gospodarczym.

Jednak to nie tylko emisja przemysłowa wpływa bezpośrednio na jakość naszego życia, największy wpływ na nasze zdrowie ma emisja pyłów zawieszonych i powstający w jej wyniku smog. Jak się okazuje, za zdecydowaną większość emisji pyłów zawieszonych odpowiada tak zwana „niska emisja”, czyli emisja powstająca na niskiej wysokości, głównie wyniku spalania węgla i innych paliw stałych na potrzeby ogrzewania domów. Raporty dotyczące zanieczyszczenia powietrza podają statystyki dotyczące stężenia pyłów o różnej frakcji cząsteczek: PM 10 i PM 2.5, czyli mieszaniny cząstek zawieszonych w powietrzu o średnicach mniejszych odpowiednio od $10\mu\text{m}$

oraz $2,5\mu\text{m}$. Pył zawieszony może zawierać substancje toksyczne takie jak wielopierścieniowe węglowodory aromatyczne (np. rakotwórczy benzo[a]piren), metale ciężkie oraz dioksyny i furany. Zgodnie z informacjami Krajowego Ośrodka Bilansowania i Zarządzania Emisjami (KOBiZE) za zdecydowaną większość szkodliwych dla naszego zdrowia odpowiada właśnie emisja zanieczyszczeń powstałych przy spalaniu paliw stałych na potrzeby ogrzewania domów jednorodzinnych [9, 10]. Na rysunku 1 przedstawiono rozkład procentowy głównych źródeł emisji cząstek PM 2.5 oraz Benzo[a]pirenu w Polsce w 2017 roku, zostały one przygotowane na podstawie danych raportowanych przez KOBiZe oraz prezentowanych przez Polski Alert Smogowy [9, 10].



Rys. 1. Główne źródła szkodliwych zanieczyszczeń w Polsce w roku 2017
a) pył PM 2.5, b) benzo[a]piren

Poziom zanieczyszczeń pyłami zawieszonymi jest monitorowany zarówno przez jednostki rządowe, takie jak Główny Inspektorat Ochrony Środowiska (GIOŚ), jak i liczne firmy, organizacje pozarządowe oraz osoby prywatne. Porównując dane rządowe oraz dane z innych sieci pomiarowych, można zauważyć, że oficjalne pomiary GIOŚ, mimo, że są alarmujące, nie oddają w pełni powagi problemu. Oficjalne stacje pomiarowe są niezbyt liczne, do tego zlokalizowane są zwykle na terenach miejskich, podczas gdy skala zanieczyszczenia powietrza na wsiach wydaje się być znacznie większa, potwierdzają to analizy danych pomiarowych ze źródeł pozarządowych.

Mimo licznych programów mających ograniczyć zanieczyszczenie powietrza, Polska jest jednym z niechlubnych „liderów” europejskich i światowych rankingów zanieczyszczenia powietrza [4], głównie za sprawą emisji pyłów związanej ze spalaniem węgla w domowych kotłowniach. Władze samorządowe coraz częściej wprowadzają przepisy ograniczające możliwość wykorzystania paliw stałych do ogrzewania budynków, przykładem może być uchwała antysmogowa dla Krakowa z dnia 15 stycznia 2016 r., czy uchwała Sejmiku Województwa Śląskiego z 7 kwietnia 2017 r. Aby można było skutecznie egzekwować ograniczenia w spalaniu paliw stałych, konieczna jest możliwość skutecznego monitorowania rzeczywistych źródeł emisji zanieczyszczeń. Jedną z opcji jest wykorzystanie metod wizji komputerowej do detekcji dymu z bezałogowych statków powietrznych.

1.2. Wizyjne metody detekcji dymu

W literaturze można znaleźć liczne rozwiązania problemu detekcji dymu oraz ognia, niestety zdecydowana większość zaproponowanych rozwiązań dotyczy ochrony przeciwpożarowej i wykrywania pożarów lasów. Najczęściej do tego celu stosowane są statyczne kamery w sposób ciągły rejestrujące dane. Pierwszym krokiem opisywanych metod jest najczęściej detekcja ruchu, w tym celu stosowane są takie rozwiązania jak:

- wyznaczenie gradientu ruchu za pomocą klatek różnicowych [2,12],
- detekcja zmian w chrominancji – dym zazwyczaj ma niższą chrominancję [13],
- estymacja i odjęcie tła z wykorzystaniem algorytmów wykorzystujących mieszaniny gaussowskie GMM (*ang. Gaussian Mixture Model*) [1],
- blokowa estymacja ruchu, analogiczna do technik stosowanych we współczesnych algorytmach kompresji wideo [6, 13],
- metody przepływu optycznego (*ang. optical flow*) [8].

Kolejnym etapem jest zazwyczaj klasyfikacja obszarów zawierających dym, z uwagi na dużą zmienność i różnorodność zjawiska nie jest to zagadnienie banalne. Do jego rozwiązania można stosować cechy chromatyczne dymu [13], lokalną utratę ostrości w obszarach zadymionych, dynamiczne właściwości dymu [13, 14, 16], miary energii wykorzystujące transformatę falkową (*ang. Discrete Wavelet Transform -DWT*) [1, 6, 12] czy dyskretną transformatę kosinusową (*ang. Discrete Cosine Transform – DCT*) [6]. Ciekawym, podejściem jest też zastosowanie lokalnych wzorców binarnych (*ang. Local Binary Patterns – LBP*) [11, 14] oraz wersji dynamicznej wyznaczonej dla ruchu (*ang. Local Binary Motion Patterns – LBPM*) [5]. Często też cechy wykorzystywane do detekcji ruchu, mogą zostać wykorzystane na etapie klasyfikacji np. cechy ruchu wyznaczone za pomocą metod przepływu optycznego [2].

Inna grupa rozwiązań stosuje z powodzeniem metody głębokiego uczenia do detekcji dymu [11], zazwyczaj wymagają one dokładnie przygotowanego zbioru uczącego, najczęściej konieczne jest też ręczne przygotowanie odpowiednich „masek dymu”, wyjątkowo efektywnym rozwiązaniem wydaje się być zastosowanie sieci Mask R-CNN [7].

2. Detekcja dymu w zdjęciach lotniczych

Opisane w poprzedniej sekcji rozwiązania, nie mogą zostać bezpośrednio zastosowane do detekcji dymu w zdjęciach czy sekwencjach lotniczych, powstającego w wyniku niskiej emisji. Pierwszym napotkanym problemem jest uzyskanie sekwencji statycznych oraz znaczna różnorodność dymu emitowanego z domowych instalacji grzewczych. Jednym z pierwszych wyzwań przy analizie problemu jest wybór odpowiedniej platformy do akwizycji zdjęć, przygotowanie szczegółowych założeń dotyczących sposobu pozyskiwania danych i przygotowanie planu nalotu.

2.1. Wybór platformy latającej

Akwizycja zdjęć lotniczych może być w ogólnym przypadku realizowana z wykorzystaniem zarówno załogowych, jak i bezzałogowych statków powietrznych. Do niedawna większość materiału była pozyskiwana głównie za pomocą samolotów

wyposażonych w specjalne zestawy do akwizycji danych. Jednak, współcześnie, coraz częściej korzysta się ze znacznie tańszych rozwiązań wykorzystujących bezzałogowe statki powietrzne, czyli popularne drony. Na rynku dostępnych jest wiele platform dedykowanych właśnie do wykonywania nalotów fotogrametrycznych, wyposażonych w systemy kamer i sensorów oraz w zaawansowane systemy pozycjonowania, umożliwiające lokalizację z centymetrową dokładnością – RTK (*ang. Real-Time Kinematic*) oraz DGPS (*ang. Differential GPS*).

Osobnym zagadnieniem jest wybór typu statku powietrznego, do wyboru mamy platformy wielowirnikowe oraz płatownice. Zaletą tych pierwszych jest prostota obsługi oraz możliwość pozostania w zawisie, płatownice zaś mogą znacznie dłużej pozostawać w powietrzu.

W przypadku opracowania kompletnej platformy do detekcji dymu należy rozważyć rozwiązania proste i ekonomiczne. W badaniach wykorzystano więc standardowe platformy czterowirnikowe firmy DJI, większość danych została pozyskana za pomocą dronów DJI Mavic Air, Mavic Air 2s oraz Mavic 2 Enterprise Dual – ten ostatni wyposażony jest zarówno w standardową kamerę RGB jak i kamerę termowizyjną. Zastosowanie termowizji na dalszym etapie prac, może wspomóc lokalizację aktywnych kominów będących wyraźnymi źródłami ciepła.

2.1. Akwizycja obrazów – plan nalotu


Wykorzystując czterowirnikowe platformy latające mamy dużą swobodę w doborze sposobu akwizycji danych, w przeciwieństwie do płatownic możemy pozyskiwać niemal statyczne sekwencje, utrzymując statek powietrzny w zawisie. Przy planowaniu nalotu musimy uwzględnić następujące czynniki:

- rodzaj pozyskiwanych danych – wideo w ruchu, wideo stacjonarne, obrazy statyczne (także ortofotomapa pozyskana z nalotu fotogrametrycznego),
- kąt i nachylenie zdjęć – pionowe, prawie pionowe, nachylone i perspektywiczne,
- pasmo akwizycji – RGB, multi/hiperspektralne i termowizyjne,
- pułap i zasięg.

Biorąc pod uwagę opisywane w literaturze metody i możliwość zawisu, zdecydowano na rejestrację sekwencji stacjonarnych. Dzięki dobrej stabilizacji pozycji drona i dodatkowej mechanicznej stabilizacji kamery możliwe jest pozyskanie sekwencji „prawie statycznych”. Na potrzeby późniejszych etapów badań wykonano także naloty fotogrametryczne w wyniku których uzyskano serię zdjęć umożliwiających stworzenie ortofotomapy. Zdecydowano, że obraz będzie rejestrowany za pomocą kamery skierowanej pionowo w dół (nadir), co umożliwi wykorzystanie pozyskanych danych także na późniejszych etapach projektu. Z uwagi na ograniczenia sprzętowe, większość danych została pozyskana za pomocą sensora RGB, dla części danych dostępny jest też obraz termiczny.

Oddzielnym problemem jest wybór pułapu nalotu oraz ogniskowej kamery. Zbyt niski pułap ogranicza obszar akwizycji, zaś zbyt wysoki może uniemożliwić poprawną detekcję. Dokonując nalołów należy brać pod uwagę aktualnie obowiązujące ograniczenia w przestrzeni lotniczej. Na początkowym etapie projektu, zgodnie z obowiązującymi wówczas ograniczeniami prawnymi, rozważano szeroki zakres pułapu nalotu, jednak zmiany ustawowe, wprowadzone z początkiem roku 2021, ograniczyły maksy-

malny pułap nalotu do 120 m. Na rysunku 2 pokazano przykładowe obrazy uzyskane dla różnych wysokości – zbyt niski pułap wyraźnie ogranicza obszar detekcji, równocześnie może stanowić problem związany z prywatnością mieszkańców. Zdecydowano więc na wybór najwyższego możliwego pułapu – czyli 100 lub 120m (w zależności od ograniczeń w przestrzeni powietrznej dla danego obszaru).



Rys. 2. Przykładowa klatka pozyskana z drona dla różnego pułapu

2.2. Schemat działania algorytmu dla sekwencji stacjonarnych

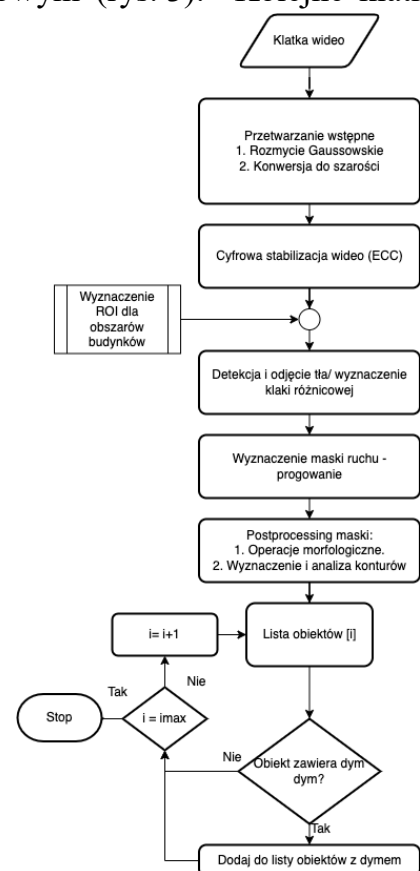
Zaproponowany algorytm detekcji dymu w sekwencjach stacjonarnych można podzielić na etapy przedstawione na schemacie blokowym (rys. 3). Kolejne klatki wideo poddawane są przetwarzaniu wstępnemu oraz stabilizacji. Następnie, wyznaczane są maski ruchu przy opcjonalnym uwzględnieniu regionów z wyznaczonymi w osobnym procesie obszarami budynków. W kolejnym kroku, uzyskane maski poddawane są szeregowi operacji mających na celu wyznaczenie spójnych masek o wypukłych konturach. Ostatecznie dokonana jest klasyfikacja decydująca o tym czy dany obiekt będzie uznany za obszar dymu.

2.3. Detekcja obszarów zawierających dym

W niniejszej pracy przetestowano trzy metody detekcji ruchomych obiektów:

1. wyznaczanie klatki różnicowej,
2. odjęcie wyznaczonej klatki tła na podstawie mediany wybranych klatek z sekwencji wideo,
3. odejmowanie tła z wykorzystaniem algorytmu mieszania gaussowskich do wyznaczania tła (MOG subtractor) [1].

Dwie pierwsze metody zakładają, że dysponujemy sekwencją statyczną. Niestety, dla rzeczywistych sekwencji pozyskanych z drona, warunek ten

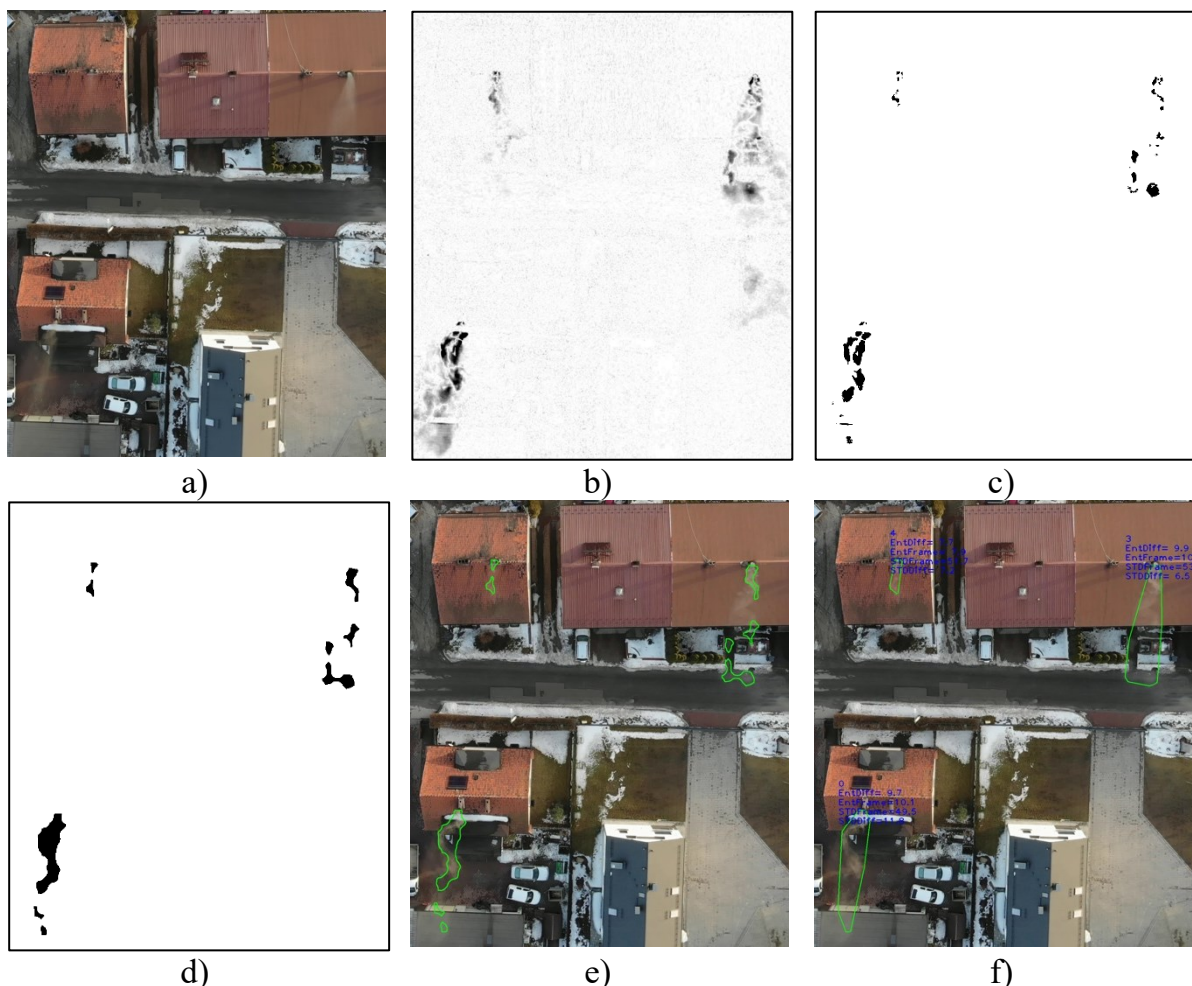


Rys. 3. Ogólny schemat blokowy algorytmu

nie jest spełniony – mimo skutecznej stabilizacji pozycji oraz samej kamery, widoczne są subtelne przesunięcia obrazu. Są one czasem na tyle zauważalne, że wpływają w znacznym stopniu także na skuteczność metody wykorzystującej algorytm MOG. Aby uzyskać skuteczną detekcję konieczna jest więc dodatkowa cyfrowa stabilizacja obrazu.

Do wyrównywania kolejnych klatek zastosowano algorytm ECC (ang. *Enhanced Correlation Coefficient Maximization*) [3], przy czym założono Euklidesowy model przemieszczeń.

Na rysunku 4 pokazano przykład tworzenia masek dla metody bazującej na klatce tła wyznaczonej metodą mediany z sekwencji wejściowej. Tło tą metodą może być wyznaczone zarówno przed uruchomieniem głównej części algorytmu, jak i w trakcie jego działania, wówczas wyznaczone jest tło dla wybranego zakresu danych historycznych. W tym przypadku klatka tła została wyznaczona jako mediana z 30 klatek w sekwencji, przy czym założono, że odległość pomiędzy tymi klatkami musi wynosić przynajmniej 10. Tak uzyskane tło widoczne jest na ilustracji poniżej (rys. 4a).



Rys. 4. Etapy tworzenia maski dymu: a) klatka tła, b) obraz różnicowy, c) wynik progowania, d-e) maska i uzyskane krawędzie po wykonaniu filtracji morfologicznej, f) ostateczny wynik po filtracji konturów

Na kolejnych obrazach przedstawiono kolejno: b) klatkę różnicową, c) wynik wstępnej segmentacji maski (progowanie), d) maskę po filtracji morfologicznej (erozja

i zamknięcie), e) wynik wstępnej detekcji konturów maski oraz f) wynikowe maski dymu, powstałe przez połączenie bliskich konturów i zamknięcie ich otoczką wypukłą. Obrazy maski oraz klatka różnicowa, zostały przedstawione w postaci negatywu. Dodatkowo, dla poprawy czytelności prezentacji, klatka różnicowa została poddana operacji rozciągania histogramu.

2.4. Klasyfikacja obiektów

W wielu przypadkach, mimo, że dysponujemy statyczną sekwencją wideo, dodatkowo poddaną stabilizacji cyfrowej, na obrazie mogą pojawić się inne ruchome obiekty, najczęściej są to samochody, piesi czy rowerzyści. Czasem wykrywany jest też ruch gałęzi i innych obiektów pod wpływem wiatru, pojawiają się też artefakty wynikające z niedoskonałej stabilizacji. Problem można rozwiązać ograniczając się do detekcji ruchu wyłącznie dla obszaru dachów, jednak wymaga to użycia dodatkowych danych pozyskanych np. z map cyfrowych. Zakładając, że są one poprawne, możemy uzyskać ROI ograniczające obszar detekcji dymu. Problemem może być jednak dokładne przeliczanie współrzędnych mapy do współrzędnych kamery drona. Innym aktualnie testowanym rozwiązaniem jest wykorzystanie sieci Mask R-CNN [7] do detekcji obszarów dachów. Jednak w przypadku braku takich danych konieczne jest zbudowanie klasyfikatora umożliwiającego odrzucenie obszarów zawierających inne obiekty. W trakcie badań zauważono, że o ile w obrazie wejściowym dym cechuje się bardzo dużą różnorodnością i trudno jest wyznaczyć cechy umożliwiające skuteczną klasyfikację, to już obrazy różnicowe umożliwiają znacznie prostsze odróżnienie dymu od pozostałych obiektów. W naszym przypadku do budowy wektora cech wykorzystano następujące cechy obiektów określonych za pomocą uzyskanych masek ruchu:

- entropia dla klatek różnicowych,
- entropia pikseli obszaru dla klatek wejściowych,
- odchylenie standardowe w obrazach różnicowych,
- odchylenie standardowe pikseli obiektów dla klatek wejściowych.

3. Podsumowanie i kierunki dalszych prac

W prezentowanej pracy przedstawiono zarys problemu detekcji źródeł niskiej emisji w obszarach niskiej zabudowy – głównie na terenach wiejskich. Rozwojowa wersja algorytmu ma dosyć wysoką skuteczność detekcji, jednak wymaga ona gruntownej ewaluacji. W dalszej części badań zostaną porównane wyniki dla „surowego” algorytmu detekcji i klasyfikacji, z algorytmem wzbogaconym informacją o lokalizacji budynków. Sporą wadą prezentowanego rozwiązania jest konieczność rejestracji stacjonarnych sekwencji wideo, co znacząco może wydłużyć czas monitoringu dla zadanego obszaru. Dużo wygodniejszym rozwiązaniem byłaby możliwość prowadzenia detekcji bezpośrednio dla sekwencji wideo w ruchu lub dla pojedynczych obrazów. Niestety duża różnorodność wizualna dymu czyni to zadanie znacznie bardziej skomplikowanym. Zaprezentowany w niniejszej pracy algorytm, posłuży do automatycznego przygotowania zbioru treningowego dla sieci neuronowych umożliwiających detekcję obszarów dymu np. Mask R-CNN [7].

LITERATURA

1. Calderara S., Piccinini P., Cucchiara R. (2008) Smoke Detection in Video Surveillance: A MoG Model in the Wavelet Domain. In: Gasteratos A., Vincze M., Tsotsos J.K. (eds) Computer Vision Systems. ICVS 2008. Lecture Notes in Computer Science, vol 5008. Springer, Berlin, Heidelberg.
2. Chunyu, Y., Jun, F., Jinjun, W. et al.: Video Fire Smoke Detection Using Motion and Color Features, *Fire Technol* (2010) 46: 651.
3. Evangelidis G. D., Psarakis E. Z.: "Parametric Image Alignment Using Enhanced Correlation Coefficient Maximization, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, no. 10, pp. 1858-1865, Oct. 2008.
4. EEA (European Environment Agency): Air quality in Europe — 2020 report. EEA Report No 09/2020, Copenhagen, Denmark.
5. Favorskaya M., Pyataeva A., Popov A.: Verification of Smoke Detection in Video Sequences Based on Spatio-temporal Local Binary Patterns, *Procedia Computer Science*, Volume 60, 2015, Pages 671-680, ISSN 1877-0509.
6. Gubbi J., Marusic S., Palaniswami M., Smoke detection in video using wavelets and support vector machines, *Fire Safety Journal*, Volume 44, Issue 8, 2009, Pages 1110-1115, ISSN 0379-7112.
7. He K., Gkioxari G. Dollár P., Girshick R.: Mask R-CNN, 2017 IEEE International Conference on Computer Vision (ICCV), 2017, pp. 2980-2988,
8. Kolesov I., Karasev P., Tannenbaum A, Haber E.: Fire and smoke detection in video with optimal mass transport based optical flow and neural networks, 2010 IEEE International Conference on Image Processing, Hong Kong, 2010, pp. 761-764.
9. Krajowy Ośrodek Bilansowania i Zarządzania Emisjami (KOBiZE), Instytut Ochrony Środowiska – Państwowy Instytut Badawczy: Krajowy bilans emisji SO₂, NO_x, CO, NH₃, NMLZO, pyłów, metali ciężkich i TZO za lata 2015 – 2017, Warszawa 2019.
10. PAS (Polski Alarm Smogowy): Program PAS dla czystego powietrza w Polsce, Warszawa 2020.
11. Xu G., Zhang Y, Zhang Q, Lin G., Wang J.: Deep domain adaptation based video smoke detection using synthetic smoke images, *Fire Safety Journal*, Volume 93, 2017, Pages 53-59, ISSN 0379-7112.
12. Xu Z., Xu J.: Automatic Fire Smoke Detection Based on Image Visual Features, 2007 International Conference on Computational Intelligence and Security Workshops (CISW 2007), Heilongjiang, 2007, pp. 316-319.
13. Yuan F.: A fast accumulative motion orientation model based on integral image for video smoke detection, *Pattern Recognition Letters*, Volume 29, Issue 7, 2008, Pages 925-932, ISSN 0167-8655.
14. Yuan F.: Video-based smoke detection with histogram sequence of LBP and LBPV pyramids, *Fire Safety Journal*, Volume 46, Issue 3, 2011, Pages 132-139, ISSN 0379-7112.
15. Zhang Q., Lin G, Zhang Y., Xu G, Wang J., Wildland Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images, *Procedia Engineering*, Volume 211, 2018, Pages 441-446, ISSN 1877-7058.
16. Zhao Y, Zhou Z, Xu M.: Forest Fire Smoke Video Detection Using Spatiotemporal and Dynamic Texture Features, *Journal of Electrical and Computer Engineering*, vol. 2015, Article ID 706187, 7 pages, 2015.