

Wiktor A. JEĆZMIŃSKI, Artur BAL
Politechnika Śląska

WYKORZYSTUJĄCA INFORMACJĘ OBRAZOWĄ METODA DETEKCJI MGŁY W CZASIE RZECZYWISTYM — BADANIA WSTĘPNE

Streszczenie. W pracy przedstawiono wstępne badania nad pasywną metodą detekcji mgły z wykorzystaniem informacji obrazowej, ze szczególnym uwzględnieniem systemów transportowych. Szczególny nacisk położono na połączenie krótkiego czasu przetwarzania z możliwie wysoką dokładnością detekcji. Opracowany algorytm charakteryzuje się krótkim i mało zmiennym czasem przetwarzania. Właściwości te, wraz z relatywnie wysoką efektywnością rozpoznawania, pozwalają na zastosowanie tego algorytmu do testów w rzeczywistych systemach przetwarzania brzegowego.

REAL-TIME FOG DETECTION METHOD USING IMAGE DATA: A PRELIMINARY STUDY

Summary. The paper presents a preliminary study on a passive fog detection method using image data, with a particular focus on transport systems. Particular emphasis was placed on combining a short processing time with the highest possible detection accuracy. The developed algorithm is characterised by a short and highly stable processing time. These properties, along with a relatively high recognition efficiency, allow it to be considered for testing in real-world edge computing systems.

1. Wprowadzenie

Zapewnienie wysokiego poziomu bezpieczeństwa we współczesnym transporcie opiera się w dużej mierze na niezawodnym działaniu zaawansowanych systemów wspomagania kierowcy (ang. *Advanced Driver Assistance Systems*, ADAS). Rozwiązania z tego zakresu stanowią również fundament rozwoju pojazdów autonomicznych. Jednym z istotnych wyzwań, przed którymi stoją te technologie, jest zagwarantowanie ich prawidłowego działania w trudnych warunkach atmosferycznych.

Szczególne zagrożenie stanowi mgła, która często ma charakter lokalny, przez co przewidzenie miejsca, czasu oraz intensywności jej wystąpienia bywa niemożliwe. Obecność mgły drastycznie wpływa na dynamikę ruchu drogowego, wymuszając natychmiastową i adekwatną reakcję systemów pokładowych (np. poprzez zwiększenie odległości między pojazdami czy automatyczne włączenie odpowiednich świateł). Z uwagi na lokalny charakter tego zjawiska, jego detekcja musi być realizowana bezpośrednio na poziomie pojazdu. Biorąc pod uwagę rygorystyczne wymagania stawiane systemom detekcji mgły — w tym bezwzględny wymóg pracy w czasie rzeczywistym, ograniczo-

ne zasoby obliczeniowe, a w przypadku pojazdów elektrycznych również ograniczony zasób energii w akumulatorach — uzasadnionym kierunkiem rozwoju jest stosowanie rozwiązań zorientowanych na przetwarzanie brzegowe (ang. *edge computing*). Z tego względu automatyczna detekcja mgły, realizowana zwykle z wykorzystaniem informacji wizyjnej, stanowi kluczowy element współczesnych systemów bezpieczeństwa w transporcie i pozostaje intensywnie rozwijanym obszarem badawczym.


Z perspektywy cyfrowego przetwarzania obrazów, mgła znacząco pogarsza właściwości pozyskiwanych danych wizyjnych. Jej występowanie skutkuje m.in. spadkiem kontrastu, zatarciem konturów obiektów oraz zmianą charakterystyki obserwowanych tekstur [6, 7, 8], a także wpływa na przesunięcie histogramu jasności [4, 5]. W literaturze dominują obecnie dwa podejścia do tego zagadnienia: modele oparte na głębokich sieciach neuronowych oraz metody bazujące na klasycznej analizie obrazu [1, 9, 10]. Mimo wysokiej skuteczności, wykorzystanie technik uczenia głębokiego w zastosowaniach mobilnych wiąże się z istotnymi ograniczeniami. Problemem jest już poprawne przeprowadzenie procesu uczenia takich modeli. Zadanie to wymaga dostępu do obszernych, silnie zróżnicowanych i precyzyjnie opisanych zbiorów danych (takich jak np. [2, 13]), które w kontekście realizacji wysoce specyficznych zadań (np. detekcji mgły w zdefiniowanych warunkach drogowych) nierzadko okazują się niewystarczające. Co więcej, głębokie sieci neuronowe, ze względu na swoją ogromną złożoność, charakteryzują się niską interpretowalnością (efekt tzw. czarnej skrzynki). Uniemożliwia to jednoznaczne określenie przesłanek, na podstawie których system podejmuje konkretne decyzje, co budzi uzasadnione wątpliwości względem jego niezawodności w nietypowych sytuacjach drogowych [11, 12]. Złożona architektura takich modeli zwiększa ponadto ryzyko przeuczenia, a ich implementacja sprzętowa wiąże się z wysokimi kosztami obliczeniowymi i dużym zapotrzebowaniem na pamięć operacyjną.

W tym kontekście atrakcyjną alternatywę wciąż stanowią metody oparte na klasycznym przetwarzaniu i analizie obrazów. Choć zwykle ustępują one modelom głębokim pod względem dokładności klasyfikacji, wyróżniają się pełną interpretowalnością działania oraz niską złożonością obliczeniową. Takie właściwości sprawiają, że doskonale sprawdzają się one m.in. w roli systemów wczesnego ostrzegania o zaistnieniu danego zjawiska. Ich wykorzystanie umożliwia wdrożenie kaskadowej architektury przetwarzania, w której wysoce złożone (i w założeniu najdokładniejsze) algorytmy uruchamiane są wyłącznie w ściśle określonych, wymagających tego sytuacjach.

Do pomyślnej realizacji takiej koncepcji niezbędne jest opracowanie algorytmu, który połączy satysfakcjonującą jakość klasyfikacji z rygorystycznym zachowaniem krótkiego czasu przetwarzania. Wyniki zaprezentowane w niniejszej pracy stanowią rezultat wstępnych badań prowadzonych w tym właśnie obszarze. Ich efektem jest opracowanie nowego algorytmu detekcji mgły w czasie rzeczywistym, określanego w dalszej części pracy akronimem RTFD (ang. *Real-Time Fog Detector*). Rozwiązanie to stanowi bezpośrednie rozwinięcie koncepcji przedstawionych w pracach [6, 8]. Skuteczność działania wszystkich zaimplementowanych algorytmów została kompleksowo zweryfikowana na wizyjnym zbiorze danych, odwzorowującym rzeczywiste sytuacje drogowe.

2. Algorytmy referencyjne

Jako punkt wyjścia do prowadzenia badań wybrano dwa rozwiązania wykorzystujące analizę obrazu w dziedzinie częstotliwości. Schematy blokowe obu rozważanych algorytmów referencyjnych przedstawiono na rysunku 1.



Rys. 1. Schematy blokowe algorytmów referencyjnych: (a) metoda AL-1, (b) metoda AL-2.

Pierwszym z analizowanych rozwiązań jest algorytm zaproponowany przez Pavlić *et al.* [6] (oznaczany dalej jako AL-1). Jego działanie opiera się na obserwacji, że obecność mgły wywołuje spadek kontrastu oraz efekt rozmycia widoczny w skali całego obrazu. Procedura przetwarzania rozpoczyna się od normalizacji i filtracji obrazu, których celem jest ograniczenie wpływu zmian oświetlenia oraz lokalnych różnic jasności. Kolejnym krokiem jest nałożenie dwuwymiarowego okna Hamminga w celu eliminacji efektu wycieku widma na granicach sygnału, po czym obliczana jest szybka transformata Fouriera (ang. *Fast Fourier Transform*, FFT). Na podstawie uzyskanej reprezentacji $I(f_x, f_y)$ wyznaczane jest widmo mocy (ang. *power spectrum slope*, PSS):

$$S(f_x, f_y) = |I(f_x, f_y)|^2. \quad (1)$$

Uzyskane widmo analizowane jest za pomocą banku filtrów Gabora o różnych skalach i orientacjach. Odpowiedzi filtrów tworzą wielowymiarowy wektor cech opisujący rozkład energii w dziedzinie częstotliwości. Ze względu na dużą liczbę cech ich wymiarowość jest redukowana metodą analizy głównych składowych (ang. *Principal Component Analysis*, PCA), co pozwala zachować najistotniejsze informacje przy jednoczesnym ograniczeniu redundancji danych. Ostateczny wynik klasyfikacji podejmowany jest przez klasyfikator maszyny wektorów nośnych (ang. *Support Vector Machine*, SVM).

Drugie rozwiązanie referencyjne (dalej określane jako AL-2), przedstawione przez Spinneker *et al.* [8], bazuje na fizycznym zjawisku rozpraszania światła, którego

efekt niskoprzepustowy narasta nieliniowo wraz z odległością obiektów od obiektywu kamery. Z tego powodu algorytm analizuje lokalne okno wokół punktu zbiegu drogi (ang. *vanishing point*). Punkt zbiegu wyznaczany jest z wykorzystaniem transformaty Hougha, która jest wykorzystywana do analizy linii zbiegu w obrazie.

Dla wyciętego kwadratowego bloku obrazu o rozmiarze $N \times N$ pikseli obliczane jest widmo mocy $S(f_x, f_y)$ zgodnie z równaniem (1). Następnie współrzędne widmo $S(f_x, f_y)$ jest transformowane do układu biegunowego $S(f, \theta)$. Poprzez sumowanie wartości widma po wszystkich kierunkach θ , rozkład energii przybiera postać:

$$\Gamma(f) = \log_{10} \left(\sum_{\theta} S(f, \theta) + \epsilon \right), \quad (2)$$


gdzie $\epsilon = 10^{-6}$ jest stałą zapobiegającą błędom numerycznym. Dla tak wyznaczonego jednowymiarowego przebiegu poszukiwany jest, z wykorzystaniem metody najmniejszych kwadratów, wielomian aproksymujący drugiego stopnia; zatem zachodzi

$$\Gamma(f) \approx af^2 + bf + c, \quad (3)$$

gdzie wyznaczone współczynniki tworzą dwuwymiarową przestrzeń cech (a, b) . Proces decyzyjny o wystąpieniu ograniczenia widoczności realizowany jest przy użyciu kwadratowego, naiwnego klasyfikatora bayesowskiego (ang. *Naive Bayes Classifier*, NBC).

3. Opis nowego algorytmu RTFD

Jak przedstawiono w rozdziale 1, głównym celem przyświecającym opracowywaniu algorytmu RTFD było dążenie do zredukowania jego złożoności obliczeniowej przy jednoczesnym zachowaniu możliwie wysokiej jakości klasyfikacji. Schemat blokowy nowego algorytmu przedstawia rysunek 2.



Rys. 2. Schemat blokowy algorytmu RTFD.

Rozwiązania zaimplementowane w proponowanym algorytmie bazują przede wszystkim na koncepcjach znanych z metody AL-2. W przeciwieństwie jednak do niej


w algorytmie RTFD za punkt zbiegu przyjęto arbitralnie dobrany, stały punkt o współrzędnych $(\frac{1}{2}M, \frac{1}{3}M)$, gdzie M oznacza rozmiar kwadratowego obrazu (przeskalowanego do rozmiarów 256×256). Stały punkt eliminuje problem jego poszukiwania z wykorzystaniem transformaty Hougha co istotnie zmniejsza złożoność obliczeniową prezentowanego algorytmu. Wybrany punkt stanowi środek wyciętego, kwadratowego okna ($N \times N$ px), którego zawartość jest przenoszona z wykorzystaniem algorytmu FFT do dziedziny częstotliwości.

Na podstawie otrzymanej transformaty wyznaczane jest widmo mocy $S(f, \theta)$, stanowiące kwadrat modułu amplitudy. Wartości widma mocy są następnie sumowane po wszystkich orientacjach θ i poddawane transformacji logarytmicznej zgodnie z wzorem (2). Między pierwszym i ostatnim punktem funkcji $\Gamma(f)$ wykreślono odcinek $\Phi(f)$. Następnie wyliczane jest pole między $\Phi(f_i)$ a $\Gamma(f_i)$, zgodnie ze wzorem

$$D = \sum_{i=0}^{\frac{1}{2}N-1} \left(\Phi(f_i) - \Gamma(f_i) \right). \quad (4)$$

Tak wyznaczona wartość D jest uproszczoną miarą określającą charakter przebiegu widma mocy. Mgła, będąc analogowym filtrem dolnoprzepustowym, wpływa na cały kształt widma mocy $\Gamma(f)$ a tym samym powoduje zwiększenie udziału składowych niskoczęstotliwościowych w widmie obrazu, co wpływa na wartość miary D .

Na rysunku 3 pokazano graficzne porównanie wyznaczania D dla dwóch przykładowych obrazów należących do obu rozważanych klas.



Rys. 3. Porównanie cechy D dla obrazów obu klas (RTFD_{N=140}).

Otrzymana wartość D przekazywana jest jako jednowymiarowy czynnik decyzyjny do Gaussowskiego naiwnego klasyfikatora bayesowskiego. Model ten bazuje na twierdzeniu Bayesa, które przy założeniu warunkowej niezależności cech wewnątrz klas pozwala sklasyfikować obrazy na podstawie reguły decyzyjnej

$$\hat{y} = \arg \max_y \left(P(y) \prod_{i=1}^n P(x_i | y) \right), \quad (5)$$

gdzie $\hat{y}$ oznacza wyznaczoną klasę ($y \in \{0, 1\}$), a $P(y)$ to prawdopodobieństwo a priori

tej klasy. Funkcja wiarygodności $P(x_i | y)$ w wariancie gaussowskim przybiera postać funkcji gęstości prawdopodobieństwa rozkładu normalnego

$$P(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_{i,y}^2}} \exp\left(-\frac{(x_i - \mu_{i,y})^2}{2\sigma_{i,y}^2}\right), \quad (6)$$

gdzie $\mu_{i,y}$ to średnia, a $\sigma_{i,y}^2$ to wariancja rozkładu i -tej spośród n cech, na podstawie których prowadzona jest klasyfikacja. Parametry te wyznaczane są na podstawie cech pozyskanych ze zbioru uczącego. Dodatkowo, w przypadku omawianego algorytmu występuje tylko jedna zmienna losowa ($n = 1$, $x_1 = D$), co na podstawie powyższych wzorów upraszcza klasyfikację do:

$$y = \begin{cases} 0 & \text{dla } D < \tau - \text{obraz bez mgły} \\ 1 & \text{dla } D \geq \tau - \text{obraz z mgłą} \end{cases}, \quad (7)$$

gdzie τ jest progiem decyzyjnym wyznaczonym w procesie strojenia klasyfikatora.

4. Badania eksperymentalne i analiza wyników

4.1. Opis eksperymentu

Celem przeprowadzonego eksperymentu jest porównanie algorytmów AL-1, AL-2 oraz algorytmu RTFD pod kątem oceny skuteczności detekcji wystąpienia mgły na obrazach, a także porównanie czasu obliczeń.

Do uczenia oraz testowania algorytmów wykorzystano dedykowaną bazę danych [3], składającą się z 566 obrazów przedstawiających drogi w różnych warunkach atmosferycznych i o różnych porach doby podzielone na dwie klasy zawierające obrazy z mgłą i bez mgły. Zbiór testowy był wybrany losowo i stanowił 30% całego zbioru. Liczebność poszczególnych klas obrazów, wraz z rozbiciem na porę doby ich wykonania, zestawiono w tabeli 1. Z uwagi na sporadyczność występowania zamglenia w terenach miejskich, na obrazach dominuje sceneria dróg wiejskich, leśnych oraz obwodnic. Obrazy zapisano w formatach PNG lub JPG, ujednolicono do wymiarów 640×480 pikseli oraz skonwertowano do skali szarości. Przykładowe obrazy przedstawiono na rysunku 4.

Tabela 1

Struktura wykorzystanego zbioru danych

	Obraz z mgłą	Obraz bez mgły	Razem
Warunki dzienne	164 (29%)	292 (52%)	456 (81%)
Warunki nocne	64 (11%)	46 (8%)	110 (19%)
Razem	228 (40%)	338 (60%)	566 (100%)

Ocena jakości działania algorytmów została przeprowadzona z wykorzystaniem klasycznych miar stosowanych w zadaniach klasyfikacji. Narzędziem analizy wyników były miary jakości, utworzone na podstawie macierzy pomyłek (ang. *confusion matrix*), która dla analizowanego problemu jest zdefiniowana zgodnie z tabelą 2. Rozważane miary to:

Tabela 2

Macierz pomyłek


Klasa rzeczywista	Klasa przewidywana	
	Bez mgły	Mgła
Bez mgły	TN	FP
Mgła	FN	TP




a



b



c



d

Rys. 4. Przykładowe obrazy wykorzystane do testów: lewa kolumna – obrazy bez mgły, prawa kolumna – obrazy z mgłą; górny wiersz – zdjęcia wykonane w warunkach dziennych, dolny wiersz – zdjęcia wykonane w nocy (na podstawie [3]).

- czułość (ang. *recall*) — odsetek rzeczywistych przypadków pozytywnych (wystąpienia mgły), poprawnie sklasyfikowanych; jest ona określona wzorem:

$$TPR = \frac{TP}{TP + FN}, \quad (8)$$

- swoistość (ang. *specificity*) — jest miarą klasyfikatora do poprawnego rozpoznawania przypadków negatywnych (w przypadku, braku mgły); miarę tę opisuje wzór:

$$TNR = \frac{TN}{FP + TN}, \quad (9)$$

- dokładność (ang. *accuracy*) – stosunek liczby poprawnych klasyfikacji do całkowitej liczby próbek; jest ona dana wzorem:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (10)$$

- precyzja (ang. *precision*) – opisuje, jaki odsetek próbek zaklasyfikowanych jako pozytywne faktycznie do tej klasy należał; przedstawiona wzorem:


$$PPV = \frac{TP}{TP + FP}. \quad (11)$$

Poza miarami jakości bazującymi na macierzy pomyłek skupiono się również na szybkości oraz determinizmie czasowym algorytmu. Czas liczono spisując czasy przetworzenia każdego z obrazów z bazy po 100 powtórzeń. W tym celu analizowano czas wykonania algorytmu dla pojedynczego obrazu. Czas przetwarzania obejmował wszystkie etapy algorytmu z wyłączeniem odczytu pliku z dysku, co pozwoliło na uniezależnienie wyników od specyfikacji sprzętowej pamięci masowej i skupienie się na czystej złożoności obliczeniowej algorytmu. Dodatkowo założono, że analizowany obraz będzie achromatyczny.

4.2. Wstępne strojenie algorytmu RTFD


Ze względu na to, że algorytm RTFD może działać dla okna $N \times N$, w praktyce, o dowolnym rozmiarze, właściwe badania zostały poprzedzone poszukiwaniem takiej jego wielkości, która dawałaby najdokładniejsze wyniki klasyfikacji. W tym celu sprawdzono wielkość N w zakresie od 40 px do 140 px z krokiem co 10 px. Dla takiego zakresu N określono dokładność klasyfikacji oraz średni czas obliczeń (zgodnie z metodą opisaną w rozdziale 4.1). Obie zależności zilustrowano na rysunku 5.

Biorąc pod uwagę niewielkie różnice w dokładności klasyfikacji oraz małe różnice w czasie obliczeń, zdecydowano się na przeprowadzenie pełnego eksperymentu dla dwóch wariantów, tj. $N = 120$ oraz $N = 140$. W dalszej części artykułu zastosowany rozmiar okna dla metody RTFD jest jawnie wskazywany w indeksie dolnym.



Rys. 5. Wpływ rozmiaru okna na dokładność klasyfikacji i czas przetwarzania.

Na rysunku 6 przedstawiono wykres gęstości rozkładu empirycznego, wyznaczonego dla danych testowych, z nałożonymi teoretycznymi krzywymi dopasowanego rozkładu Gaussa dla obu klas oraz zaznaczoną wartością decyzyjną. Analiza uzyskanych przebiegów potwierdza wysoką zdolność separacyjną wskaźnika τ . Zarówno w przypadku rozkładów empirycznych, jak i modeli teoretycznych, maksima funkcji gęstości prawdopodobieństwa obu klas są od siebie wyraźnie odseparowane. Niewielki obszar wspólny (nakładanie się na siebie krzywych) wskazuje na niskie prawdopodobieństwo popełnienia błędu klasyfikacji. Analiza uzyskanych rozkładów potwierdza wysoką przydatność wskaźnika D do klasyfikacji.



Rys. 6. Gęstości empiryczne i teoretyczne prawdopodobieństwa cechy D dla analizowanych kategorii; wykres dla $RTFD_{N=140}$.

4.3. Wyniki

Wyniki eksperymentu przedstawione zostały tabelach. Dla wartości macierzy pomyłek w tabeli 3 oraz dla miar na jej podstawie w tabeli 4. Pomiary czasu zestawiono w tabeli 5 oraz na rysunku 7 dla różnych skal czasowych, a najlepsze wartości dla każdej miary zostały pogrubione.

Tabela 3
Wartości macierzy pomyłek

Metoda	TP	TN	FP	FN
AL-1	58	95	7	10
AL-2	65	91	11	3
$RTFD_{N=120}$	53	97	5	15
$RTFD_{N=140}$	56	95	7	12


Miary jakości klasyfikacji

Tabela 4

Metoda	TPR [%]	TNR [%]	PPV [%]	ACC [%]
AL-1	85,29	93,14	89,23	90,00
AL-2	95,59	89,22	85,53	91,76
$RTFD_{N=120}$	77,94	95,10	91,38	88,24
$RTFD_{N=140}$	82,35	93,14	88,89	88,82

Tabela 5
Porównanie czasów przetwarzania analizowanych algorytmów.

Metoda	t_{sr} [ms]	t_{min} [ms]	t_{max} [ms]	t_{med} [ms]	σ [ms]
AL-1	7,34	6,67	28,77	7,17	0,650
AL-2	4,18	0,66	250,52	2,26	12,793
RTFD _{N=120}	0,39	0,33	1,36	0,38	0,055
RTFD _{N=140}	0,49	0,43	1,19	0,48	0,060



Rys. 7. Wykresy pudełkowe czasu wykonania dla poszczególnych algorytmów. Uwaga dla poszczególnych wykresów zastosowano różne skale czasowe.

5. Dyskusja wyników

Warunkiem natychmiastowej reakcji na zagrożenia drogowe w systemach ADAS jest praca w reżimie czasu rzeczywistego, która nakłada rygorystyczne ograniczenia na czas przetwarzania pojedynczej klatki obrazu oraz wymaga możliwie dużej stabilności czasów przetwarzania kolejnych klatek. Na tym polu wyróżnia się algorytm RTFD, w którym dzięki modyfikacji metody AL-2 udało się zredukować średni czas przetwarzania pojedynczej klatki (t_{sr}) dla RTFD_{N=140} do zaledwie 0,39 ms. Oznacza to ponad dziesięciokrotne przyspieszenie w stosunku do metody AL-2 oraz blisko dwudziestokrotne skrócenie czasu obliczeń w porównaniu do AL-1. Ponadto, w przeciwieństwie do algorytmów referencyjnych AL-1 oraz AL-2, algorytm RTFD cechuje się bardzo dużą powtarzalnością, o czym świadczy niska wariancja RTFD ($\sigma \leq 0,06$). Tak mała wariancja w praktyce gwarantuje stabilny i przewidywalny potok przetwarzania danych w systemie bezpieczeństwa.

Tak duża poprawa wydajności odbyła się jednak kosztem spadku, przede wszystkim, czułości detekcji. W kontekście systemów ADAS, w których kluczowym aspektem jest minimalizacja ryzyka niewykrycia zagrożenia, wymagane jest, aby ten parametr

osiągał możliwie dużą wartość. Pod tym względem najbardziej złożony obliczeniowo algorytm referencyjny, tzn. AL-2, charakteryzuje się najwyższą czułością. Metoda RTFD jednak cechuje się najwyższą spośród badanych metod zdolnością do poprawnego rozpoznawania obrazów bez mgły, co odzwierciedla wysoka swoistość. Na tej podstawie można stwierdzić, że przyjęty czynnik decyzyjny D jest wystarczający, by w miarę skutecznie zastąpić cechy w kosztownych obliczeniowo algorytmach AL-1 i AL-2, oferując dobry kompromis pomiędzy dokładnością a czasem obliczeń.

6. Podsumowanie

Podsumowując przeprowadzone badania, opracowany algorytm RTFD stanowi wysoce efektywną alternatywę dla metod referencyjnych AL-1 oraz AL-2. Choć algorytm AL-2 osiąga wyższą dokładność i czułość, odbywa się to kosztem znacznej degradacji stabilności czasowej. Istotną zaletą metody RTFD jest wyraźne skrócenie średniego czasu przetwarzania przy jednoczesnym ograniczeniu jego odchylenia standardowego, co potwierdza skuteczność przeprowadzonej optymalizacji wydajnościowej. Przedstawione rozwiązanie jest efektem wstępnych prac nad detekcją mgły w czasie rzeczywistym. Celem dalszych badań będzie rozwój metody RTFD, ze szczególnym uwzględnieniem poprawy jej czułości. Wydaje się, że zmiana stosowanego klasyfikatora stanowi obiecujący kierunek do osiągnięcia tego celu.

Z punktu widzenia systemów jazdy autonomicznej, w których kluczowym parametrem jest przewidywalność czasu obliczeń, wysokie odchylenie standardowe charakteryzujące algorytm AL-2 jest niedopuszczalne, gdyż może prowadzić do opóźnień w procesach decyzyjnych. Proponowany algorytm RTFD cechuje się wysoką powtarzalnością czasową. Cecha ta, w połączeniu z satysfakcjonującą skutecznością detekcji mgły, uzasadnia implementację algorytmu w układach o mocy obliczeniowej zbliżonej do tej spotykanej w systemach ADAS, w celu weryfikacji jego efektywności. Co więcej, niski narzut obliczeniowy oraz wysoka swoistość predestynują tę metodę również do pracy w układzie kaskadowym jako szybki moduł wstępnej detekcji mgły. W takim ujęciu RTFD może skutecznie dokonywać wstępnej klasyfikacji i uruchamiać bardziej złożone, a tym samym czasochłonne, algorytmy detekcji dopiero w razie zaistnienia takiej konieczności. Rozwiązanie to znacząco ogranicza średni czas analizy pojedynczych klatek, przy zachowaniu wysokiej jakości klasyfikacji osiągananej przez cały system.

Podziękowania

Praca powstała przy wsparciu finansowym MNiSzW dla Politechniki Śląskiej w ramach grantu badawczego 02/070/BK_26/0077.

LITERATURA

1. Chincholkar S., Rajapandy M.: Fog image classification and visibility detection using CNN. International Conference on Intelligent Computing, Information and Control Systems, 2019, p. 249–257.
2. Cordts M., Omran M., Ramos S., Rehfeld T., Enzweiler M., Benenson R., Franke

- U., Roth S., Schiele B.: The cityscapes dataset for semantic urban scene understanding. *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016,.
3. Jęczmiński W. A.: *Detekcja mgły w oparciu o informację wizyjną*. Praca inżynierska Politechnika Śląska 2026.
 4. Liu C., Lu X., Ji S., Geng W.: A fog level detection method based on image HSV color histogram. *2014 IEEE International Conference on Progress in Informatics and Computing*, 2014, p. 373–377.
 5. Narasimhan S. G., Nayar S. K.: Vision and the atmosphere. *Proceedings of International Journal of Computer Vision*, 2002, Vol.48(3), p. 233–254.
 6. Pavlic M., Belzner H., Rigoll G., Ilic S.: Image based fog detection in vehicles. *2012 IEEE Intelligent Vehicles Symposium*, 2012, p. 1132–1137.
 7. Pavlic M., Rigoll G., Ilic S.: Classification of images in fog and fog-free scenes for use in vehicles. *2013 IEEE Intelligent Vehicles Symposium (IV)*, 2013, p. 481–486.
 8. Spinneker R., Koch C., Park S.-B., Yoon J. J.: Fast fog detection for camera based Advanced Driver Assistance Systems. *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2014, p. 1369–1374.
 9. Wang Q., Zhou Z., Zhang Z.: Fog-YOLO: A real-time object detector for foggy autonomous driving scenarios. *Symmetry*, 2026, Vol.18(2).
 10. Wang X., Fu R., Li S., Liang X.: Fog-YOLO: an efficient object detection model for autonomous vehicles in foggy environment. *2025 9th CAA International Conference on Vehicular Control and Intelligence (CVCI)*, 2025, p. 1–6.
 11. Wang Z.: Deep learning in autonomous driving: Current status, challenges and future outlook. *Applied and Computational Engineering*, 06 2026, Vol.241, p. 202–212.
 12. Xu C., Sankar R.: A comprehensive review of autonomous driving algorithms: Tackling adverse weather conditions, unpredictable traffic violations, blind spot monitoring, and emergency maneuvers. *Algorithms*, 2024, Vol.17(11).
 13. Yu F., Chen H., Wang X., Xian W., Chen Y., Liu F., Madhavan V., Darrell T.: Bdd100k: A diverse driving dataset for heterogeneous multitask learning. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, p. 2633–2642.