ZASTOSOWANIE AEROFOTOGRAMETRII W PODCZERWIENI DO ŚLEDZENIA DZIKÓW W ICH NATURALNYM ŚRODOWISKU ORAZ IDENTYFIKACJI OSOBNIKÓW ZARAŻONYCH AFRYKAŃSKIM POMOREM ŚWIŃ. CZ. I – ARCHITEKTURA SYSTEMU I METODYKA IDENTYFIKACJI

PAWEŁ KALINOWSKI, PAWEŁ SZCZEPANIAK, LESZEK UŁANOWICZ

Instytut Techniczny Wojsk Lotniczych, Warszawa e-mail: pawel.kalinowski@itwl.pl; pawel.szczepaniak@itwl.pl; leszek.ulanowicz@itwl.pl

Krzysztof Sibilski

Politechnika Warszawska, Wydział Mechaniczny Energetyki i Lotnictwa, Warszawa e-mail: krzysztof.sibilski@pw.edu.pl

W artykule został opisany oparty o aerofotometrię system przeznaczony do wykrywania dzików oraz identyfikacji chorych na afrykański pomór świń osobników. System opiera się o bezzałogowe statki powietrzne: czterowirnikowy mikrowiropłat oraz bezzałogowy samolot klasy mini. Wykonujące autonomiczne loty bezzałogowe statki powietrzne są wyposażone w termowizyjne sensory optoelektroniczne, systemy transmisji danych oraz systemy analizy obrazów termowizyjnych. W artykule została opisana architektura systemu oraz metodyka analizy obrazów termowizyjnych. Zostały także omówione algorytmy wykrywania dzików w ich naturalnym środowisku oraz automatycznej identyfikacji dzików chorych na Afrykański Pomór Świń.

1. Wstęp

Afrykański pomór świń (African Swine Fever, ASF) znajduje się na liście chorób Międzynarodowego Urzędu ds. Zdrowia Zwierząt (Word Organisation for Animal Heath, OIE) podlegających obowiązkowi zgłaszania i urzędowego zwalczania. Jest to wyjątkowo groźna, nieuleczalna, wysoce zakaźna i zaraźliwa, wirusowa choroba świń domowych wszystkich ras oraz dzików. Rezerwuarem wirusa mogą być dziki europejskie, dzikie świnie afrykańskie (bush pigs), guźce (wart hogs) oraz kleszcze z gatunku Ornithodorus. Pozostałe gatunki zwierząt są na zakażenie ASFV (African Swine Fever Virus) niewrażliwe. Chorobę charakteryzują objawy kliniczne, zwłaszcza wysoka gorączka oraz sięgająca 100% śmiertelność [1], [2].

Od czasu opublikowania przez OIE w dniu 6.06.2007 r. pierwszego raportu na temat wystąpienia choroby na terytorium Gruzji, wirus ASF został zawleczony do niemal wszystkich państw Kaukazu i na terytorium Federacji Rosyjskiej. Ogniska ASF potwierdzono także na Ukrainie (na Zaporożu), a 16.06.2013 r. wystąpienie ASF w okolicach Grodna (170 km od granicy Polski) potwierdziła Białoruś. W ostatnich 6 latach ogniska ASF wykryto we wszystkich wschodnich województwach, a w ostatnim roku pojawiły się również na zachodzie Polski. Pomimo że sam wirus nie stanowi zagrożenia dla ludzi, to stwarza poważny problem ekonomiczny, zarówno dla przemysłu mięsnego jak i hodowli. Obecnie przypadki wystąpień ASF obejmują praktycznie całą Polskę. Dlatego też problem wykrywania i eliminacji chorych na ASF dzików jest kluczowy w aspekcie ograniczenia rozprzestrzeniania się zarazy [3], [4].

Wykrycie chorych na ASF dzików za pomocą systemów naziemnych (np. foto pułapek) jest mało efektywne [5]-[7]. Wydaje się, że najbardziej efektywne będzie wykorzystanie wyposażonych w odpowiednie sensory bezzałogowych statków powietrznych [8], [9]. W dostępnej literaturze pojawiło się szereg prac na temat możliwości wykorzystania systemów bezzałogowych w rolnictwie, leśnictwie oraz do monitorowania dzikich zwierząt, a także ludzi [10]-[13]. Ze względu na to, że głównym symptomem choroby ASF jest znacznie podwyższona temperatura chorego osobnika [14], podstawowym sensorem pozwalającym na identyfikację zainfekowanego zwierzęcia powinny być wysokiej klasy (duża rozdzielczość i czułość) kamery termowizyjne. W literaturze można znaleźć szereg prac poświęconych termowizji oraz wykorzystaniu zainstalowanych na pokładach bezzałogowych statkach powietrznych systemów termowizyjnych [15]-[20]. Cytowane powyżej prace omawiały szereg aspektów wykorzystania termowizji w różnorodnych zastosowaniach monitorowania środowiska.

W artykule zostal opisany oparty o aerofotometrii innowacyjny system przeznaczony do wykrywania dzików oraz identyfikacji chorych na ASF osobników. System opiera się o bezzałogowe statki powietrzne: czterowirnikowy mikrowiropłat oraz bezzałogowy samolot klasy mini. Opisany w artykule system, nazwany ASF Ochrona, powstał w ramach projektu badawczo-rozwojowego pt. "Zastosowanie innowacyjnych i efektywnych metod i technologii umożliwiających wykrycie watah dzików, identyfikacji osobników z objawami klinicznymi ASF w naturalnym terenie ich występowania", nr umowy DOB-BIO9/30/01/2018, realizowanego w ramach projektów na rzecz obronności i bezpieczeństwa państwa KONKURS 9/2018 i został sfinansowany przez Narodowe Centrum Badań i Rozwoju.

2. Architektura systemu ASF Ochrona

W skład systemu ASF Ochrona wchodzą: wyposażony w średniofalową kamerę termowizyjną samolot bezzałogowy klasy mini Neox ASF (rys. 1) oraz czterowirnikowy mikrowiropłat Atrax ASF (rys. 2a) wyposażony w długofalową kamerę termowizyjną o wysokiej rozdzielczości (rys. 2b). Lecący na wysokości 100 m bezzałogowy samolot przeznaczony jest do wstępnego wykrywania watah dzików (lub pojedynczych osobników) na dużym obszarze patrolowanego terenu. Wykonujący autonomatyczny lot po zaplanowanej trasie samolot jest wyposażony w system automatycznej analizy wykonywanych przez zainstalowaną na jego pokładzie kamerę zdjęć pokłatkowych. Przedstawiona na rys. 3 kamera wykonuje zdjęcia o rozdzielczości 640×512 px z częstotliwością 60 Hz.



Rys. 1. Wyposażony w średniofalową w kamerę termowizyjną bezzałogowy samolot klasy mini NeoxASF na wyrzutni startowej

System wykrywa dziki i przekazuje współrzędne geograficzne watahy lub wykrytego osobnika do mobilnego stanowiska dowodzenia. Stamtąd taka informacja jest przekazywana do wyposażonego w czterowirnikowy mikrowiropłat AtraxASF samochodu interwencyjnego. Współrzędne



Rys. 2. (a) Czterowirnikowy mikrowiropłat AtraxASF, (b) montowana na czterowirnikowcu głowica obserwacyjna z długofalową kamerą termowizyjną o wysokiej rozdzielczości KTX firmy Etronika



Rys. 3. Głowica obserwacyjna z średniofalową kamerą termowizyjną KTCH podsystemu NeoxASF

watahy są wprowadzane do sytemu autonomicznego sterowania czterowirnikowcem, który wykonuje lot interwencyjny na wysokości do 50 m. Zainstalowana na czterowirnikowcu kamera wykonuje zdjęcia termowizyjne o rozdzielczości 1024×728 px z częstotliwością 15 Hz. Po wykonaniu lotu zapisany na dysku zbiór zdjęć jest wgrywany do komputera analizy obrazu. Komputer w oparciu o bazujące na sieciach neuronowych wyspecjalizowane oprogramowanie wykrywa dziki oraz identyfikuje osobniki z symptomami ASF oraz generuje raport, który za pomocą sieci GSM jest przesyłany na skrzynki mailowe odpowiednich służb weterynaryjnych i leśnych.

Podsystem oblotu wielkoobszarowego składa się z następujących zespołów: pojazdu dowodzenia misją (PD) (rys. 4), systemu łączności (SŁ), naziemnej stacji kontroli lotu (NSKL) (rys. 5), bezzałogowego samolotu klasy mini NeoxASF z głowicą obserwacyjną z kamerą średniofalową i systemami pokładowymi (BSP) (rys. 1), stanowiska przygotowania do lotu i obsługi BSP, lekkiej wyrzutni startowej (LWS) (rys. 1), stanowiska koordynatora lotów (SKL), zaplecza socjalnego i wyposażenia dodatkowego).

Podsystem nalotu precyzyjnego wyposażony w pojazd interferencyjny (PI) (rys. 6) oraz platformy bezzałogowej – czterowirnikowego mikrowiropłata AtraxAS" (ABSP) wyposażonego w głowicę obserwacyjną z kamerą długofalową KTX) (rys. 2a,b). W skład podsystemu wchodzą



Rys. 4. Pojazd dowodzenia (na dachu widoczny jest złożony maszt anteny)



Rys. 5. Naziemna stacja kontroli lotu (NSKL), widoczne stanowiska (od lewej): operatora lotu oraz operatora analizy obrazu, pomiędzy tymi stanowiskami znajduje się stacja analizy obrazu (wieloprocesorowa stacja robocza z zainstalowanym specjalistycznym oprogramowaniem)

także: system łączności (SŁ), system obserwacji (SO), poligonowy systemu obsługi wielowirnikowca (PSOA) oraz wyposażenie dodatkowe.

Pojazd dowodzenia jest pojazdem dostawczym typu furgon (rys. 4) DMC 3500 kg z napędem na wszystkie osie. Pojazd zabezpieczony jest przed zarysowaniami okleiną zabezpieczającą w kolorze Mat NATO Zielony. Na tylnych drzwiach pojazdu zabudowana jest drabina. Pojazd dowodzenia wyposażony jest w silnik o zapłonie samoczynnym o mocy 110 kW. Zbiornik paliwa ma pojemność 70 dm³. Samochód jest wyposażony w uniwersalny sprzęg przyczepy zapewniający możliwość ciągnięcia przyczepy o masie całkowitej 3 t. Pojazd dowodzenia jest wyposażony w układ zasilania elektrycznego BSP NeoxASF, teleskopowy maszt antenowy wraz z rotorem i radiomodemem z anteną radiową, bębnowe zwijacze przewodów antenowych, stanowisko przygotowania i obsługi BSP NeoxASF, stanowiska operatora/pilota BSP, stanowisko na skrzynią transportową BSP NeoxASF, stanowisko na skrzynie transportową lekkiej wyrzutni startowej, kompresora olejowego, oraz stacji meteorologicznej. Pojazd dowodzenia umożliwia dojazd w rejon poszukiwania watah dzików oraz przewóz BSP NeoxASF. Wykorzystanie podsystemu NeoxASF wymagało zorganizowania (zabezpieczenia) płaszczyzny lotniska trawiastego o wymiarach co najmniej 50×300 m. Start samolotu NeoxASF odbywa się z lekkiej wyrzutni startowej LWS (rys. 1). Czas misji wykonywanej w trakcie nalotu zgrubnego (wielkoobszarowego) przez samolot NeoxASF wynosi co najmniej 1,5 godziny.

Start samolotu odbywa się przy bezpośrednim udziale operatora, natomiast misja odbywa się w trybie programowanym. Pułap operacyjny wynosi nie więcej niż 120 m AGL, natomiast prędkość przelotowa samolotu ze względu na ograniczenia sensora termowizyjnego średniofalowego została zredukowana do 18 m/s (65 km/h). Masa startowa samolotu NeoxASF wynosi ok. 16 kg. NeoxASF jest samolotem w układzie górnopłata. Jest napędzany silnikiem elektrycznym, ze śmigłem ciągnącym. Taki układ płatowca pozwala wykonywać zadania przy emisji hałasu poniżej 53 dB. Dedykowana głowica z kamerą średniofalową (GOŚ) jest stabilizowana elektromechanicznie w dwóch osiach z cyfrowa stabilizacja w trzeciej osi. Głowica została opracowana w Z-58 ITWL. W głowicy tej zastosowano kamerę średniofalową KTCH-25 firmy Etronika. Kamera jest wyposażona w detektor Sparrow-Blackbird 640-IZRAEL. Głowica z kamerą jest umieszczona wewnątrz kadłuba. Podczas wykonywania misji jest wysuwana z kadłuba. Ze względu na warunki oprogramowania identyfikującego dziki, kat pochylenia obiektywu kamery jest stały i wynosi 45°. Kat odchylenia obiektywu także jest stały i ustawiony "za kursem BSP". Oprogramowanie analizy obrazu nie wymaga kompensowania położenia obiektywu w kanale przechylenia. Po wykonaniu zadania głowica jest chowana do kadłuba. Samolot ląduje z użyciem wyzwalanego pirotechnicznie systemu spadochronowego. Analiza obrazu z samolotu odbywa się w czasie rzeczywistym w trakcie lotu. Analiza obrazu z Atyraxa jest w post procesingu.



Rys. 6. Pojazd interwencyjny

Rejestrowane przez systemy BSP obrazy są zapisywane w postaci plików RAW na karcie pamięci. Pliki graficzne z kamery są skorelowane ze współrzędnymi geograficznymi w formacie WGS84 oraz danymi o kącie pochylenia i odchylenia osi głowicy z kamerą termowizyjną. Efektem działania algorytmu wykrywania dzików w trakcie oblotu wieloobszarowego jest zestaw danych wynikowych zapisanych w postaci pliku w formacie CSV, zawierającego dane w poszczególnych kolumnach: ścieżka do zdjęcia, liczba wykrytych dzików, przybliżone dane lokalizacyjne odpowiadające wykrytym dzikom. Plik wynikowy stanowi element wsadowy działań w ramach oblotu precyzyjnego z wykorzystaniem czterowirnikowca Atrax ASF, wyposażonego w głowicę obserwacyjną z kamerą długofalową o wysokiej rozdzielczości. Analiza obrazu nie wymaga kompensowania położenia obiektywu w kanale przechylenia. Głowica została opracowana w Z-58 ITWL i wykorzystuje polski moduł termalny KTX firmy Etronika. Po wykonaniu analizy z oblotu wielkoobszarowego i znalezieniu obiektów do kolejnego kroku sprawdzenia w wytypowane obszary operator pojedzie pojazdem interwencyjnym (PI), który na wyposażeniu posiada przede wszystkim platformę czterowirnikową AtraxASF z głowicą obserwacyjną z kamerą długofalową wysokiej rozdzielczości. Pojazd interwencyjny jest pojazdem samochodowym typu pickup (rys. 6) DMC 3500 kg z napędem na wszystkie osie i kołami 17". Pojazd zabezpieczony jest przed zarysowaniami okleiną zabezpieczającą w kolorze Mat NATO Zielony. Pojazd interwencyjny wyposażony jest w silnik o zapłonie samoczynnym o mocy 110 kW, zbiornik paliwa o pojemności 70 dm³, wspomagany układ kierowniczy, uniwersalny sprzęg przyczepy zapewniający możliwość ciągnięcia przyczepy o masie całkowitej 3 t. Pojazd interwencyjny wyposażony jest w wyciągarkę na przednim zwisie samochodu o uciągu 5000 kg wraz z instalacją elektryczną do podłączenia wyciągarki.

Pojazd interwencyjny zaopatrzony jest w: układ zasilania elektrycznego 12/230 V składający się z agregatu prądotwórczego ESE 606 DHS-GT AVR (rys. 7), przetwornicy napięcia SINUS 5000 (rys. 7a) wraz z zasilaczem awaryjnym typu UPS, bębnowe zwijacze przewodów antenowych, teleskopowy maszt antenowy wraz z rotorem i radiomodemem z anteną radiową (rys. 7b).



Rys. 7. Wyposażenia zabudowy pojazdu interwencyjnego: 1 – pompa paliwa, 2 – agregat prądotwórczy, 3 – zasilacz, 4 – kompresor, 5 – monitor, 6 – przetwornica napięcia, 7 – prostownik (z lewj). Rotor antenowy teleskopowego masztu antenowego wraz z anteną (z prawej)

Bezzałogowe statki powietrzne AtraxASF oraz NeoxASF spełniają "Warunki techniczne dopuszczające do lotów w trybie BVLOS" (Beyond Visual Line of Sight – loty poza zasięgiem wzroku pilota drona). Są to między innymi: oświetlenie pozycyjne BSP oraz lokalizator awaryjny. BSP AtraxASF startuje pionowo, zatem nie wymaga szczególnych warunków w postaci płaszczyzny lotniska – wystarczy obszar 20×20 m niezalesionego terenu z dobrą widocznością. Przed lotem operator BSP AtraxASF programuje trasę lotu, wykorzystując zminiaturyzowaną stację kontroli lotu. Łączność pomiędzy BSP a pojazdem interwencyjnym i stacją kontroli lotu zapewnia bezpośredni kanał radiowy. Pojazd interwencyjny jest wyposażony w mechanicznie rozkładany maszt antenowy o długości 15 m (rys. 7). Potwierdzona próbami w locie długotrwałość lotu BSP AtraxASF wynosi 40 minut. Operator BSP AtraxASF jest jednocześnie kierowcą pojazdu interwencyjnego oraz przekazuje dane do pojazdu dowodzenia, w którym zainstalowany jest komputer analizy obrazu (rys. 7). Dane z oblotów precyzyjnych są opracowywane w trybie post-processingu. Po wylądowaniu BSP informacje zapisane w komputerze pokładowym przenoszone są z wykorzystaniem pamięci flash do stacji analizy obrazu (SAO). Efektem działania algorytmu stacji SAO jest wygenerowanie automatycznego raportu z wykrycia w formacie pdf.

3. Algorytmy wykrywania dzików

Metodyka wykrywania i klasyfikacji dzików bazuje na analizie zdjęć i opiera się na wykorzystaniu algorytmów śledzenia, które zwiększają skuteczność systemu i pozwalają na zmniejszenie zapotrzebowania na moc obliczeniową. Metodyka została podzielona na dwie fazy:

- fazę pierwszą, której celem jest wyznaczenie tzw. regionów zainteresowania ROI (ang. region of interest), które reprezentują jeden obiekt (np. dzika). W tej fazie dzięki wstępnemu przetworzeniu obrazu, można ograniczyć wpływ warunków atmosferycznych oraz nakładania się na siebie obiektów (np. gałęzi drzewa zasłaniające zwierzę) itp. (rys. 8).
- fazę drugą, której celem jest przypisanie obiektu znajdującego się w ROI do jednej z wskazanych wcześniej grup. Do ekstrakcji cech obrazów, a tym samym do ich klasyfikacji wykorzystywane są konwolucyjne sieci neuronowe. Podczas uczenia nadzorowanego wielowarstwowych sieci neuronowych wykorzystany został algorytm propagacji wstecznej opartej na minimalizacji sumy kwadratów błędów uczenia z wykorzystaniem optymalizacji metody największego spadku. W wariancie tym błędy powstałe na wyjściu przesyłane są na wejście sieci [28].



zdjęcie z kamery KTX

Rys. 8. Schemat działania systemu w pierwszej fazie

Pierwsze rozwiązanie opiera się na dwóch klasyfikatorach binarnych połączonych ze sobą (rys. 9).



Rys. 9. Pierwsze rozwiązanie w drugiej fazie działania systemu

Drugie rozwiązanie opiera się na klasyfikatorze wielokryterialnym (rys. 10).



Rys. 10. Drugie rozwiązanie w drugiej fazie działania systemu

3.1. Metodyka wykrywania dzików

Metoda wykrywania dzików oraz identyfikacji osobników z symptomami ASF bazuje na analizie klatek filmów wykonanych w podczerwieni. Filmy wykonywane są za pomocą kamer: krótkofalowej KTX oraz średniofalowej KTCh. Pierwszym krokiem analizy jest detekcja obiektów (tym przypadku dzików). W literaturze przedmiotu opisywane są różne algorytmy detekcji obrazów. Można tu wymienić:

- Algorytm YOLO [29], [30]. W przypadku tego algorytmu analizowany jest zawsze cały obraz, dlatego zasadne jest jego zastosowanie do wybierania ramek kluczowych. Mankamentem algorytmu jest utrudniona ingerencja w procesie tworzenia ROI.
- Algorytmy odejmowania tła [31], które bardzo dobrze sprawdzają się w przypadku kamer zamontowanych na stałe, natomiast nie sprawdzają się w przypadku ruchów głowicą termowizyjną. Algorytmy te nie nadają się do wykrywania zwierząt pozostających dłuższy czas w bezruchu.
- Algorytmy stałego [32] bądź dynamicznie zmienianego [33] poziomu jasności pikseli, od którego obraz jest analizowany. W oparciu o zastosowanie tego algorytmu dokonywana była detekcja dzików, jednakże ta metoda jest wrażliwa na złe warunki pogodowe, np. mgłę.

Ze względu na to, że opisane powyżej algorytmy miały istotne wady opracowany został autorski algorytm, polegający na połączeniu dwóch metod komputerowego przetwarzania obrazów obejmujących obróbkę wstępną oraz wykrywanie krawędzi. Współczynniki funkcji wykorzystywane w poszczególnych etapach są obliczane lub dobierane empirycznie. Następnie są testowane na stale powiększanym zbiorze obrazów, które zostały pozyskane w różnych warunkach. Materiały obrazowe różnią się otoczeniem, warunkami atmosferycznymi, porami roku. Duże zróżnicowanie materiału pozwoliło na większą generalizację współczynników wykorzystywanych funkcji oraz uniknięcie uzależnienia skuteczności detekcji obiektów od warunków, w których został pozyskany materiał. Detekcja dzików przeprowadzana jest w kilku etapach.

Etapem pierwszym jest wczytanie zdjęcia (rys. 11).



Rys. 11. Przykładowe zdjęcie z kamery KTX

Etapem drugim jest wstępne rozmycie filtrem dolnoprzepustowym pozwalające na uśrednienie pikseli poprzez przemnożenie ich przez macierz jedynek. We wstępnym rozmyciu stosujemy tzw. filtr uśredniający. Wartość intensywności pikseli wyjściowych jest średnią wszystkich wartości intensywności pikseli pierwotnych przemnożonych przez maskę

$$W = \frac{1}{(\text{macierz.wiersze}) \cdot (\text{macierz.kolumny})} \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}$$
(3.1)

W opisywanym przypadku zastosowano maskę filtru o rozmiarach 3×3 , ponieważ może być umieszczony dokładnie w środku okna filtracji (co jest niemożliwe w przypadku jądra 2×2). Wartość pikseli w obrazie wynikowym p' jest określona za pomocą wzoru

$$p'(x,y) = \sum_{i,j \in K} w(i,j)p(x-i,y-j) \qquad mboxdla \qquad K = \{-1,0,1\}$$
(3.2)

gdzie: w(i, j) – wartość maski, p(x, y) – wartość intensywności punktu.

Efekt rozmycia obrazu wejściowego filtrem dolnoprzepustowym można zaobserwować na rys. 12.



Rys. 12. Efekt rozmycia obrazu filtrem dolnoprzepustowym

Następnym etapem wstępnego przetwarzania obrazu jest rozmycie z wyostrzeniem krawędzi [34] służące zmniejszeniu liczby detekcji obszarów zainteresowania, które będą podlegać klasyfikacji. Jak wskazano m.in. w publikacji [35], źródłem wielu fałszywych alarmów są nagrzewające się obiekty, np. gałęzie drzew. Do rozmycia z wyostrzeniem krawędzi użyto filtru bilateralnego. Jest to filtr nieliniowy, który przekształca obraz w zależności od wartości gradientu intensywności. W przypadku małych wartości gradientu działa jak filtr dolnoprzepustowy oparty na rozkładzie Gaussa. Natomiast obszary o dużej wartości gradientu są uśredniane w znacznie mniejszym stopniu. Pozwala to na rozmycie obrazu z jednoczesnym zachowaniem krawędzi, które będą niezbędne w kolejnych etapach przetwarzania obrazu cyfrowego. Filtr bilateralny polega na połączeniu dwóch filtrów: w dziedzinie przestrzennej (odległości) i w dziedzinie intensywności. Funkcja rozkładu Gaussa w dziedzinie odległości, funkcja odległości h_d opisana jest zależnością

$$h_d(x_o - x) = \exp\left(-\frac{1}{2}\frac{d(x_0 - x)^2}{\sigma_d^2}\right)$$
(3.3)

gdzie: x_0 – położenie centralnego punktu maski, $d(x_0 - x)$ – euklidesowa odległość między punktami x_0 a x, σ_d – odchylenie standardowe rozkładu w dziedzinie odległości.

Natomiast funkcja intensywności h_r dana jest wzorem

$$h_r(x_o - x) = \exp\left(-\frac{1}{2}\frac{\delta[f(x_0) - f(x)]^2}{\sigma_r^2}\right)$$
(3.4)

gdzie: $\delta[f(x_0) - f(x)]^2$ – różnica intensywności punktów x i x_0 , σ_r – odchylenie standardowe rozkładu w dziedzinie intensywności.

Proces filtracji polega na splocie funkcji obrazu z funkcją maski h_d i h_r

$$f(x_0) = \frac{1}{k} \sum_{i \in R} f(x_i) h_d(x_0 - x) h_r(x_0 - x)$$
(3.5)

gdziek– współczynnik normalizujący wartość jasności pikseli

$$k = \sum_{i \in R} h_d(x_0 - x)h_r(x_0 - x)$$
(3.6)

Efekt działania filtru bilateralnego na obrazie wejściowym (rys. 12) zaprezentowano poniżej (rys. 13).



Rys. 13. Efekt rozmycia obrazu filtrem bilateralnym

Kolejnym etapem analizy obrazu jest wykrycie krawędzi obiektów z zastosowaniem algorytmu opisanego przez Johna F. Canny'ego [36]-[38]. Algorytm Canny'ego jest wieloetapowy i składa się:

- z eliminacji szumów w tym przypadku proces podzielono na dwa etapy: wstępne rozmycie filtrem dolnoprzepustowym i rozmycie z wyostrzeniem krawędzi, króre zostały opisane powyżej,
- z wyznaczenia map amplitudy gradientów i kierunków gradientów dla każdego piksela obrazu przy pomocy filtru Sobela. Jest on operatorem dyskretnego różniczkowania, umożliwiającym aproksymację pochodnych kierunkowych.

Maski filtru wyglądają następująco

$$\mathbf{S}_{x} = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \qquad \mathbf{S}_{y} = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$
(3.7)

W celu uzyskania gradientów w poszczególnych kierunkach niezbędna jest operacja splotu maski z wartościami intensywności poszczególnych punktów obrazu

$$\mathbf{G}_{x}(x,y) = \mathbf{S}_{x}\mathbf{I}(x,y) \qquad \qquad \mathbf{G}_{y}(m,n) = \mathbf{S}_{y}\mathbf{I}(x,y) \tag{3.8}$$

gdzie: $\mathbf{I}(x,y)$ – intensywność piksela o współrzędnych $x,\,y.$

Amplitudy gradientów można obliczyć na dwa sposoby

$$G = \sqrt{\mathbf{G}_x^2 + \mathbf{G}_y^2} \tag{3.9}$$

lub

$$G = |\mathbf{G}_x| + |\mathbf{G}_y| \tag{3.10}$$

Ze względu na mniejszą złożoność obliczeniową w opisywanym rozwiązaniu zastosowano równania (3.10). Takie podejście zostało zaprezentowane m.in. w [39]. Kierunek gradientu oblicza się wzorem

$$\theta(x,y) = \tan^{-1} \frac{\mathbf{G}_y(x,y)}{\mathbf{G}_x(x,y)}$$
(3.11)

Następnym etapem analizy obrazu jest tłumienie niemaksymalne (ang. non-maximum suppression) – tłumienie pikseli niebędących lokalnym maksimum.

Proces ten polega na zmniejszeniu szerokości krawędzi do jednego piksela poprzez porównywanie każdego piksela z dwoma sąsiednimi pikselami leżącymi na prostej kierunku gradientu danego piksela zgodnie z zależnością

$$G'(x,y) = \begin{cases} G(x,y) & \text{jeżeli} \quad G(x,y) > G(x_1,y_1) \quad \wedge \quad G(x,y) > G(x_2,y_2) \\ 0 & \text{w innych przypadkach} \end{cases}$$
(3.12)

gdzie: $G(x_1, y_1)$ i $G(x_2, y_2)$ – wartości gradientów sąsiednich pikseli leżących na prostej kierunku gradientu testowanego piksela.

Kolejnym etapem analizy jest progowanie obrazu histerezą w celu eliminacji krawędzi o małych wartościach gradientu, a jednocześnie przy zachowaniu ciągłości krawędzi. John F. Canny zaproponował użycie dwóch progów: wysokiego HT (ang. high treshold) i niskiego LT (ang. low treshold). Proces progowania przedstawiono poniżej

$$G'(x,y) > HT \Rightarrow \text{ piksel jest krawędzią}$$

 $G'(x,y) < LT \Rightarrow \text{ piksel nie jest krawędzią}$
(3.13)

w pozostałych przypadkach sprawdzamy otoczenie testowanego piksela (w 4 lub 8 kierunkach).

Jeżeli jakikolwiek z punktów otoczenia jest krawędzią, to testowany punkt również jest krawędzią. Progowanie obrazu prowadzi do utworzenia listy konturów obiektów na podstawie binarnego obrazu reprezentującego krawędzie (rys. 14) oraz utworzenia prostokątów stycznych do konturów obiektów poprzez obliczenie skrajnych punktów konturów w osiach x i y.



Rys. 14. Wynik wykrywania krawędzi na obrazie z rys. 13

W opisywanym przypadku wszystkie wyznaczane prostokąty nie są obracane względem osi obrazu. Pozwala to na zastosowanie prostych obliczeń położenia i rozmiarów prostokąta. Kontur K jest reprezentowany, jako zbiór N punktów (x, y), więc wyznaczając prostokąt, korzystamy ze wzorów:

- dla osi x

$$x_0 = \min_{n \in N} (x_n)$$
 $x_k = \max_{n \in N} (x_n)$ (3.14)

— analogicznie dla osi y

$$y_0 = \min_{n \in N}(y_n)$$
 $y_k = \max_{n \in N}(y_n)$ (3.15)



Rys. 15. Wykres poglądowy obrazujący proces wyznaczania prostokątów

Współrzędne przedstawiono na wykresie poglądowym na rys. 15.

Kolejnym etapem jest posortowanie prostokątów względem ich pola oraz sprawdzenie współczynnika kształtu sr (ang. shape ratio) prostokątów, czyli stosunku długości krawędzi, oraz odrzucenie nieregularnych prostokątów (rys. 16).



Rys. 16. Fragment obrazu ukazujący prostokąty o zbyt dużymsr

Wskaźniksroblicza się prostym wzorem

$$sr = \frac{w}{h} = \frac{x_k - x_0}{x_k - x_0} \tag{3.16}$$

gdzie: w– szerokość prostokąta, h– wysokość prostokąta.

Prostokąt zostanie odrzucony, jeżeli

$$sr \notin (sr_1, sr_2) \tag{3.17}$$

gdzie: sr_1 , sr_2 – dolny i górny próg wartości sr. Progi można obliczyć lub wyznaczyć empirycznie. Postawienie warunku na wartość sr pomaga odrzucić zbyt długie prostokąty (rys. 16), które wskazują obiekty jaśniejsze od otoczenia niebędące zwierzętami, np. drzewa, cieki wodne, elementy infrastruktury itp. Kolejnym etapem jest sprawdzenie pola powierzchni prostokątów P i odrzucenie zbyt małych lub zbyt dużych. Analogicznie do poprzedniego etapu jest sprawdzany kolejny parametr, jakim jest pole powierzchni prostokątów

$$P = wh \tag{3.18}$$

Prostokąt zostanie odrzucony, jeżeli

$$(3.19)$$

gdzie: P_1, P_2 – dolny i górny próg wartości P. Można je obliczyć lub wyznaczyć empirycznie.

W kolejnym etapie następuje sprawdzenie, czy środki wyznaczonych prostokątów nie zawierają się w innych prostokątach zaznaczonych na obrazie (rys. 17).



Rys. 17. Fragment obrazu przedstawiający problem nakładania się na siebie prostokątów

Środki prostokątów obliczono, korzystając ze wzoru

$$c_x = x_0 + \frac{w}{2}$$
 $c_y = y_0 + \frac{h}{2}$ (3.20)

Prostokąt zostanie odrzucony, jeżeli dla $m \in M$

$$c_x \in \langle x_{om}, x_{km} \rangle \qquad \land \qquad c_y \in \langle y_{om}, y_{km} \rangle \tag{3.21}$$

gdzieM– zbiór prostokątów zaznaczonych na obrazie.

Klasyfikacja obiektów przez sieć neuronową jest następnym etapem analizy obrazu (rys. 18). Należy podkreślić, że algorytm ROI przekazuje do sieci neuronowej fragmenty obrazu oryginalnego, ponieważ w procesie wstępnego przetwarzania obrazu niektóre cechy obiektów mogą ulec zmianie, np. kształt, rozkład temperaturowy.

Zaletami opisanego powyżej podejścia są możliwości:

- zastosowania na komputerach pokładowych bezzałogowych statków powietrznych,
- stosowania w różnych warunkach otoczenia, w odróżnieniu od metod bazujących tylko na jasności obiektów,
- analizy obrazów ograniczona do zdjęć kluczowych, na których wykryto jaśniejsze obiekty posiadające kontury,
- obróbki wstępnej obrazów, co przekłada się na ilość regionów zainteresowań, a tym samym na szybkość wykrywania obiektów.



Rys. 18. Obraz z zaznaczonymi ROI, które będą klasyfikowane przez sieć neuronową

4. Klasyfikacja obiektów

Do klasyfikacji obiektów użyto konwolucyjnych sieci neuronowych. Spłotowe sieci neuronowe pozwalają na ekstrakcję cech, na podstawie których można określić, do jakiej klasy należy wskazany obiekt. W opisywanym rozwiązaniu wykorzystano architekturę LeNet-5 [37] (rys. 19).



Rys. 19. Schemat architektury LeNet-5

Implementacja modelu za pomocą biblioteki Keras została przedstawiona na rys. 20.



Rys. 20. Implementacja modelu za pomocą biblioteki Keras

Pierwszy etap: klasyfikacja czy obiekt jest tłem, czy zwierzęciem. Test skuteczności przedstawiono na rys. 21. Elementami tła mogą być nagrzane drzewa, krzaki, kamienie, elementy maszyn lub budynków itp. Skuteczność klasyfikacji obiektów na zbiorze testowym wyniosła 98,6%.



Rys. 21. Test skuteczności klasyfikacji obiektów w pierwszym etapie klasyfikacji

Drugi etap: klasyfikacja czy obiekt jest dzikiem, czy innym zwierzęciem. Skuteczność klasyfikacji obiektów na zbiorze testowym wyniosła 96,52% (rys. 22). W celu zwiększenia skuteczności klasyfikacji można zwiększyć bazę uczącą model lub ograniczyć zbiór uczący tylko do obiektów zaobserwowanych z danej wysokości lub pod danym kątem.

Warto zwrócić uwagę na fakt, że aplikacja działa z prędkością ponad 5 klatek/s (oczywiście prędkość przetwarzania obrazów zależy od parametrów użytego sprzętu).



Rys. 22. Wykres skuteczności klasyfikacji obiektów w drugim etapie klasyfikacji

5. Śledzenie obiektów

W celu zwiększenia stabilności klasyfikacji i szybkości działania aplikacji trwają prace nad opracowaniem algorytmu śledzenia obiektów sklasyfikowanych jako dziki. W założeniach, jeżeli dzik zostanie kilkukrotnie dobrze sklasyfikowany, to zostaje przypisany mu identyfikator i zaczyna się proces śledzenia. Algorytm śledzący oparty jest na określaniu różnic odległości między środkami śledzonych obiektów w kolejnych klatkach.

Jeżeli implementacja algorytmu śledzenia przyniosłaby oczekiwane efekty, można rozwinąć go o implementację estymatora ruchu obiektów. Najczęściej stosowane w dziedzinie przetwarzania obrazu są filtr Kalmana i algorytm kondensacji, które różnią się sposobem opisu gęstości prawdopodobieństwa stanu. Zastosowanie filtra Kalmana w śledzeniu obiektów na danych obrazowych z kamery termowizyjnej zostało opisane m.in. w pracach [38], [39].

6. Podsumowanie

Na bazie zebranych danych pomiarowych z kamer termowizyjnych oraz w oparciu o powyżej opisane metody analizy obrazów termowizyjnych opracowano algorytmy automatycznego wykrywania i wskazywania potencjalnych watah dzików w warunkach naturalnych oraz modele klasyfikacji i identyfikacji osobników z objawami choroby ASF. Do opracowania modeli klasyfikacyjnych wykorzystane zostały najnowsze techniki uczenia maszynowego typu Deep Learning, poprzez zintegrowanie ich z klasycznymi metodami analizy obrazu typu Feature Engineering w celu redukcji liczby danych wejściowych do sieci neuronowej.

Na podstawie analizy obrazów termowizyjnych ze stanowiska stacjonarnego oraz lotów BSP w naturalnych środowiskach bytowania dzików wysunięto następujące spostrzeżenia:

- Na wiarygodny pomiar za pomocą kamery termowizyjnej wpływa m.in.: nasłonecznienie otoczenia, elementy emitujące promieniowanie, warunki atmosferyczne (wiatr, deszcz, opady śniegu) wpływające na temperaturę powierzchni badanego obiektu.
- Istotnym parametrem mającym wpływ na wyniki badań jest wilgotność powietrza w otoczeniu obiektu obserwacji. Istotne znaczenie odgrywa również odległość kamery termowizyjnej od obiektu obserwacji. Istnieje silna korelacja wielkości obiektu obserwacji z odległością rejestracji kamerą termowizyjną.
- Kamera termowizyjna rejestruje pozorną temperaturę obiektu obserwacji.
- Ze względu na wyższy kontrast temperatury między dzikiem i otoczeniem preferowaną porą dnia pomiarów jest noc.
- Kamera nie powinna rejestrować obrazu dzika w rzucie poziomym. Rejestracja powinna się odbywać za pomocą kamery umieszczonej pod kątem ostrym, tak aby możliwe było zarejestrowanie profilu bocznego dzika. Wyłącznie ten profil dzika pozwoli odróżnić go od innych zwierząt.

Podziękowanie

Pracę zrealizowano w ramach Grantu Badawczo-Rozwojowego NCBiR, umowa nr DOB-BIO9/30/01/2018 pt. "Zastosowanie innowacyjnych i efektywnych metod i technologii umożliwiających wykrycie watah dzików, identyfikacji osobników z objawami klinicznymi ASF w naturalnym terenie ich występowania", realizowanego w latach 2018-2021.

Bibliografia

- EFSA AHAW Panel (EFSA Panel on Animal Health and Welfare), Scientific opinion on African swine fever, EFSA Journal, 13, 7, 4163, 2015, DOI: 10.2903/j.efsa.2015.4163
- European Food Safety Authority (EFSA), Desmecht D., Gerbier G., Schmidt G.C., Grigaliuniene V., Helyes G., Kantere M., Korytarova D., Linden A., Miteva A., Neghirla I., Olsevskis E., Ostojic S., Petit T., Staubach C., Thulke H.-H., Viltrop A., Richard W., Wozniakowski G., Abrahantes Cortiñas J., Broglia A., Dhollander S., Lima E., Papanikolaou A., van der Stede Y. and Stähl K., 2021, Scientific Opinion on the epidemiological analysis of African swine fever in the European Union (September 2019 to August 2020), EFSA Journal, 19, 5, 2021, DOI: 10.2903/j.efsa.2021.6572
- GUBERTI V., KHOMENKO S., MASIULIS M., KERBA S., African Swine Fever in Wild Boar Ecology and Biosecurity, FAO Animal production and health manual no. 22' FAO, Oie and ec. Rome, 2018. ISBN 978-92-5-131781-5 (FAO)
- WOŹNIAKOWSKI G., PEJSAK Z., JABŁOŃSKI A., Emergence of African Swine Fever in Poland (2014-2021). Successes and Failures in Disease Eradication, *Agriculture*, **11**, 738, 2021, DOI: 10.3390/agriculture11080738

- DE BONDI N., WHITE J.G., STEVENS M., COOKE R., A comparison of the effectiveness of camera trapping and live trapping for sampling terrestrial small-mammal communities, *Wildlife Research*, 37, 6, 456-465, 2010, DOI: 10.1071/WR10046
- FLEMING P., MEEK P., BALLARD G., BANKS P., CLARIDGE A., SANDERSON J., DON SWANN D., Camera Trapping: Wildlife Management and Research, Csiro Publishing, Collingwood (Melbourne), Australia, 2014, 392 s., ISBN 9781486300396
- CHENCHO, DECHEN LHAMO, KELZANG DORJI, Feasibility study on using passive infrared densor for wild pig repellent system in Bhutan, *International Journal of Science and Research (IJSR)*, 6, 17, 178-181, 2017, https://www.ijsr.net/get_abstract.php?paper_id=ART20178479
- 8. STANGER L.R., WILKES T.C., BOONE N.A., MCGONIGLE A.J.S., WILLMOTT J.R., Thermal imaging metrology with a smartphone sensor, *Sensors*, **18**, 2169, 2019, DOI: 10.3390/s18072169
- IWIŃSKI M., ZYDROŃ A., CHWIAŁKOWSKI C., DĄBROWSKI T., The use of a camera trap system for monitoring the movement of forest animals through the wildlife crossing in Napchanie, Annual Set the Environment Protection, 21, 1, 157166, 2019
- GIEFER M., AN L., Synthesizing remote sensing and biophysical measures to evaluate humanwildlife conflicts: the case of wild boar crop raiding in rural China, *Remote Sens.*, 12, 618, 2020, DOI: 10.3390/rs12040618
- WITCZUK J., PAGACZ S., ZMARZ A., CYPEL M., Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests – preliminary results, *International Journal of Remote Sensing*, **39**, 15-16, 5504-5521, 2018, DOI: 10.1080/01431161.2017.1390621
- SEIER G., HDL C., ABERMANN J., SCHTTL S., MARINGER A., HOFSTADLER D.N., PRBSTL-HAIDER U., LIEB G.K., Unmanned aircraft systems for protected areas: Gadgetry or necessity?, *Journal for Nature Conservation*, 64, 126078, 2021, DOI: 10.1016/j.jnc.2021.126078
- HYUN C.-U., PARK M., LEE W.Y., Remotely piloted aircraft system (RPAS) based wildlife detection: A review and case studies in maritime antarctica, *Animals*, 10, 2387, 2020, DOI: 10.3390/ani10122387
- 14. MESSINA G., MODICA G., Applications of UAV thermal imagery in precision agriculture: State of the art and future research outlook, *Remote Sens.*, **12**, 1491, 2020, DOI: 10.3390/rs12091491
- 15. JIN H., KPPL C.J., FISCHER B.M.C., ROJAS-CONEJO J., JOHNSON M.S., MORILLAS L., LYON S.W., DURÁN-QUESADA A.M., SUÁ REZ-SERRANO A., MANZONI S., GARCIA M., Drone-based hyperspectral and thermal imagery for quantifying upland rice productivity and water use efficiency after biochar application, *Remote Sens.*, 13, 1866, 2021, DOI: 10.3390/rs13101866
- DE OLIVEIRA D.C., WEHRMEISTER M.A., Using deep learning and low-cost RGB and thermal cameras to detect pedestrians in aerial images captured by multirotor UAV, Sensors, 18, 2244, 2018, DOI: 10.3390/s18072244
- PIETSCHMANN J., GUINAT C., BEER M., ET AL., Course and transmission characteristics of oral low-dose infection of domestic pigs and European wild boar with a Caucasian African swine fever virus isolate, *Arch. Virol.*, 160, 1657-1667, 2015, DOI: 10.1007/s00705-015-2430-2.
- CORDEIRO SANTANA D., ET AL., UAV-based multispectral sensor to measure variations in corn as a function of nitrogen topdressing, *Remote Sensing Applications: Society and Environment*, 23, 100534, 2021, DOI: 10.1016/j.rsase.2021.100534
- OLEJNIK A., KISZKOWIAK Ł., ROGÓLSKI R., CHMAJ G., RADOMSKI M., MAJCHER M., OMEN Ł., The use of unmanned aerial vehicles in remote sensing systems, *Sensors*, 20, 2003, 2020, DOI: 10.3390/s20072003
- BARELA J., FIRMANTY K., KASTEK M., Measurement and analysis of the parameters of modern long-range thermal imaging cameras, *Sensors*, 21, 5700. 2021, DOI: 10.3390/s21175700
- FRODELLA W., GIGLI G., MORELLI S., LOMBARDI L., CASAGLI N., Landslide mapping and characterization through infrared thermography (IRT): Suggestions for a methodological approach from some case studies, *Remote Sens.*, 9, 1281, 2017, DOI: 10.3390/rs9121281

- GONZALEZ L.F., MONTES G.A., PUIG E., JOHNSON S., MENGERSEN K., GASTON K.J., Unmanned aerial vehicles (UAVs) and artificial intelligence revolutionizing wildlife monitoring and conservation, Sensors, 16, 97, 2016, DOI: 10.3390/s1601009
- KIM J., CHUNG Y., CHOI Y., SA J., KIM H., CHUNG Y., PARK D., KIM H., Depth-based detection of standing-pigs in moving noise environments, *Sensors*, 17, 2757, 2017, DOI: 10.3390/s1712275
- 24. JAROLMEK J., VANÉK J., JEŽEK M., MASNER J., STOČES M., The telemetric tracking of wild boar as a tool for field crops damage limitation. *Plant Soil Environ.*, **60**, 418-425, 2014, DOI: 10.17221/462/2014-PSE
- SAMIAPPAN, SATHISHKUMAR, ET AL., Quantifying damage from wild pigs with small unmanned aerial systems, Wildlife Society Bulletin, 42, 2, 304-309, 2018, https://www.jstor.org/stable/90022730
- HOHMANN U., KRONENBERG M., SCHERSCHLICHT M., SCHNFELD F., The possibilities and limitations of thermal imaging to detect wild boar (Sus scrofa) carcasses as a strategy for managing African Swine Fever (ASF) outbreaks, *Berliner und Münchener Tierärztliche Wochenschrift*, 134, 1-14, 2021, DOI: 10.2376/1439-0299-2020-46
- ARAI K., NUGRAHA ABDULLAH I., KUBO K., SUGAWA K., Methods for wild pig identifications from moving pictures and discrimination of female wild pigs based on feature matching methods, *International Journal of Advanced Research in Artificial Intelligence (IJARAI)*, 4, 7, 2015, DOI: 10.14569/IJARAI.2015.040707
- KORBICZ J., OBUCHOWICZ A., UCIŃSKI D., SSztuczne sieci neuronowe: podstawy i zastosowania, Warszawa : Akademicka Oficyna Wydawnicza, 1994, ISBN 8371011970
- IVAŠIĆ-KOS M., KRIŠTO M., POBAR M., Human detection in thermal imaging using yOLO, Proceedings of the 2019 5th International Conference on Computer and Technology Applications, ICCTA 2019, Association for Computing Machinery, New York, NY, USA, 20-24, 2019, DOI: 10.1145/3323933.3324076
- IPPALAPALLY R., MUDUMBA S.H., ADKAY M., NANDI VARDHAN H.R., Object detection using thermal imaging, 2020 IEEE 17th India Council International Conference (INDICON), 1-6, 2020, DOI: 10.1109/INDICON49873.2020.9342179
- DAVIS J.W., SHARMA V., Robust BACKGROUND-SUBTRACTION FOR PERSON DETEC-TION IN THERMAL IMAgery, Conference on Computer Vision and Pattern Recognition Workshop, 128-128, 3004, DOI: 10.1109/CVPR.2004.431
- FERNÁ NDEZ-CABALLERO A., LÓPEZ M.T., SERRANO-CUERDA J., Thermal-infrared pedestrian ROI extraction through thermal and motion information fusion, *Sensors*, 14, 6666-6676, 2014, DOI: 10.3390/s140406666
- 33. 33. CHRISTIANSEN, P.; STEEN, K.A.; JØRGENSEN R.N., KARSTOFT H., Automated detection and recognition of wildlife using thermal cameras, *Sensors*, 14, 13778-13793, 2014, DOI: 10.3390/s140813778
- 34. TOMASI C., MANDUCHI R., Bilateral filtering for gray and color images, Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271), 839-846, 1998, DOI: 10.1109/ICCV.1998.710815
- 35. OISHI Y., OGUMA H., TAMURA A., NAKAMURA R., MATSUNAGA T., Animal detection using thermal images and its required observation conditions, *Remote Sens.*, 10, 1050. 2018, DOI: 10.3390/rs10071050
- CANNY J., A computational approach to edge detection, *IEEE Transactions on Pattern Analysis* and Machine Intelligence, PAMI-8, 6, 679-698, 1986, DOI: 10.1109/TPAMI.1986.4767851
- LECUN Y., BOSER B., DENKER J.S., HENDERSON D., HOWARD R.E., HUBBARD W., JACKER L.D., Handwritten digit recognition with a back-propagation network, *Advances in Neural Information Processing Systems*, 2, 2, 396-404, 1989, https://proceedings.neurips.cc/paper/1989/file/53c3bce66e43be4f209556518c2fcb54-Paper.pdf.

- GADE R.; MOESLUND T.B., Thermal tracking of sports players, Sensors, 14, 13679-13691, 2014, DOI: 10.3390/s140813679
- 39. TADEUSIEWICZ R., KOROHODA P., *Komputerowa analiza i przetwarzanie obrazów*, Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków, 1997

Application of aerophotogrammetry in infrared to track wild boars in their natural environment and identify individuals infected with African swine fever. Part I – System architecture and identification methodology

This article presents a system that uses aerial photometry for detecting wild boars and identifying individuals infected with African swine fever. The system relies on two types of unmanned aerial vehicles (UAVs): a four-rotor micro-rotor wing and a mini-class UAV. Such UAVs are equipped with thermal imaging optoelectronic sensors, data transmission systems and thermal image analysis software. The article provides a detailed description of the system architecture and methodology for analyzing thermal images. Additionally, the article discusses algorithms for detecting wild boars in their natural environment and automatically identifying those infected with African swine fever. The system capability to detect and identify individual animals enables targeted management strategies to reduce the spread of the disease. The proposed system can provide a practical solution for wild boar management and disease control in natural environments.