



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Warszawa, 28.02.2021

NETWORK PARTNERS TOMASZ MACHNICKI SPÓŁKA JAWNA
SPRAWOZDANIE Z PRAC BADAWCZO – ROZWOJOWYCH

„Prace badawczo-rozwojowe nad zautomatyzowaniem procesu inwentaryzacji i niszczenia Barszczu Sosnowskiego Heracleum Sosnowskyi i Barszczu Mantegazziego Heracleum Mantegazzianum za pomocą systemów bezzałogowych”

Sprawozdanie sporządził:	Jacek Jabłoński
Zatwierdził:	Tomasz Machnicki

Przeprowadzenie prac B+R celem: opracowania algorytmów umożliwiających zautomatyzowanie procesu inwentaryzacji, a także niszczenia niebezpiecznych gatunków roślin, jakimi są Barszcz Sosnowskiego i Barszcz Mantegazziego (barszcze kaukaskie) za pomocą systemów bezzałogowych.

Okres realizacji prac:	Od: 2017-09-01 Do: 2021-02-28
-------------------------------	----------------------------------

1. SŁOWNIK POJEŃ

B+R - działalność badawcza i prace rozwojowe, obejmuje pracę twórczą podejmowaną w sposób systematyczny w celu zwiększenia zasobów wiedzy, oraz wykorzystanie tych zasobów wiedzy do tworzenia nowych zastosowań. Obejmuje trzy rodzaje działalności:

- badania podstawowe
- badania przemysłowe
- prace rozwojowe

Badania podstawowe - to działalność eksperymentalna lub teoretyczna podejmowana przede wszystkim w celu zdobycia nowej wiedzy na temat podłoża zjawisk i obserwowalnych faktów bez nastawienia na konkretne zastosowanie lub wykorzystanie,

Badania przemysłowe - to także oryginalna praca badawcza podejmowana w celu zdobycia nowej wiedzy. Jest ona jednak zorientowana przede wszystkim na konkretny cel praktyczny,

Prace rozwojowe - to systematyczna praca opierająca się na istniejącej wiedzy uzyskanej w wyniku działalności badawczej oraz/lub doświadczeń praktycznych i mająca na celu wytworzenie nowych materiałów, produktów lub urządzeń, inicjowanie nowych lub znaczące udoskonalenie już istniejących procesów, systemów i usług.

2. WPROWADZENIE

Niniejszy dokument stanowi wewnętrzną dokumentację firmy NETWORK PARTNERS TOMASZ MACHNICKI SPÓŁKA JAWNA i jest przeznaczony tylko do wewnętrznego przetwarzania. Stanowi podsumowanie prac badawczo-rozwojowych przeprowadzonych w okresie od września 2019 do lutego 2021 dotyczących przeprowadzenia prac B+R w celu opracowania nowego produktu, zautomatyzowanego systemu inwentaryzowania i niszczenia barszczy kaukaskich za pomocą dronów. Prace prowadzone były w ramach projektu nr POIR.01.01.01-00-0189/17, tytuł projektu *„Prace badawczo-rozwojowe nad zautomatyzowaniem procesu inwentaryzacji i niszczenia Barszczu Sosnowskiego Heracleum Sosnowskyi i Barszczu Mantegazziego Heracleum Mantegazzianum za pomocą systemów bezzałogowych.”*, realizowanego w ramach Programu Operacyjnego Innowacyjny Rozwój, priorytet I, działanie 1.1 Projekty B+R przedsiębiorstw, Numer naboru: 1/1.1.1/2017.

3. ANALIZA POTRZEB

Barszcz kaukaski jest z gatunku roślin inwazyjnych, a państwa członkowskie UE mają obowiązek tworzenia planów i programów dot. zwalczania tych gatunków. W połowie XX wieku był uprawiany w krajach b. bloku wschodniego jako roślina pastewna, przeznaczona na pasze. Z powodu problemów z jej uprawą, zbiorem, a także negatywnego oddziaływania na zdrowie roślin i zwierząt, uprawy były porzucane. Obecnie występuje w każdym województwie kraju, a jego areał rośnie z roku na rok. Barszcz jest odporny na wiele środków do zwalczania chwastów, ma dużą zdolność do regeneracji i łatwo się rozmnaża. Szczególnie groźne są wydzielane przez niego olejki eteryczne, które przy kontakcie ze skórą powodują poważne i bolesne oparzenia. Co roku na pogotowie trafiają kolejni poparzeni, gdyż jego przekwitnięte kwiaty mylone są z koprem włoskim oraz z barszczem zwyczajnym. Barszcz kaukaski to roślina trudna do zwalczania, niebezpieczna, szczególnie dla dzieci, uniemożliwia dostęp do terenów, na których rośnie, odkryto także jej działanie rakotwórcze i teratogenne. Są znane przypadki śmierci spowodowane zetknięciem się z tą rośliną. W lipca 2015 roku w siemianowickim Centrum Leczenia Oparzeń zmarła 67-letnia kobieta, która oparzyła sobie rękę barszczem Sosnowskiego. Kobieta zmarła w wyniku nagłego zatrzymania krążenia. Kilkanaście dni wcześniej kosząc trawę w ogródku oparzyła sobie rękę barszczem Sosnowskiego. Oparzeniu uległo 5% jej ciała. Choć oparzenie nie było duże, toksyny dostały się do jej organizmu, a w wyniku powikłań doprowadziły do jej śmierci. W upalne dni barszcz wydziela opary, które mogą porazić układ oddechowy. Również krążące w roślinie soki mają silne właściwości parzące.

Jej zdradliwość zaś polega na tym, że objawy nie są widoczne i odczuwalne bezpośrednio po kontakcie z rośliną. Dolegliwości po kontakcie skóry z sokiem barszczu pojawiają się w ciągu od 30 minut do dwóch godzin po fakcie. W czasie upałów toksyczne związki barszczu Sosnowskiego mogą wydostawać się z rośliny również w postaci lotnej. Związki te, oprócz poparzeń skórnych, mogą powodować obrażenia dróg oddechowych, wymioty, bóle głowy, nudności, mogą prowadzić do uszkodzenia wzroku, zapalenia spojówek i skóry. Na nasilenie występowania objawów mają wpływ warunki, szybszej i silniejszej reakcji można się spodziewać przy większej wilgotności (deszcz, spocona skóra) i nasłonecznieniu. Aktywatorem dla toksyn są bowiem promienie ultrafioletowe. Kontakt z rośliną może spowodować poparzenia II i III stopnia. To bardzo żywotna roślina, bardzo łatwo się nią poparzyć, nawet przez ubranie, a rany długo się goją i są bolesne.

Roślina jest niebezpieczna również dla zwierząt, u których może powodować poparzenia, podrażnienie przewodu pokarmowego, a nawet krwotok wewnętrzny. Może powodować

oparzenia także u zwierząt hodowlanych, na przykład wymion krów mlecznych. Mleko i mięso od zwierząt, które spożywały barszcz nie nadaje się już do konsumpcji dla ludzi. Stanowi to niemały problem dla rolników, którzy ponoszą z tego tytułu straty, a także dla gmin, ponieważ rolnicy straty te chcą pokryć odszkodowaniami, których żądają od gminy, na terenie której zatrwały się zwierzęta. Często do poparzeń dochodzi wśród rolników i pracowników zajmujących się pielęgnacją zieleni publicznej. W 2002 r. barszcz Sosnowskiego po raz pierwszy został uwzględniony w „Klasyfikacji szkodliwych czynników biologicznych występujących w środowisku pracy oraz narażonych na nie grup zawodowych”, jako czynnik zagrożenia zawodowego. Na skutek powyższego osoby, które podczas pracy uległy poparzeniom spowodowanym przez ten gatunek, mogły ubiegać się o zwiększone świadczenia z Kasy Rolniczego Ubezpieczenia Społecznego czy ZUS z tytułu choroby zawodowej.

Resort środowiska pracuje nad nowymi przepisami, które mają zapewnić lepszą koordynację działań związanych ze zwalczaniem barszczu, a województwa apelują do gmin o monitorowanie występowania oraz usuwanie barszczu kaukaskiego. Gminy więc próbują prowadzić z agresywną rośliną ostrą walkę, ale to ciągle za mało. Obecnie wyróżnia się dwie metody zwalczania barszczu:

1) mechaniczną poprzez:

- wykopywanie całych roślin, - osłanianie i ścinanie kwiatostanów (kaukaskie barszcze są roślinami monokarpicznymi, co oznacza, że samoistnie obumierają po wydaniu nasion; metoda polega na tym, by pozwolić roślinie na wydanie nasion, a tym samym doprowadzić do jej zamarcia przy jednoczesnym niedopuszczeniu do rozsiania się nasion),

- przecinanie szyjki korzeniowej;

2) chemiczną poprzez:

- opryski chemiczne (rozpylanie środków chemicznych z pewnego dystansu zazwyczaj opryskiwaczami maszynowymi lub ręcznymi)

- iniekcje (wprowadzenie wnętrza rośliny środków chemicznych)

- mazakowanie (naniesienie na powierzchnię rośliny środków chemicznych).

Koszenie nie jest metodą zwalczania kaukaskich barszczy, może jedynie być traktowane jako zabieg mający na celu ograniczenie ekspansji tych gatunków lub przygotowujący dane stanowisko do przeprowadzenia innych metod zwalczania.

Każda z tych metod wymaga zbliżenia się człowieka wykonawcy do niebezpiecznych kaukaskich barszczy. Należy pamiętać, że podczas mechanicznego uszkodzenia tych gatunków wzrasta w nich stężenie substancji toksycznych (jest to mechanizm obronny rośliny), co zwiększa poziom zagrożenia dla zdrowia pracowników wykonujących zabiegi zwalczania. Praca bazująca na

wykorzystaniu herbicydów niezależnie od toksyczności samych barszczy dodatkowo wiąże się z niebezpieczeństwem styczności z substancjami chemicznymi.

Barszcz występuje w każdym województwie naszego kraju, a jego areał rośnie z roku na rok, do 2016 roku na terenie samego Mazowsza znajdowało się 50 potwierdzonych miejsc.

Niszczenie roślin wykonywane jest ręcznie (dłońmi w rękawicach), przy pomocy motyk bądź też specjalistycznego sprzętu. Wszystkie osoby biorące udział w zwalczaniu barszczu, bez względu na stosowaną metodę i wykonywaną pracę, muszą być dokładnie poinformowane o szkodliwości oraz toksycznych i parzących właściwościach tej rośliny, ponadto muszą być wyposażone w odpowiednie ubrania ochronne.

Z powodu mało skutecznych i bardzo niebezpiecznych dla ludzi obecnych metod inwentaryzowania, monitoringu i zwalczania barszczu, pożądanym rozwiązaniem będzie innowacyjna usługa, która pozwoli w bezpieczny, szybki i skuteczny sposób zinwentaryzować i zniszczyć barszcz kaukaski - co bardzo ważne, bez udziału człowieka w bezpośrednim kontakcie z tą groźną rośliną. Drony występują tutaj jako maszyny w celu ochrony ludzi.

4. APARATURA BADAWCZA

W pracach badawczych korzystano z poniższej aparatury badawczej:

- Mobilna Stacja Kontroli Lotów;
- System bezzałogowy wraz z kamerami do inwentaryzowania barszczy kaukaskich – 2 systemy;
- System bezzałogowy do badań nad niszczeniem barszczy kaukaskich – 2 systemy;
- 4 komputery stacjonarne do tworzenia map;
- 1 komputer stacjonarny do projektowania 3D;
- 1 laptop do nadzorowania lotu i projektowania map;

oraz z wartości niematerialnych i prawnych:

- Oprogramowanie do tworzenia ortofotomap wraz z kamerą wielospektralną;
- Oprogramowanie do tworzenia treści 3D z fotografii cyfrowej;
- Oprogramowanie konstrukcyjne 3D;
- Oprogramowanie do tworzenia algorytmu;
- Program do projektowania PCB i schematów elektronicznych.

5. SKŁAD OSOBOWY ZESPOŁU B+R

Kadra badawcza bezpośrednio zaangażowana w realizację prac B+R:

- Kierownik projektu/Pilot Operator UAVO, Konstruktor: Pan Jacek Jabłoński;
- Specjalista ds. Fotogrametrii: Pani Agnieszka Jabłońska;
- Specjalista ds. barszczy kaukaskich: Pani Izabela Sachajdakiewicz;
- Specjalista ds. barszczy kaukaskich: Pan Piotr Mędrzycki;
- Programista: Pan Adam Michalak oraz Pan Marcin Sikorski;
- Główny Technolog Konstrukcji: Pan Grzegorz Kaliński;
- Pilot UAV: Pani Justyna Zdanowska;
- Konstruktor: Pan Piotr Pabjanek.

6. PRACE BADAWCZE ORAZ ICH WYNIKI

A. Etap nr: **1**, realizowany w ramach **badan przemysłowych** .

nazwa: Przeprowadzenie prac badawczych nad opracowaniem algorytmu do automatyzacji rozpoznania barszczy kaukaskich przy pomocy systemów bezzałogowych i kamer wielospektralnych

Lista wykonanych prac w ramach pierwszego etapu projektu:

1. Opracowanie zamówień publicznych
 - 1.1. Opracowano trzy zamówienia publiczne.
 - 1.2. Wybrano najkorzystniejsze oferty
 - 1.3. Podpisano umowy
 - 1.4. Przyjęto sprzęt na stan
2. Kalibracja i dostosowanie dronów do potrzeb projektu
 - 2.1. Instalacja sprzętu komputerowego
 - 2.2. Instalacja oprogramowania na w/w
 - 2.3. Uruchomienie sieci i przetestowanie działania
 - 2.4. Odbiór dwóch dronów
 - 2.5. Dostosowanie ich do potrzeb projektu
3. Wybór stanowisk do oblotu
 - 3.1. Wybrano stanowiska w okolicy Gorzowa Wlk. jako najbardziej reprezentatywne
 - 3.2. Ilość stanowisk 46 o łącznej powierzchni ok 25 ha każde. Łącznie 1150 ha
 - 3.3. Sprawdzono również inne stanowiska, w sumie 34 lokalizacje
4. Pierwsze loty kalibracyjne

- 4.1. Wykonano serię nalotów celem ustalenia wysokości AGL nalotów i typu obiektywu oraz prędkości lotów
- 4.2. Za najbardziej optymalne warunki uznano:
 - 4.2.1. Wysokość 100m AGL
 - 4.2.2. Prędkość poziomą 10 m/s
 - 4.2.3. Obiektyw 55 mm
5. Wykonanie serii nalotów testowych
 - 5.1. Wykonano serię 60 nalotów testowych
 - 5.2. Wyregulowano autopilota
 - 5.3. Ustalono parametry konfiguracyjne aparatu
6. Składanie mozaik i analiza danych
 - 6.1. Złożono mozaiki z nalotów testowych
 - 6.2. Zunifikowano proces ich tworzenia
 - 6.3. Przetestowano 4 aplikacje do ich tworzenia (AgiSoft, Pix4D, EnsoMOSAIC, APS)
 - 6.4. Wybrano Pix4D jako najkorzystniejsza
7. Ustalenie procedur nalotów docelowych
 - 7.1. Ustalono logistykę wyboru miejsc startowych
 - 7.2. Ustalono listę sprzętu potrzebnego podczas nalotów
 - 7.3. Ustalono procedury logistyczne bytowania
8. Wykonanie nalotów nad stanowiskami docelowymi
 - 8.1. Zaplanowano 283 naloty
 - 8.2. Wykonano plany misji do tychże nalotów
 - 8.3. Wykonano serię 200 nalotów
 - 8.4. Naloty wykonano nad 15 różnymi lokacjami
 - 8.5. Wykonano 200.000 zdjęć kamerą SONY A7R3 oraz ok 1.000.000 zdjęć kamerą RedEdgeM
 - 8.6. Do każdej serii zdjęć dołączono plik z geolokacjami
 - 8.7. Złożono 82 mozaiki z kamery SONY A7R3 oraz 78 z kamery RedEdge-M
9. Analiza danych
 - 9.1. Zespół specjalistów przeprowadził analizę tych zdjęć oraz wizje lokalne - raport
10. Ocena efektywności
 - 10.1. Współczynnik wykonania nalotów do zaplanowanych 70%
 - 10.2. Współczynnik wykonania przydatnego materiału fotograficznego 95%

Opis prac badawczych:

Zespół Specjalistów ds. Kaukaskich Barszczy przyjął wewnętrzny plan prac nad algorytmem, który objął zdefiniowanie działań, które będą objętych algorytmem, jednocześnie stanowiąc procedurę jego tworzenia i stałego adaptowanego doskonalenia.

Na etapie I projektu prowadzono prace dotyczące Działu 1 Formułowanie założeń. Oprócz wymogów formalnych zdefiniowanych w projekcie dodano następujące założenia techniczne i merytoryczne, mające na celu zapewnienie jego optymalnego tworzenia i wykorzystywania w środowisku docelowym:

1.2.1.1 algorytm ma umożliwiać identyfikację barszczy w terenie na podstawie zdjęć i dodatkowych danych

1.2.1.2 algorytm ma mieć charakter adaptacyjny, czyli umożliwiać stopnie zwiększanie jakości i poszerzanie zakresu warunków możliwości rozpoznawania

1.2.1.3 algorytm ma być oszczędny w wykorzystaniu danych, mocy obliczeniowej, czasu

1.2.1.4 algorytm ma być odporny na braki danych

1.2.1.5 algorytm ma być hierarchiczny, czerpać wskazania do decyzji z danych na innych poziomach szczegółowości

1.2.1.6 algorytm ma być open-source, szczegółowa parametryzacja ma stanowić tajemnicę przedsiębiorstwa.

Większość prac toczyła się w ramach zdefiniowanego Działu 2 – Rozpoznawanie. W ramach niego wydzielono następujące poddziały docelowego algorytmu rozpoznawania barszczy, rozumiane jako zespoły działań, których przebieg może wpływać na skuteczność lub warunki prowadzenia rozpoznawania:

Poddział 2.1 Pozyskanie zlecenia (poza zakresem bieżącego etapu)

Poddział 2.2 Wstępna ocena występowania barszczy - z wykorzystaniem modeli rozmieszczenia gatunku (SDM), umożliwiająca wstępną preselekcję miejsc i warunków występowania barszczy;

Poddział 2.3 Planowanie i realizacja lotów – jako działania, których odpowiednie przeprowadzenie będzie miało wpływ na skuteczność rozpoznania,

Poddział 2.4 Przechowanie i obróbka zdjęć – jako czynności formalne umożliwiające docelowo zwiększanie poziomu automatyzacji pracy algorytmu,

Poddział 2.5 Budowa algorytmu – obejmujący etapy tworzenia samego algorytmu czynnościowego i obliczeniowego rozpoznawania. Poddział podzielono na 3 zadania, obejmujące 3 fazy tworzenia algorytmu, merytorycznie odpowiadające etapom dojrzewania technologii.

Zadanie 2.5.1 Proof of concept – miało doprowadzić do doboru metod i narzędzi, które pokażą, że rozpoznanie barszczy w dogodnych warunkach jest możliwe i że jego skuteczność

osiąga lub przekracza poziom przewidziany w milestone, czyli 75%.

Zadanie 2.5.2 Scope extension - Powtarzanie zadania 2.5.1. z zapisem metadanych, stopniową automatyzację poprzez skrytpowanie, optymalizację zwiększanie uniwersalności i zakresu dopuszczalności stosowania.

Zadanie 2.5.3 Production ready – obejmujący weryfikację i dokumentację funkcji używanych do rozpoznawania, oraz tworzenie i wdrożenie narzędzi wspomagania decyzji i stopniowe testy w warunkach docelowego stosowania.

W toku realizacji etapu I przeprowadzono pracę nad zdaniem 2.5.1, którego realizacja odpowiadała wymogom

Milestone 1: algorytm ma osiągnąć poziom skuteczności rozpoznania min. 75%.

W tym celu wydzielono i realizowano cztery podzadania:

Podzadanie 2.5.1.1 Presekcja algorytmów rozpoznawania, służące do inicjalnego wytypowania metod i narzędzi możliwych do pozyskania i wykorzystania w tworzeniu algorytmu,

Podzadanie 2.5.1.2 Wyznaczanie obiektów klasyfikacji – wybór zobrazowań dających szansę na osiągnięcie wysokich skuteczności rozpoznawania, oraz wskazanie obiektów poddanych klasyfikacji nadzorowanej.

Podzadanie 2.5.1.3 Sesje rozpoznawanie barszczu – prowadzenie – sesji rozpoznania,

Podzadanie 2.5.1.4 Kontrola jakości rozpoznania – weryfikacja, czy algorytm przyniósł rezultat w postaci osiągnięcia poziomu skuteczności wyznaczonego przez Milestone 1: **min75%**.

W ramach podzadania 2.5.1.1. przeprowadzono analizę literatury z zakresu teledetekcji roślinności pod kątem możliwości realizacji rozpoznawania kaukaskich barszczy. Wyniki przeglądu wykazały, że mając do dyspozycji zobrazowania wielospektralne w paśmie widzialnym i 3-5 dodatkowych kanałów, rozpoznanie barszczy lub roślinności zbliżonej do niego metodami spektralnymi może mieć ograniczoną skuteczność. Skuteczność przewidziana w Milestone I bywała niekiedy osiągnięta przy wykorzystaniu zdjęć hiperspektralnych, których stałe pozyskiwanie znajduje się jednak poza zakresem możliwości technicznych i finansowych projektu. Ustalono za to, że **bardzo wysokie rozdzielczości terenowe zobrazowań z aparatów latających klasy UAS umożliwiają wykorzystanie pokrewnych metod teledetekcyjnych – rozpoznawania obiektowego.** W literaturze odnaleziono przykłady bardzo wysokiej skuteczności rozpoznawania barszczy z użyciem tej metody. Metodę tę wraz z zastosowanym oprogramowaniem eCognition zarekomendowano optymalną kombinację wyjściową.

W toku realizacji podzadania 2.5.1.2. wytypowano zobrazowania uzyskane w 3 lotach jako

spełniające warunki techniczne (ostrość, geolokalizacja, dobre naświetlenie) i biologiczne (dobrze widoczne barszcze, mało złożone tło, niska wysokość i różnorodność roślinności tła, mała liczba warstw roślinności, duże zagęszczenie barszczy w płacie).

Równocześnie w programie QGIS stworzono zbiory punktów treningowych wskazujących klasy obiektów do klasyfikacji nadzorowanej w dwóch wariantach: jeden typ barszczy (liście osobników juwenilnych) + tło oraz dwa typy barszczy (liście osobników juwenilnych+suche łodygi i owocostany osobników owocujących + tło).

W toku realizacji podzadania 2.5.1.3. przeprowadzono sesje rozpoznania, w których osiągnięto z użyciem programu eCognition Essential Trial 13.1 maksymalną skuteczność 84%.

Pozwala to uznać, że w pracach nad algorytmem zrealizowano pomyślnie fazę ProofOfConcept a skuteczność rozpoznania z użyciem technologii pozyskiwania i przetwarzania zobrażeń osiągnęła i przekroczyła poziom wyznaczony w Milestone 1.

WYNIKI:

Poziom TRL osiągnięty po zakończeniu ww. Etapu: V

Osiągnięty kamień milowy: Algorytm do automatyzacji rozpoznania barszczy kaukaskich przy pomocy systemów bezzałogowych i kamer wielospektralnych.

W toku obu scenariuszy rozpoznawania (1 typ barszczu + tło oraz 2 typy barszczy + tło) uzyskano maksymalną dokładność całkowitą 83% i 84%.

Osiągnięto wynik lepszy niż zakładano we wniosku o dofinansowanie. We wniosku zakładano, że algorytm zostanie uznany za skuteczny, gdy osiągnie wynik na poziomie 75%.

B. Etap nr: 2, realizowany w ramach badań przemysłowych .

nazwa: Przeprowadzenie prac badawczych nad opracowaniem algorytmu niszczenia barszczy kaukaskich różnymi metodami za pomocą systemów bezzałogowych.

Badanym rozwiązaniem będzie algorytm niszczenia barszczy kaukaskich przy pomocy systemów bezzałogowych. Opracowany algorytm umożliwi zwalczanie niepożądanych roślin z wykorzystaniem systemów bezzałogowych poprzez ich skaszanie, mazakowanie, iniekcję oraz opryski.

Opis prac badawczych:

badania miały na celu uzyskanie wiedzy jak w sposób zdalny, z wykorzystaniem systemów bezzałogowych wyeliminować zagrożenia wynikające z konieczności styczności z kaukaskimi

barszczami osób podejmujących się ich zwalczania oraz w jaki sposób poprzez użycie dronów maksymalnie zautomatyzować cały proces zwalczania groźnych roślin, a co za tym idzie uprościć go i w pewnych metodach przyspieszyć. Do tej pory robi się to ręcznie, niszczenie barszczy realizuje się wg odpowiednich metod które już są opracowane. Badania mają na celu zaadaptować te metody do systemów bezzałogowych. Niezbędne jest w tym celu opracowanie algorytmu niszczenia barszczy za pomocą systemów bezzałogowych. Algorytm będzie tworzony na podstawie już istniejących metod dla pracy ręcznej. Założeniem etapu drugiego jest opracowanie algorytmu niszczenia oraz skonstruowanie sprzętu do tego celu (odpowiednich głowic) bazując na dostępnym obecnie sprzęcie do ręcznego niszczenia roślin.

Problem badawczy:

1. Ewentualna złożoność procesu niszczenia.

Problem badawczy będzie stanowić dobór skutecznych metod zwalczania za pomocą systemów bezzałogowych i opracowanie do tego celu odpowiednich głowic, które zamocowane do drona zastąpią obecny „ręczny” proces zwalczania takimi metodami jak:

- osłanianie i ścinanie kwiatostanów (kaukaskie barszcze są roślinami monokarpicznymi, co oznacza, że samoistnie obumierają po wydaniu nasion. Metoda polega na tym, by pozwolić roślinie na wydanie nasion, a tym samym doprowadzić do jej zamarcia przy jednoczesnym niedopuszczeniu do rozsiania się nasion);
- przecinanie szyjki korzeniowej specjalną kosą;
- chemicznymi poprzez:
 - opryski chemiczne, problem badawczy to opracowanie głowicy do rozpylania tak aby rozpylanie było ukierunkowane;
 - iniekcje - wprowadzenie do wnętrza rośliny środków chemicznych;
 - mazakowanie - naniesienie na powierzchnię rośliny środków chemicznych;

Obecnie każda z tych metod wymaga zbliżenia się człowieka do niebezpiecznych roślin. Należy pamiętać, że podczas mechanicznego uszkodzania tych gatunków wzrasta w nich stężenie substancji toksycznych (jest to mechanizm obronny rośliny), co zwiększa poziom zagrożenia dla zdrowia pracowników wykonujących zabiegi zwalczania. Praca bazująca na wykorzystaniu herbicydów niezależnie od toksyczności samych barszczy dodatkowo wiąże się z niebezpieczeństwem styczności z substancjami chemicznymi. Maszyny sterowane zdalnie wyeliminują zagrożenie wynikające z konieczności styczności z kaukaskimi barszczami osób podejmujących się ich zwalczania. Po za tym użycie systemów bezzałogowych bardzo zautomatyzuje cały proces, a co za tym idzie uprości go i w pewnych metodach przyspieszy.

2. Uzyskanie odpowiedniej selektywności niszczenia

Problemem badawczym będzie uzyskanie odpowiedniej selektywności niszczenia, która umożliwi niszczenie wyłącznie barszczy, bez roślin rosnących w jego otoczeniu.

Sposób rozwiązania:

Badania nad doбором najbardziej optymalnych i skutecznych metod zwalczania przy pomocy dronów. Przeprowadzenie badań nad wytworzeniem układu sprzęgniętego w system autopilota platformy latającej, który pozwoli utrzymać precyzyjną wysokość podczas zabiegów niszczenia niezależnie od dobranej metody zwalczania. Następnie przeprowadzenie badań i testów w warunkach laboratoryjnych nad konkretnymi rozwiązaniami, które dadzą oczekiwany wynik w postaci zautomatyzowanego systemu do zwalczania groźnych roślin przy pomocy dronów.

Przyjęta koncepcja zakłada badania nad opracowaniem algorytmów kwalifikujących odpowiedni proces niszczenia w zależności od odpowiedniego typu barszczu i miejsca jego położenia (ukształtowanie terenu) oraz kwalifikujących rośliny żyjące w otoczeniu danego stanowiska barszczu. Jest to konieczne aby nie zniszczyć innych roślin, oprócz danego stanowiska barszczu. Jakość i procentowa ilość usuniętych roślin z danego stanowiska będzie potwierdzana w terenie osobiście przez specjalistów ds. barszczów kaukaskich. Takie rozwiązanie umożliwi wyznaczenie wskaźników skuteczności niszczenia. Z każdej z metod niszczenia będzie generowany raport z postępu prac dla każdego stanowiska, co pozwoli na weryfikację procesów niszczenia oraz na ocenę jego skuteczności.

Przesłanki za powodzeniem: obecny stan wiedzy dotyczący podobnych rozwiązań w branży bezałogowych statków powietrznych, co pozwala sądzić, że planowane założenie jest możliwe do realizacji.

Etap II obejmował następujące działania:

1) Badania nad metodami niszczenia oraz ich funkcjonalnością i skutecznością w walce z barszczem kaukaskim.

Założeniem prac badawczych w tym etapie było opracowanie metod niszczenia barszczy kaukaskich za pomocą podwieszanych do drona głowic:

- koszenie roślin za pomocą głowicy podwieszanej pod drona. Ważnym elementem badań nad głowicą to ustalenie możliwości jej opuszczania się tak, aby koszenie było wykonywane bez zahaczania o roślinę poprzez wirniki nośne;

- mazakowanie środkami chemicznymi za pomocą głowicy podwieszanej pod drona. Zadaniem głowicy będzie pomazać łodygę rośliny środkiem chemicznym, co spowoduje jej zniszczenie.

Niezbędne były badania nad opracowaniem mobilnej wersji systemu mazakowania oraz

odpowiednim zbiornikiem z systemem transportowania cieczy do mazakowania do głowicy. Odpowiedni zbiornik powinien być trwały i wytrzymały, odporny na pestycyd, który nie rozpadnie się w locie oraz pojemny, tj. mieszczący 3 do 5 litrów środka;

- iniekcja roślin wykonywana głowicą podwieszaną pod drona. Głowica do iniekcji również wymaga zbiornika na ciecz z systemem transportowania. Badania nad tą metodą będą dotyczyły przede wszystkim wkluwania się w roślinę, na początku sterując dronem ręcznie, a docelowo automatycznie;

- opryski wykonywane głowicą przymocowaną do drona. Przedmiotem badań będzie opracowanie głowicy do oprysków zawierającej zbiornik na ciecz opryskową oraz odpowiednio rozłożone dysze. Obecnie wykonywane są już opryski rolnicze za pomocą dronów. Lecą jednak one jedynie na wprost i spryskają pod siebie, ciągnąc za sobą chmurę rozpylonej cieczy, która opada z wiatrem. Innowacyjność metody, która zostanie opracowana w tym etapie prac badawczych będzie polegać na spryskiwaniu danej rośliny w zawisie lub przy minimalnej prędkości z automatyczną poprawką na wiatr, tak by najbardziej precyzyjnie wycelować opryskiem w roślinę. Dzięki takiemu rozwiązaniu rośliny sąsiadujące z opryskiwaną rośliną nie będą narażone na zniszczenie.

2) Opracowanie systemu precyzyjnego utrzymywania wysokości nad łanem roślin i/lub nad glebą.

Zaplanowano badania nad wytworzeniem układu sprzęgniętego w system autopilota platformy latającej, który pozwoli utrzymać precyzyjną wysokość podczas zabiegów niszczenia niezależnie od dobranej metody zwalczania. Standardowo każdy autopilot używa barometru do ustalania i utrzymywania stałej wysokości. Niestety barometr, który mierzy ciśnienie atmosferyczne i przelicza jego wartości na wysokość AGL, jest urządzeniem o bardzo małej precyzji. Każdy podmuch wiatru fałszuje wyniki takich urządzeń. Dlatego konieczne jest przeprowadzenie własnych badań i opracowanie autorskiego rozwiązania do pomiarów wysokości, wykorzystującego systemy laserowe oraz systemy RTK do zwiększenia precyzji ustalania pozycji.

Badania nad opracowaniem urządzenia do pomiarów wysokości będą prowadzone poprzez wybór metody pomiaru, jej zastosowanie i obserwowanie efektów. Następnie będą wprowadzane ewentualne korekty i powtórzenie procesu. Próby będą wykonywane, aż do uzyskania pożądanego efektu tj. odpowiedniej dokładności pomiaru (+-3m).

3) Automatyczna klasyfikacja odpowiedniej metody niszczenia na podstawie wyników I etapu;

Badania polegały na wyborze danej metody niszczenia, jej zastosowaniu i obserwacji efektów, wprowadzaniu korekt i powtórzeniu procesu.

4) Testowanie opracowanych metod w warunkach laboratoryjnych.

Podstawowe testowanie sprzętu, tj. głowic i system precyzyjnego utrzymywania wysokości w laboratorium odbyło się będzie na sztucznej roślinie aby ustalić największe zagrożenia i problemy które trzeba rozwiązać.

5) Loty treningowe w celu ustalenia procedur stosowania opracowanych metod niszczenia barszczy w terenie.

Załącznik stanowi dokument „Materiały do raportu końcowego etap II”

WYNIKI:

Poziom TRL osiągnięty po zakończeniu ww. Etapu: V

Osiągnięty kamień milowy: Opracowany algorytm umożliwi zwalczanie niepożądanych roślin z wykorzystaniem systemów bezzałogowych poprzez ich skasanie, mazakowanie, iniekcję oraz opryski. W toku badań uzyskano maksymalną skuteczność niszczenia barszczy metodą opryskową. Na polu testowym o powierzchni 1h pokrytej barszczami w ok 60% przeprowadzono nalotu z tryskaczami. Uzyskano powtarzalne wyniki zwalczania 93% oraz uszkodzenia roślin tła ok 7%.

C. Etap nr: 3, realizowany w ramach **prac rozwojowych** .

nazwa: Integracja opracowanych algorytmów, połączenie elementów składowych w jeden, złożony i zautomatyzowany system, umożliwiający jednoczesny proces inwentaryzacji i niszczenia barszczy kaukaskich za pomocą systemów bezzałogowych.

Prace rozwojowe miały na celu zintegrowanie zbadanych, opracowanych i wykonanych w dwóch pierwszych etapach prac badawczych rozwiązań, tak aby powstał końcowy złożony i zautomatyzowany system do jednoczesnego i skutecznego procesu inwentaryzacji i niszczenia barszczy kaukaskich za pomocą systemów bezzałogowych.

Ostatecznie opracowano na podstawie wyników etapu I i II ostatecznego kształtu algorytmu, który sam klasyfikuje daną roślinę i jej otoczenie, dobiera program niszczenia i rozpocznie proces zwalczania.

Wszystkie badania wykonane do momentu realizacji tego etapu pozwoliły na sfinalizowanie zakładanego w projekcie algorytmu łączącego i optymalizującego opracowane systemy, dającego jednoczesny zautomatyzowany proces inwentaryzacji i niszczenia barszczy kaukaskich.

Rezultat projektu stanowi gotową do wdrożenia usługę, dzięki której bez udziału człowieka możliwa jest dokładna i sprawna inwentaryzacja oraz skuteczne zwalczanie inwazyjnych i niebezpiecznych gatunków roślin.

Do przeprowadzenia testów wybrano dwie lokacje Miłków oraz Górki. Naloty polegały na wypuszczeniu w trybie automatycznym pierwszej platformy i pobranie materiałów do analizy. Kiedy algorytm zainstalowany na komputerze wyznaczył stanowiska do niszczenia, wypuszczany zostawał również w trybie automatycznym drugi drona do oprysków. Zazwyczaj badany obszar nie był cały pokryty barszczem więc druga maszyna wykonywała krótszy lot w konfiguracji dwie baterie i 10l płynu co starczało na bezpieczny 15 minutowy lot podczas którego opryskiwane zostało wyznaczone stanowiska.

Z uwagi na pandemię Covid-19 udało się wykonać tylko 32 loty z których:

- 1) 26 zakończyło się 100% wynikiem (wszystkie barszcze zinwentaryzowane pierwszą platformą zostały opryskane);
- 2) 3 loty w których opryskany został dany obszar tylko w część (76%, 88% i 82%) z uwagi na ilość barszczy i zbyt mały czas lotu platformy opryskowej;
- 3) 2 loty opryskowe się nie odbyły z uwagi na brak znalezionych barszczy;
- 4) 1 lot się nie odbył ze względu na pogodę – zaczęło padać;
- 5) Skuteczność oprysków badana została, poprzez ocenę naoczną, czy odpowiednie partie terenu są opryskane (ciecz miała czerwony barwnik spożywczy biodegradowalny).

WYNIKI:

Współpraca na poziomie etapu pierwszego i drugiego, czyli wyznaczanie za pomocą algorytmu z pierwszego etapu stanowisk barszczy i niszczenie ich opryskami (etap 2) wypadła dobrze. Wyznaczanie miejsc do oprysków na podstawie danych z algorytmu wyszło na poziomie ponad 94%.

Pozwoliliśmy automatycznie działać algorytmowi i za jego pomocą zostały wyznaczone stanowiska do oprysków. Podczas wizji lokalnej powierzchnie do oprysków pokrywały 98% miejsc faktycznych stanowisk barszczy, a w 4% pokrywały tereny całkowicie bez barszczy. Uzналиśmy więc skuteczność na 94%.

Następnie dron do niszczenia wykonał 32 loty opryskowe, które zostały ocenione naocznie:

Wnioski są następujące:

- a) 100% pokrycie opryskami nastąpiło w przypadku 81,25% stanowisk.
- b) 100% działanie (uwzględniając brak lotów z uwagi na brak barszczy do niszczenia) nastąpiło w przypadku 87,5% stanowisk.
- c) W 3,125% przypadków lot się nie odbył (w sensie pierwszy lot się odbył a drugi nie).

- d) W 9,375% przypadków wykonano i pierwszy i drugi lot, ale drugi lot nie pokrył całości stanowisk (średnio 82%) z powodu braku czasu lotu (koniec pojemności baterii).
- e) Jeśli dodać częściowe pokrycie stanowisk płynem, należy proporcjonalnie dodać do całkowitej skuteczności 87,5% jeszcze 82% z 9,375% skuteczności częściowej czyli 7,68%. Razem więc skuteczność pracy powiązanej pierwszego i drugiego etapu to 95,18%.
- f) System jako całość nadaje się do implementowania jako usługa biznesowa.
- g) Cele projektu w postaci opracowania efektywnych metod namierzania, rozpoznawania i zwalczania kaukaskich barszczy z użyciem BSP, bez konieczności kontaktu operatora z toksycznymi roślinami został zrealizowany

Załącznik stanowi dokument „Raport sprzętowy”

7. PODSUMOWANIE

W wyniku przeprowadzonych prac badawczo-rozwojowych opracowano innowacyjny proces inwentaryzacji i niszczenia barszczy kaukaskich, pozwalający na wykonywanie bardzo dokładnych zdjęć z wysokości ok. 50 m, z wykorzystaniem platform bezzałogowych z laserowym systemem pozycjonowania, służących do precyzyjnego wyznaczania współrzędnych stanowisk, oraz platformę do niszczenia, która zamiast czułego sprzętu optycznego będzie miała zamontowany zbiornik do oprysków. Za pomocą dronów można wykonać nalot o powierzchni 15 ha w 15 minut. Dziennie możliwe będzie wykonanie do pięciu takich nalotów, co daje zobrazowanie dla 75 ha powierzchni. Docelowo obróbka danych potrwa około 3-4 dni, tym samym w ciągu 5 dni zinwentaryzowany zostanie 75-hektarowy obszar. Drony będą mogły zastąpić niebezpieczne dla człowieka sposoby „ręcznego” inwentaryzowania barszczy.

Podczas badań pozyskano ponad p 1,2 mln zdjęć wysokościowych, które przeanalizowano pod kątem rozpoznawania barszczy na tle innych gatunków roślin. Opracowywane metody polegają na stosowaniu dużych wielowirnikowych BSP w połączeniu z kamerami o wysokiej rozdzielczości w paśmie widzialnym, podczerwieni, co pozwala na uzyskanie fotomapy, na której wyraźnie widać kształt liści.



Testowa inwentaryzacja kaukaskich barszczy – fotografia z wys. 100 m AGL, obiektyw 85 mm GSD 5,6 mm

W rozpoznaniu wspomagają automatyczne i półautomatyczne algorytmy obiektowe, które najpierw segmentują obraz, a dalej, na podstawie charakterystycznych kolorów i kształtów liści, kwiatostanów lub suchych pędów, rozpoznają barszcz. Uzyskana mapa rozmieszczenia osobników ma dużą dokładność. Na podstawie stanu osobników tworzone są mapy prognostyczne spodziewanego rozmieszczenia i mapy zagrożenia poparzeniem. W ten sposób w krótkim czasie może powstać kompleksowa i aktualna dla danego roku informacja o występowaniu kaukaskich barszczy oraz zagrożeniu z ich strony, która może być przydatna zarówno do przygotowania przetargów na usługi zwalczania, jak i do oceny efektywności prowadzonych działań.

Dzięki opracowanemu w ramach badań algorytmowi inwentaryzowania, możliwe jest wykonanie systemów, które zastosowane w dronie umożliwią:

- precyzyjne wyznaczenie pozycji rośliny z odległości ok 100 m. Nie można bowiem wyznaczać pozycji będąc bezpośrednio nad rośliną, bo zostanie przez niego rozsiana, miejsce musi być widoczne poprzez kamerę z pewnej odległości, bezpiecznej z uwagi na właściwości samej rośliny.

- wykonywanie wielu pomiarów jednocześnie na pokładzie drona oraz zapisanie ich wyników i przekazanie do centrum mobilnego w czasie rzeczywistym. Dron zostanie wyposażony w opracowany od podstaw system wyświetlania danych w obrazie kamery, te dostępne obecnie na rynku przekazują tylko parametry lotu nie pokazując np. precyzyjnej odległości od ziemi czy innych danych fizycznobiochemicznych.

Algorytm niszczenia natomiast zapewni takie innowacyjne rozwiązania do zastosowania w dronie jak:

- system pomiarów telemetrycznych – rozbudowany system niestosowany obecnie, który umożliwi umieszczenie w dronie środków żrących do niszczenia groźnych roślin;
- system elektroniczny z laserowymi czujnikami do utrzymywania stałej wysokości nad roślinami;
- szerokość strumienia regulowana automatycznie;
- aerodynamikę, której nie zakłóci zastosowanie dowolnego systemu oprysku;
- specjalnie opracowaną głowicę montowaną do drona, dzięki której możliwe będzie opryskiwanie roślin;

Rezultatem końcowym projektu jest innowacyjny algorytm, który w sposób zautomatyzowany sklasyfikuje daną roślinę i jej otoczenie, na tej podstawie dobierze program niszczenia i rozpocznie proces zwalczania.



Raport techniczny z działań Specjalistów ds. Kaukaskich Barszczy w celu stworzenia algorytmu rozpoznawania i zwalczania barszczy.

Podział algorytmu na działy

Specjaliści ds Kaukaskich Barszczy na potrzeby własnych działań wyznaczyli metodykę pracy nad powstaniem algorytmu rozpoznawania i zwalczania barszczy przeznaczonego do przyszłego wdrożenia w przedsiębiorstwie, integralnie powiązanego z kamieniami milowymi projektu. W tym celu zdefiniowali parametry algorytmu podzielone na poziomy: L0(działy), L1 (poddziały), L2(zadania), L3(podzadania), L4(aspekty) i L5(podaspekty).

W roku

Tabela 1 Działy algorytmu rozpoznawania i zwalczania kaukaskich barszczy

Parametr	L0		Opis	Milestone
\$ARG_ASSUMPT	1	Założenia	Założenia przyjmowane na początku opracowania algorytmu	1
\$HM_RECG	2	Rozpoznawanie	Działania polegające na rozpoznawania barszczy	1
\$SURVEY_REPORT	3	Raportowanie	Raportowanie rozpoznawania	1
\$REMOVAL	4	Usuwanie barszczy	Usuwanie zobrazowanych osobników	2
\$REMOVAL_REPORT	5	Raportowanie	Raportowanie usuwania	NA
\$REMOVAL_ACCEPT	6	Odbiory	Odbiory, weryfikacja, poprawki	NA

Dział Założenia (\$ARG_ASSUMPT)

W ramach konstruowania algorytmu przyjęto następujące założenia:

Tabela 2 Założenia przyjęte dla algorytmu

Parametr	L0	L1	Założenia
\$ARG_ASSUMPT	1		
\$ARG_ASSUMPT_DATA	1	1	algorytm ma umożliwić identyfikację barszczu w terenie na podstawie zdjęć i dodatkowych danych
\$ARG_ASSUMPT_ADAPT	1	2	algorytm ma mieć charakter adaptacyjny, czyli umożliwiać stopniowe zwiększanie jakości i poszerzanie zakresu warunków możliwości rozpoznawania
\$ARG_ASSUMPT EFFIC	1	3	algorytm ma być oszczędny w wykorzystaniu danych, mocy obliczeniowej, czasu
\$ARG_ASSUMPT EFFIC	1	4	algorytm ma być odporny na braki danych
\$ARG_ASSUMPT SMART	1	5	algorytm ma być hierarchiczny, czerpać wskazania do decyzji z danych na innych poziomach szczegółowości
\$ARG_ASSUMPT_OPEN	1	6	algorytm ma być open-source, parametryzacja – tajemnica przedsiębiorstwa

Dział 2. Rozpoznawanie (\$HM_RECG)

Tabela 3 Działania w obrębie działu 2 Rozpoznawania (\$HM_RECG)

Parametr	L0	L1	Działanie	Treść
\$HM_CONTR	2	1	Otrzymanie zlecenia	Proces pozyskania zlecenia
\$HM_CONTR_INIT_ASSESS	2	2	Wstępna ocena występowania barszczu	Służy wytypowaniu miejsc do wykonania oblotu
\$STRIP	2	3	Planowanie i realizacja lotów	Planowanie i realizacja lotów
\$STRIP_FL_IMG	2	4	Przechowanie i obróbka zdjęć	
\$STRIP_FL_IMG_TILE	2	5	Analiza danych dla płyty (TILE)	
\$PAR_SPACE	2	7	Określenie ilościowe jakości rozpoznania w przestrzeni czasowo-geograficznej i hiperprzestrzeni parametrów procesu	
\$PAR_SPACE_NEXT_SCEN	2	8	Wyznaczenie następnego scenariusza	

Działania z objęte pracami B+R w raportowanym okresie

Tabela 4 Działania w obrębie działu 2 Rozpoznawania (\$HM_RECG)

Parametr	L0	L1	Działanie	Docelowo	2018	KTO ?
\$HM_CONTR	2	1	Pozyskanie zlecenia	<ul style="list-style-type: none"> Pozyskiwanie powinno uwzględniać również ocenę możliwości realizacji zlecenia wynikające ze sprzężenia zwrotnego (\$PAR_SPACE_NEXT_SCENE) 	Brak działań	
\$HM_CONTR_INIT_ASSES	2	2	Wstępna ocena występowania barszczu	<ul style="list-style-type: none"> Zrozumienie lokalnego mechanizmu inwazji preselekcja miejsc nalotów 	<ul style="list-style-type: none"> Wybór miejsc wyłącznie dobrze rozpoznanych miejsc o wysokim maksymalnym stopniu zasiedlenia i dużej różnorodności warunków 	0
\$STRIP	2	3	Planowanie i realizacja lotów	<ul style="list-style-type: none"> Organizacja lotu ustawienia lotu ustawienia zobrazowań 	<ul style="list-style-type: none"> Ustawienia i konfiguracja UAV wybór i ustawienia aparatu wybór obiektywu wybór wysokości lotu wybór warunków lotu realizacja lotów 	0
\$STRIP_FL_IMG	2	4	Przechowanie i obróbka zdjęć	<ul style="list-style-type: none"> 	<ul style="list-style-type: none"> Ustalenie nomenklatury przechowanie 	0
\$STRIP_FL_IMG_TILE	2	5	Analiza danych dla płyty (TILE)	<ul style="list-style-type: none"> 	<ul style="list-style-type: none"> Wykonanie analiz <ul style="list-style-type: none"> ocena przydatności rozwiązań przeprowadzenie testowych rozpoznań ocena jakości rozpoznawania 	PP PM

Parametr	L 0	L 1	Działanie	Docelowo	2018	KTO ?
\$PAR_SPACE	2	7	Określenie ilościowe jakości rozpoznania w przestrzeni czasowo-geograficznej i hiperprzestrzeni i parametrów procesu	•	•	PP i PM
\$PAR_SPACE_NEXT_SCEN	2	8	Wyznaczenie następnego scenariusza			PP i PM

Poddział 2.5 Tworzenie algorytmu

Obejmie trzy zadania: stworzenie wstępnego modelu demonstracyjnego (2.5.1 Proof of concept, \$STRIP_ALGO_PROOF), rozszerzenie zakresu (2.5.2 Scope extension Powtarzanie zadania 2.5.1. z zapisem metadanych, \$STRIP_ALGOS_SCOPEEXT) i na końcu

Tabela 5

Poddział	2.5	Budowa algorytmu rozpoznawania	\$STRIP_ALGO
Zadanie	2.5.1	Proof of concept	\$STRIP_ALGO_PROOF
Podzadanie	2.5.1.1	Presekcja algorytmów rozpoznawania	\$STRIP_ALGOS_PROOF_PRESEL
Podzadanie	2.5.1.2	Wyznaczanie obiektów klasyfikacji	\$STRIP_FL_IMG_TILE_BGR
Podzadanie	2.5.1.3	Rozpoznawanie barszczu	\$STRIP_FL_IMG_TILE_HM_RECOG
Podzadanie	2.5.1.4	Kontrola jakości rozpoznania	\$STRIP_FL_IMG_TILE_HM_RECG_SES_QC
Podzadanie	2.5.1.5	Wstępne wyznaczenie z zakresów stosowania wyznaczony próg jakości rozpoznania	\$STRIP_FL_IMG_TILE_HM_RECG_SES_QC_VAL_THRESH
Zadanie	2.5.2	Scope extension Powtarzanie zadania 2.5.1. z zapisem metadanych	\$STRIP_ALGOS_SCOPEEXT
Podzadanie	2.5.2.1	Wyznaczenie zakresu testów	\$PAR_SPACE
Podzadanie	2.5.3.3	Automatyzacja rozpoznania poprzez skryptowanie	NA
Podzadanie	2.5.3.4	Dołączanie nowych algorytmów (AOS)	NA
Podzadanie	2.5.3.5	Budowa metamodelu dla jakości rozpoznania	NA

Podzadanie 2.5.1.1 Presekcja algorytmów rozpoznawania (\$RECG_PRESEL)

W ramach zadania dokonano przeglądu literatury pod kątem algorytmów służących do klasyfikacji obrazów. W analizie uwzględnione kilka klas algorytmów (Tabela 7)

Tabela 6 Publikacje dotyczące rozpoznawania barszczu na zobrazeniach teledetekcyjnych. .

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opis	Miara jakości – wartość
Heracleum mantegazzianum	Czechy	Timing Is Important Unmanned Aircraft vs. Satellite Imagery in Plant Invasion Monitoring	Müllerová, J., Brůna, J., Bartaloš, T., Dvořák, P., Vítková, M., & Pyšek, P.	2017	Frontiers in plant science	https://www.frontiersin.org/articles/10.3389/fpls.2017.00887/full	10.3389/fpls.2017.00887	UV-cameras: - RGB: Sony Alpha A5100 with APS-C - NIR : Sony E 202.8 lens, Hoya R72 filter, piksel 5cm	Agisoft PhotoScan Professional	1. maximum likelihood (ML) 2. Support Vector Machine (SVM) 3. Random Forests (RF) 4. OBI A (różne warianty)	1-3. ArcGIS 10.4.1, 4. eCognition	user's accuracy (UA), producer's accuracy (PA), overall accuracy (OA)	w pełni kwitnienia: OA dla OBI A 83 site 1, 100 site 2

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software georeferencing	Metody klasyfikacji	Software do klasyfikacji	Miarą jakości opisu	Miara jakości – wartość
Heracleum mantegazzianum								satelita Pleiades 1B, 4 kanały, piksel 50 cm					OADLA ML 91
Heracleum mantegazzianum								color orthophoto, piksel 25 cm					OADLA OBI A 71-79
Fallopia sp.								UAV					OA 66-79 (RF, ML, SVM)

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referencj	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opisu	Miara jakości – wartość
Fallopia sp.								Pleiades 1B					OA 66-85 (RF, ML, SVM)

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opisu	Miara jakości – wartość
Robinia pseudocacia	Czechy	Unmanned aircraft in nature conservation: an example from plant invasions	Müllerová, J., Bartaloš, T., Brůna, J., Dvořák, P., & Vítková, M.	2017	International Journal of Remote Sensing	https://www.researchgate.net/publication/312293624	10.1080/01431161.2016.1275059	UA V, 2 platformy: -2x Canon S100 (VIS+NIR) -2x Sony A5100 + E20/2.8 (VIS+NIR) z APS-C	Agisoft PhotoScan	Pixel-based Supervised Maximum-Likelihood and Support Vector Machines (SVM)		user's accuracy (UA), producer's accuracy (PA), condition 1 Kappa index	92/81% and 75/92% PA/UA for site 1 and 2, respectively

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software georeferencing	Metody klasyfikacji	Softwa re do klasyfikacji	Miara jakości opis	Miara jakości – wartość
Robinia pseudocacia								satellite imagery WV-2, 8 kanałów piksel 2m					61/81% PA/UA

<p>Heracleum mantegazzianum, Robinia pseudacacia, Ailanthus altissima, Fallopia japonica, F. sachalinensis, F. × bohemica</p>	<p>Czechy</p>	<p>Does the data resolution-origin matter? Satellite, airborne and UAV imagery to tackle plant invasions</p>	<p>Müllerová, J., Brůna, J., Dvořák, P., Bartaloš, T., & Vítková, M.</p>	<p>2016</p>	<p>The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences</p> <p>https://www.researchgate.net/profile/Jana_Muellerova/publication/307530102_DOES_THE_DATA_RESOLUTION_ORIGIN_MATTER_SATELLITE_AIRBORNE_AND_UAV_IMAGERY_TO_TACKLE_PLANT_INVASIONS/links/57cd285b08ae59825185e210.pdf</p>		<p>- UAV RGB+NIR3 platform 2x Canon S100 stabilized 2x Sony A5100 + E20/2.8 1x Canon S100+ 1x GoPro - panoramic historic al</p>	<p>Agisoft PhotoScan</p>				<p>wstępne wyniki bez dokładności</p>
---	---------------	--	--	-------------	---	--	---	--------------------------	--	--	--	---------------------------------------

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referencj	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opisu	Miara jakości – wartość
								ades (0.5/2.8 m PA N/M SS resolution), - RapidEye (6.5 m), - Sentinel-2 (10 m),					

Stratigies	Kanada, Ontario	Object-based analysis of UAS imagery to map emergent and submerged invasive aquatic vegetation: a case study	Chabot, D., Dillon, C., Ahmed, O., & Shmrock, A.	2016	Journal of Unmanned Vehicle Systems	<p>https://tspace.library.utoronto.ca/bitstream/1807/75763/1/juvs-2016-0009.pdf</p>	10.1139/juvs-2016-0009	UAV RGB - Sony Cyber-shot DS-C72 WX220, piksel 3.9 cm NIR - Canon PowerShot S110 modified to capture NIR, piksel 5.4 cm	Postflight Terra 3D v4.0 (senseFly)			producer's and user's accuracy 81% and 74%, respectively, an overall accuracy of 78%, and a kappa value of 61%.
------------	-----------------	--	--	------	-------------------------------------	--	------------------------	---	-------------------------------------	--	--	---

Gatunek	Region	Tytuł	Autrzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miarę jakości opis	Miarę jakości – wartość
Acacia longifolia	Portugalia	Mapping the flowering of an invasive plant using Unmanned Aerial Vehicles: is there potential for bioco ntrol monitoring ?	César De Sá, N., Castro, P., Carvalho, S., López-Núñez, F. A., Marchante, E., & Marchante, H.	2018	Frontiers in Plant Science	https://www.frontiersin.org/articles/10.3389/fpls.2018.00293/full	10.3389/fpls.2018.00293	RGB and CIR Canon IXUS/E LPH cameras (2 kamery= 2 loty)	Agisoft Photo Scan	RF	R	OA ; Cohen's Kappa	Overall Accuracy > 0.96 ; Cohen's Kappa > 0.85

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miarę jakości opis	Miara jakości – wartość
Fallopia japońska	Słowenia, Ljubljana	Mapping invasive Fallopia japonica by combined spectral, spatial, and temporal analysis of digital orthophotos	Dorigo, W., Lucier, A., Podobnikar, T., & Čarni, A.	2012	International Journal of Applied Earth Observation and Geoinformation	https://pdfs.semanticscholar.org/6ad6/4a90bb4a89c12dda302bc239dd926f6a7f7d.pdf?_ga=2.266210122.438448783.1520974952-2045968567.1520974952	10.1016/j.jag.2012.05.004	digital orthophotos, RGB-pixel 50 cm, NIR – pixel 1 m, dwa naloży: wiosna i lato		RF z użyciem NDVI, BTBR-bitemporal band ratio, Texture measures - GLCM		PA, UA, OA, Kappa	OA, najlepszy wariant 95

Gatunek	Region	Tytuł	Autorki	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miarę jakości opis	Miara jakości – wartość
Silybum marianum Ostropest plamisty	Thessaloniki	Evaluation of UAV imagery for mapping Silybum marianum weed patches	Tamouri dou, A. A., Alexandridis, T. K., Pantazi, X. E., Lagopodi, A. L., Kashefi, J., & Moshou, D.	2017	International Journal of Remote Sensing	https://www.researchgate.net/profile/Thomas_Alexandridis/publication/309751030_Evaluation_of_UAV_imagery_for_mapping_Silybum_marianum_weed_patches/links/59e5f83caca272390ee01d2a/Evaluation-of-UAV-imagery-for-mapping-Silybum-marianum-weed-patches.pdf	10.1080/01431161.2016.1252475	Canon S110 NIR camera (12 Mpixels), multispectral camera (green-red-near-infrared), pixel 10 cm	Pix4Dmapper Pro	ML	ERDAS Imagine	PA, UA, OA, Khat statistic	OA najlepszy wariant (UAV bands, Texture layer, Majority filter) 85

Gatunek	Region	Tytuł	Autorki	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miarę jakości opis	Miara jakości – wartość
Iris pseudacorus	British Columbia	Utility of unmanned aerial vehicles for mapping invasive plant species: a case study on yellow flag iris (Iris pseudacorus L.)	Hill, D. J., Tarasoff, C., Whittworth, G. E., Baron, J., Bradshaw, J. L., & Church, J. S.	2017	International Journal of Remote Sensing	https://www.tandfonline.com/doi/full/10.1080/01431161.2016.1264030?src=recsys	10.1080/01431161.2016.1264030	12.4 MP digital camera RGB		- manual interpretation of the raw UAV-RF pixel-based classification			manual interpretation – false-positive and false-negative classification rate of less than 1%

Gatunek	Region	Tytuł	Autrzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software referenc	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opis	Miara jakości – wartość
Elymus caput-medusae, Aegilops triuncialis [invasive weed grasses]	Sacramento Valley, CA, USA	Novel fine-scale aerial mapping approach quantifies grass and weed cover dynamics and response to management	Malmstrom, C. M., Butterfield, H. S., Plank, L., Long, C. W., & Eviner, V. T.	2017	PloS one	http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0181665	10.5061/dryad.cv791	color infrared (CIR) aerial photography, pixel 45 cm	Leica Photogrammetry Suite in ERDAS Imagine 9.3	ML, isodata obraz NDVI z pełni i i końca sezonu, maska z non-vegetation	ENVI 4.7	PA, UA, OA, Kappa + coefficient of variation dla nich	Kappa > 0.7 dla stacked NDVI, UA 100 dla różnicy NDVI

Gatunek	Region	Tytuł	Autorzy	Rok	Czasopismo	Link	DOI	Typ sensora	Software georeferencing	Metody klasyfikacji	Software do klasyfikacji	Miara jakości opisu	Miara jakości – wartość
Phragmites australis	USA, Gulf Coast, Pearl River delta in southeastern Louisiana	Using unmanned aerial vehicles for high-resolution remote sensing to map invasive Phragmites australis in coastal wetlands	Samian, S., Turnage, G., Hatcock, L., Casagrande, L., Stinson, P., & Morhead, R.	2017	International Journal of Remote Sensing	https://www.tandfonline.com/doi/full/10.1080/01431161.2016.1239288?src=recsys	10.1080/01431161.2016.1239288	RGB		Gamma filters, grey level co-occurrence matrices, segmentation-based fractal texture analysis, and wavelet-based texture analysis			OA >85, kappa > 0.70

WNIOSKI

Za najbardziej obiecująca należy uznać pracę o *Heracleum mantegazzianum* w Belgii: Michez, A., Piégay, H., Jonathan, L., Claessens, H., & Lejeune, P. Mapping of riparian invasive species with supervised classification of unmanned aerial system (UAS) imagery, 2016, International Journal of Applied Earth Observation and Geoinformation, <https://www.sciencedirect.com/science/article/pii/S0303243415300040> 10.1016/j.jag.2015.06.014

Użyto w niej zobrażeń analogicznych, jak przewidziane w projekcie: VIS + NIR, z pikselem 5-10 cm, pozyskanych z użyciem UAS. W analizie użyto analizy obiektowej (OBIA, segmentacja; RF). Do rozpoznawania użyto programu eCognition. Uzyskano wysokie maksymalne skuteczności rozpoznania (97%). Powtórzenie tej metody z użyciem własnych zobrażeń daje szansę na osiągnięcie Milestone 1. #

W ramach zadania dokonano przeglądu literatury pod kątem algorytmów służących do klasyfikacji zobrażeń. W analizie uwzględnione kilka klas algorytmów (Tabela 7).

Tabela 7 Klasy algorytmów rozważane w ramach preselekcji

Klasa algorytmów	Możliwości	Skala	Implementacja	Jakość rozpoznania roślinności	Przydatność do projektu D4N	WNIOSKI
Analiza multispektralna	Odnajdywanie i lokalizacja klas obiektów na zobrażowaniach Powtarzalne i ilościowe określanie natężenia zjawisk na zidentyfikowanym obszarze	Multispektralne zobrażenia satelitarne, lotnicze i UAV	Programy GIS#	Umiarkowana, ograniczona do dużych obiektów, w najlepszych momentach kontrastu z otoczeniem Q_≥75%	Ograniczona, faza wstępnej identyfikacji. Możliwości techniczne w projekcie.	DO UWZGLĘDNIENIA W 2019

Klasa algorytmów	Możliwości	Skala	Implementacja	Jakość rozpoznania roślinności	Przydatność do projektu D4N	WNIOSKI
Analiza hiperspektralna	Odnajdywanie i lokalizacja klas obiektów na zobrazowaniach	Hiperspektralne zobrazowania satelitarne, lotnicze i UAV	Specjalistyczne	Średnio wysoka, ograniczona do dobrze wyróżnialnych obiektów, w optymalnych momentach kontrastu z otoczeniem Q_z≥75%	Możliwość uzupełniającego wykorzystania dla pozyskiwanych komercyjnie danych satelitarnych, brak dostępnych danych lotniczych. Brak możliwości technicznych pozyskiwania z UAV	DO UWZGLĘDNIENIA 2020
Klasyfikacja nienadzorowana i nadzorowana	Automatyczna identyfikacja klas zjawisk na zobrazowaniach	Obrazy satelitarne, lotnicze i własne UAV,	E-cognition, ArcGIS, R, SAGA, GRASS< TerraLib, OrfeoToolbox,	Średnio wysoka, ograniczona do dobrze wyróżnialnych obiektów, w optymalnych momentach kontrastu z otoczeniem Q_z≥75%	Główna metoda pierwszego wyboru	2018. Do przetestowania w celu osiągnięcia stadium proof of concept
Rozpoznawanie i lokalizacja wzorców	Automatyczne rozpoznawanie występowania obiektów na zobrazowaniach	Zdjęcia naziemne w dowolnym rzucie, wykorzystywana do analizy obrazów poziomych	R YOLO,	Różna w zależności od założeń	Bardzo wysoka, metoda drugiego wyboru, w szczególności przydatna do lokalizacji i przyszłego naprowadzania zautomatyzowanych dronów zwalczających	2018, 2019

WNIOSKI

- W ramach zadania **ProofOfConcept** (\$RECG_PROOF) w pierwszej kolejności należy przetestować metody oparte na klasyfikacji obiektowej;
 - wyznaczyć obiekty do klasyfikacji począwszy od danych o wysokiej spodziewanej możliwości rozpoznania;
 - na wybranych zobrazeniach własnych sprawdzić skuteczność algorytmów referencyjnych AR (rozpowszechnionych w biznesie implementacji komercyjnych) – tj. E-cognition;
 - zweryfikować uzyskaną jakość rozpoznania
 - rozpoznać możliwości implementacji algorytmów open-source (AOS) (R+SAGA+GRASS+QGIS)
 - porównać jakość rozpoznania i AOS v AR
 - Wyznaczyć zakresy stosowania obu grup metod
- w zadaniu **ScopeExtension** (\$RECG_SCOPEEXT)
 - stopniowo zwiększać zakres warunków zobrażeń, przechodząc od wybranych do coraz bardziej realistycznych;
 - stopniowo włączać dodatkowe algorytmy, zwłaszcza AOS
 - dążyć do automatyzacji procesu rozpoznawania w środowisku R poprzez
 - skryptowanie,
 - definiowanie funkcji dla powtarzalnych scenariuszy,
 - definiowanie roboczych pakietów dla przetestowanych funkcji,
 - gromadzić metadane, umożliwiające tworzenie metamodeli i szeroką optymalizację procesu rozpoznawania.
- w zadaniu **ProductionReady** (\$RECG_PRODREADY)
 - zweryfikować, udokumentować i opublikować funkcje dla algorytmów rozpoznawania
 - pakiet R
 - publikacja metodyczna
 - stworzyć narzędzia wspomagania decyzji dla wykorzystania metadanych i obiektów w rozpoznawaniu w warunkach docelowych.
 - W szczególności zbiór i wykorzystanie metadanych, metamodeli i optymalnie wytrenowanych modeli o dużej transferability dla konkretnych działań związanych ze zwalczaniem.
 - W toku eksploatacji powtarzać podzadania 2.5.1.1 do 2.5.1.4 w ramach stałych przeglądów technologicznych.

Podzadanie 2.5.1.2 Wyznaczanie obiektów klasyfikacji (\$RECG_BGR)

Do sesji rozpoznania zakwalifikowano zobrazowania własne uzyskane w czasie lotów wykonanych w roku 2018 r.

Tabela 8 Zobrazowania uzyskane w roku 2018 i ich właściwości.

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiekty w	FLIHGT_PARM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkty WGS 84	E-cognition
RRRR-MM_DD	Miejscowość, nazwa kodowa	tekst	tekst	[0,1]	[0-1]	tekst		50			[0,1]	[0-10]			
2018-04-20	Błędów	Lot #1 50m AGL	zdjęcia puste	0	0	0	NA	50	NA	unstable	0		BRAK		
2018-04-20	Błędów	Lot #2 50m AGL	tylko jpg	0	0	0	NA	50	NA	unstable	0		BRAK		
2018-04-20	Błędów	Lot #3 100m AGL	brak zdjęć	0	0	0	NA	50	NA	unstable	0		BRAK		
2018-04-20	Błędów	Lot #4 125m AGL	brak zdjęć	0	0	0	NA	50	NA	unstable	0		BRAK		
2018-04-20	Błędów	Lot #5 150m AGL	brak zdjęć	0	0	0	NA	50	NA	unstable	0		BRAK		
2018-08-07	Skalnicowa	SONY A7R3 85	tylko jpg bez logów, rozmazane	0	0	0	NA	0	NA	unstable	0	0	BRAK		
2018-08-17	Chylice		tylko zdjęcia z ziemi	0	0	0	NA	0	NA	unstable	0		BRAK		
2018-08-18	Chylice	RE-M #0	tylko zdjęcia z ziemi	0	0	0	NA	0	BRAK	unstable	0		BRAK		

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiektyw	FLIHGT_PAR AM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkt y WGS 84	E-cognition
2018-08-18	Chylice	RE-M #1	RE, NDVI, mozaiki dla kanałów	0	0	PROŚBA	NA	BD	BRAK	unstable	0		BRAK		
2018-08-18	Chylice	RE-M #2	RE, NDVI, mozaiki dla kanałów	0	0	PROŚBA	NA	BD	BRAK	unstable	0		BRAK		
2018-08-18	Chylice	RE-M #3	RE, NDVI, mozaiki dla kanałów	0	0	PROŚBA	NA	BD	BRAK	unstable	0		BRAK		
2018-09-17	Gorki	Lot_3_100m_AGL_85mm_10ms	jpg, RE, NDVI, mozaiki dla kanałów, brak orto	1	NA	PROŚBA	10	100	85	unstable	0		BRAK		
2018-09-17	Gorki	Lot_4_100m_AGL_85mm_9ms	jpg, RE, brak mozaik	1	NA	PROŚBA	9	100	85	unstable	0		BRAK		
2018-09-17	Górki	RE-M_1_100m_AGL_10m_s	jpg, RE, brak mozaik	1	NA	PROŚBA	10	100	BRAK	unstable	0		BRAK		
2018-09-17	Górki	RE-M_1_100m_AGL_9m_s	jpg, RE, brak mozaik	1	NA	PROŚBA	9	100	BRAK	unstable	0		BRAK		
2018-09-18	Iskra	Lot_1_100m_AGL_5m_s_85mm	brak zdjęć		NA	0	5	100	85	unstable	0		BRAK		

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiektyw	FLIHGT_PAR AM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkt y WGS 84	E-cognition
2018-09-18	Iskra	Lot_2_100m AGL 10m_s_85mm	jpg geotagged, RE, brak mozaik	?	NA	0	10	100	85	unstable	0		BRAK		
2018-09-18	Iskra	Lot_3_100m AGL 10m_s_55mm	tylko jpg	?	NA	0	10	100	55	unstable	0		BRAK		
2018-09-18	Iskra	Lot_4_75m AGL 7m_s_85mm	jpg, RE, brak mozaik	?	NA	0	7	75	85	unstable	0		BRAK		
2018-09-19	Iskra	Lot_2_100m AGL 10m_s_85mm	jpg, RE, brak mozaik	?	NA	0	10	100	85	unstable	0		BRAK		
2018-09-19	Iskra	Lot_3_100m AGL 10m_s_55mm	tylko jpg	?	NA	0	10	100	55	unstable	0		BRAK		
2018-09-19	Iskra	Lot_4_75m AGL 7m_s_85mm	tylko jpg	?	NA	0	7	75	85	unstable	0		BRAK		
2018-09-20	Górki 2	Lot 1 85mm 85m AGL 9m_s	jpg, RE, NDVI, mozaiki dla kanałów, DSM, brak orto	1	NA	PROŚBA	9	85	85	unstable	0		BRAK		
2018-09-20	Górki 2	Lot 2 85mm 70m AGL 8m_s	jpg, RE, NDVI, mozaiki dla kanałów, brak orto	1	NA	PROŚBA	8	70	85	unstable	0		BRAK		
2018-09-20	Górki 2	Lot_1 85m AGL 9m-s 85mm	jpg, RE, brak mozaik	1	NA	PROŚBA	9	85	85	unstable	0		BRAK		

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiektyw	FLIHGT_PAR AM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkt y WGS 84	E-cognition
2018-10-13	Chudoby	1 lot	jpg, RE, brak mozaik	?	NA	0	NA	NA	NA	unstable	0		BRAK		
2018-10-13	Chudoby Test	1 lot	tylko jpg		NA	0	NA	NA	NA	unstable	0		BRAK		
2018-10-15	Górki 3	Lot 1 85 m AGL 10m_s 85mm Bez BreakUp Starts	jpg, orto	1	NA	PROŚBA	10	85	85	unstable	0		BRAK		
2018-10-15	Górki 3	Lot 2 85 m AGL 10m_s 85mm Bez BreakUp Starts Poprawiony aparat	orto jpg, mozaika NDVI jako barwa jpg	1	NA	PROŚBA	10	85	85	unstable	0		BRAK		
2018-10-16	Stare Polichno Wał	LOT-1 100 m AGL 55m 10m_s RTL	jpg, RE, brak mozaik	0	0	0	10	100	55	unstable	0		BRAK		
2018-10-16	Stare Polichno Wał	LOT-2 100 m AGL 55m 10m_s	jpg, RE, mozaika NDVI jako barwa jpg, orto geotif	0	0	1	10	100	55	unstable	0		NA	0	0
2018-10-16	Stare Polichno Wał	LOT-3 85 m AGL 55m 10m_s BAD GIMBAL	złe zdjęcia	0	0	0	10	85	55	unstable	0	bad gimbal	BRAK		
2018-10-16	Stare Polichno Wał	LOT-4 85 m AGL 55m 10m_s	jpg, RE, mozaika NDVI jako barwa jpg, orto geotif failed	0	0	PROŚBA	10	85	55	unstable	0		BRAK		

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiektyw	FLIHGT_PARM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkt y WGS 84	E-cognition
2018-10-17	Stare Polichno	Lot 1 100 m AGL 10m_s 55mm Pastwisko	jpg prześwietlone	?	NA	0	10	100	55	unstable	0		BRAK		
2018-10-17	Stare Polichno	Lot 2 100 m AGL 10m_s 55mm Pastwisko	jpg, RE, mozaika NDVI jpg, orto jpg	?	NA	PROŚBA	10	100	55	unstable	0		BRAK		
2018-10-18	Czechów	Lot 1 100m AGL 55mm 10m-s	jpg, RE, orto jpg	1	NA	PROŚBA	10	100	55	stable	0		BRAK		
2018-10-18	Czechów	Lot 2 100m AGL 55mm 10m-s	jpg, RE, orto jpg	1	NA	PROŚBA	10	100	55	stable	0		BRAK		
2018-10-18	Czechów	Lot 3 100m AGL 55mm 10m-s	jpg, RE	1	NA	PROŚBA	10	100	55	stable	0		BRAK		
2018-10-18	Czechów	Lot 4 100m AGL 55mm 10m_s	jpg, RE	1	NA	PROŚBA	10	100	55	stable	0		BRAK		
2018-10-18	Górki		brak zdjęć		NA	0	10	100	NA	stable	0		BRAK		
2018-10-19	Czechów	Lot 1 100m AGL 55mm 10m_s	jpg, orto jpg i geotif	1	NA	1	10	100	55	stable	1	orto geotif chyba źle wygenerowane stąd przesunięcia, widoczne fale na miniaturce	NA		
2018-10-19	Czechów	Lot 2 20m AGL 55mm	tylko kilka zdjęć, nie brać do analizy		NA	0	10	20	55	stable	0		BRAK		

Data	Miejsce	Lot	Uwagi	barszcz	Ilość barszczu	orto geotif	V	AGL	Obiektyw	FLIHGT_PAR AM	punkty weryfikacyjne	JPG_Quality	ORTO_Quality	Punkt y WGS 84	E-cognition
2018-10-19	Czechów	Lot 3 100m AGL 55mm 10m_s	jpg, orto jpg i geotif	1	NA	1	10	100	55	stable	0		NA		
2018-11-07	Górki	Lot-1	RE, orto jpg	1	NA	PROŚBA	10	NA	NA	stable	0		BRAK		
2018-11-07	Górki	TEST-1	RE		NA	0	10	NA	NA	stable	0		BRAK		
2018-11-07	Górki	TEST-2	jpg, RE		NA	0	10	NA	NA	stable	0		BRAK		
2018-11-08	Górki	LOT-1	brak zdjęć		NA	0	10	NA	NA	stable	0		BRAK		
2018-11-08	Górki	LOT-2	brak zdjęć		NA	0	10	NA	NA	stable	0		BRAK		
2018-11-08	Górki	LOT-3	brak zdjęć		NA	0	10	NA	NA	stable	0		BRAK		
2018-11-08	Górki	LOT-4	brak zdjęć		NA	0	10	NA	NA	stable	0		BRAK		

Zgodnie z założeniami zadania 2.5.1. do analizy wytypowano podzbiór obrazowań, dający możliwość przetestowania możliwości rozpoznawania barszczu. Podzbiór uwzględnił jedynie fragment zmienności parametrów mogących mieć wpływ na skuteczność rozpoznania (Tabela 9).

Tabela 9 Właściwości zdjęć wybranych do rozpoznawania barszczu

Aspekt	2.5.1.2.1	Wybór zdjęć do wstępnego rozpoznawania (tło) pokrycie terenu,	\$RECG_BGR	Możliwe stany	Testowane wartości
Podaspekt	2.5.1.2.1.1	pokrycie terenu,	\$RECG_BGR_LC	Dane na podstawie BDOT_10k,	łąki i pastwiska, drogi, torowiska kolejowe, pola orne
Podaspekt	2.5.1.2.1.2	Roślinność rzeczywista	\$RECG_BGR_VEG	Wg klasyfikacji fitosocjologicznej http://atlas-roslin.pl	NIE ANALIZOWANE
Podaspekt	2.5.1.2.1.3	typ fizjonomiczny	\$RECG_BGR_PHYS	Opis charakteru wizualnego zbiorowisk	Odłogi, łąki świeże i murawy przyuliczne zbiorowiska ruderalne na torowiskach kolejowych
Podaspekt	2.5.1.2.1.4	liczba gatunków,	\$RECG_BGR_SPNR	Dane na podstawie lokalnego rozpoznania	1-10 gatunków tła
Podaspekt	2.5.1.2.1.5	wysokość,	\$RECG_BGR_H	Niskie zielne (0- 0,1m) Umiarkowanie niskie zielne (0,1-0,5m) Umiarkowanie wysokie zielne (0,5-1,0m) Wysokie zielne (1.0-1,5m) Krzewy (1,5-3m) Krzewy wysokie (3-6m) Niskie zadrzewienia (5-10m), Średnie zadrzewienia (10-15m) Wysokie zadrzewienia (15-30m) Barzdo wysokie zadrzewienia (30-50m)	Niskie zielne (0- 0,1m) Umiarkowanie niskie zielne (0,1-0,5m) Umiarkowanie wysokie zielne (0,5-1,0m) Wysokie zielne (1.0-1,5m) Krzewy (1,5-3m) Krzewy wysokie (3-6m) Niskie zadrzewienia (5-10m), Średnie zadrzewienia (10-15m) Wysokie zadrzewienia (15-30m)

Aspekt	2.5.1.2.1	Wybór zdjęć do wstępnego rozpoznawania (tło) pokrycie terenu,	\$RECG_BGR	Możliwe stany	Testowane wartości
					Barzdo wysokie zadrzewienia (30-50m)
Podaspekt	2.5.1.2.1.6	warstwowość	\$RECG_BGR_LAYERS	D CD C BCD BD BC B AB ABC ABCD AD AC	C, BC, ABC
Podaspekt	2.5.1.2.1.7	zaburzenia	\$RECG_BGR_DISTURB		

Problemy z wykorzystaniem zdjęć i wniosku

W trakcie pracy ze zobrazowaniami zdefiniowano następujące problemy techniczne zobrazowań, wymagające weryfikacji i korekty w czasie kolejnych lotów, mające wpływ na możliwości rozpoznania.

1. Orto generowane w formacie JPG nie mają georeferencji. Do pracy w GIS nadają się tylko w formacie GeoTIF.
2. Opracowano metodykę automatycznej rejestracji pojedynczych zdjęć. Potrzebne informacje: liczba pikseli na szerokość i wysokość, terenowy rozmiar piksela, współrzędne geograficzne środka zdjęcia, azymut (kąt yaw). Zdjęcia lokalizowane w ten sposób są przesunięte w stosunku do orto, gdzie dodatkowo uwzględniane są kąty pitch, roll i efekty 3D. Również same środki zdjęć są przesunięte.
3. Pojedyncze zdjęcia i mozaiki orto są przesunięte w stosunku do zobrazowań dostępnych na geoportalu i Google Maps.
4. W trakcie nalotu wskazane wykorzystanie fotopunktów, białego prześcieradła (do kalibracji barw). Być może wskazane będzie użycie GPSu geodezyjnego do wyznaczenia współrzędnych fotopunktów. Temat do dyskusji na najbliższym spotkaniu.
np. może tak to wyglądać
5. Kolejne wykonywane zdjęcia różnią się znacznie jasnością
6. Problemem są także rozmycia np.



Ilustracja 1



DSC03991.JPG



DSC03992.JPG



DSC03995.JPG



Ilustracja 3 Rozmyty fragment torowiska



Ilustracja 4 Rozmycia występujące na ortofotomapie w miejscach dużych nachyleń i skomplikowanej strukturze roślinności.

7. Bardziej operacyjne wydaje się klasyfikowanie mozaik ortofoto, mimo rozmycia obrazu (rozmycia dotyczą tylko obiektów o skomplikowanych kształtach np. drzew).

8. Mozaiki NDVI też powinny być opracowane jako geotif, Posłużą one do wymaskowania terenów nieroślinnych (przyjmą wartość NDVI powyżej której uznajemy, że jest to żywa roślinność). Ważne: obiekty na mozaikach NDVI powinny mieć tę samą lokalizację co na mozaikach orto (synchronizacja przestrzenna). Zbyt mała rozdzielczość aby użyć do rozpoznawania barszczu (6x mniejsza niż obrazy RGB w zakresie widzialnym lustrzanką).

9. Testowy nalot kamerą RE na niższych wysokościach (piksel 5-10cm), aby rozróżnić na nich liście

barszczu.

10. Październik – liście od żółtych do zielonych, niejednolita barwa utrudnia klasyfikację.
11. Downsampling rozmiaru piksela – 2 cm jest to minimum, przy większym pikselu, przestają być widoczne wcięcia liścia i słabo są widoczne łodygi. Przy większym pikselu trudno byłoby zidentyfikować barszcz w wyniku wzrokowej manualnej interpretacji. Być może w pełni wegetacji, gdy płyty barszczu są duże piksel mógłby być większy np. 10 cm.
12. Aby ułatwić wyświetlanie dużych rastrów generujemy overview w zewnętrznym pliku .ovr. Można to zrobić poleceniem gdaladdo z OSGeo4W Shell instalowanym z QGIS np.
`gdaladdo -ro --config COMPRESS_OVERVIEW JPEG --config INTERLEAVE_OVERVIEW PIXEL orto.tif`
Overview funkcjonuje w QGIS, nie działa w zwykłych przeglądarkach plików graficznych.

Wstępnie do użycia wytypowano 5 fragmentów zdjęć z lotów:

- 2018-09-20 Lot_1 85m AGL 9m-s 85mm,
- 2018-10-15_Górki3_Lot 1_Bez_BreakUp,

- 2018-10-19_Czechów_Lot 1 100m AGL 55mm 10m_s,
- 2018-10-19_Czechów_Lot 3 100m AGL 55mm 10m_s.

Ostatecznie do rozpoznawania użyto 3 ortofotomapy z nalotów wykonanych w dniach 2018-10-15, 2018-10-19.



Ilustracja 6: 20181019_Czechow_Lot3_orto - wycinek

- 20181019_Czechow_Lot1_orto



Ilustracja 7: 20181019_Czechow_Lot1_orto - wycinek

Inne wnioski:

- Manualna interpretacja pozwala łatwo rozpoznać barszcz przy rozdzielczości $<1\text{cm}$. Na jesiennych zdjęciach barszcz wyróżnia się dużymi suchymi pędami i parasolowatymi baldachami.
- Zestaw danych do klasyfikacji jaki powinien przygotować JJ:
- - mozaika ortofoto RGB 3 kanały, w formacie geotif, najlepiej w układzie 2000 (obecne poligony strefa 5 układu 2000, EPSG:2176), ewentualnie UTM, piksel kwadratowy (po transformacji z WGS84 do 2000 piksel nie jest kwadratowy, co nie jest wygodne)
- - poszczególne kanały z kamery RE, jako mozaiki w tym samym formacie i układzie co orto, piksel może być różny (zawsze można zrobić resampling jeśli programy klasyfikacyjne będą wymagały, takiego samego piksela), ważna jest synchronizacja przestrzenna, pomocne w tym będą fotopunkty. NDVI lub inne wskaźniki będą generowane już w programach GIS.
- - Model 3D pokrycia powierzchni terenu DSM z wysokością (do piksela przypisana wysokość, współrzędna Z jako pochodna wysokości rejestrowanej przez GPS). Mając lidarowy DEM można wygenerować warstwę wysokości roślinności (do przetestowania), Sam DSM z AgiSoft, będzie przydatny do klasyfikacji barszczu na terenach płaskich.
-



Ilustracja 8

Aspekt 2.5.1.2.2 Wyznaczanie obiektów do klasyfikacji (\$RECG_HM_PTS)

Tabela 10 Podaspekty wyznaczania obiektów do klasyfikacji

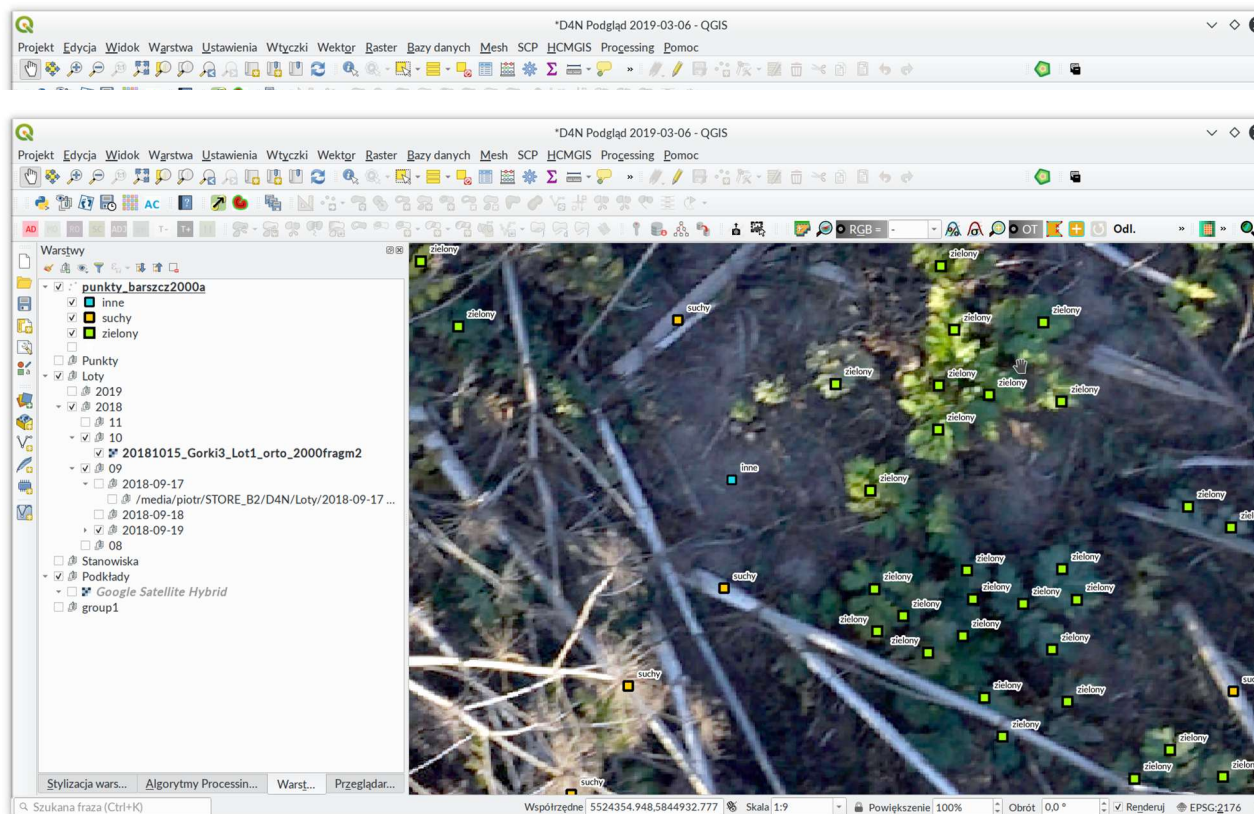
Aspekt	2.5.1.2.2	Wyznaczanie obiektów do klasyfikacji	\$RECG_HM_PTS	Możliwe wartości	Zastosowane wartości
Podaspekt	2.5.1.2.2.1	wielkość punktów	\$RECG_HM_PTS_SIZE	0,1m, 0,2m, 0,5m	0,2m
Podaspekt	2.5.1.2.2.2	liczba punktów	\$RECG_HM_PTS_NR		100 na 1 klasę obiektów
Podaspekt	2.5.1.2.2.3	zagęszczenie	\$RECG_HM_RECOG		1 na obiekt, z dala od brzegu
Podaspekt	2.5.1.2.2.4	dane punktów	\$RECG_SES		

Na wybranych zdjęciach rozmieszczono punkty oznaczające barszcz i tło, bądź różne typy barszczu (w tym przypadku stadia rozwojowe: liście osobników juvenilnych, zaschnięte łodygi i kwiatostany, oraz tło (roślinność nie będąca barszczem, gleba itp)).

Podzadanie 2.5.1.3
 Sesje rozpoznawanie barszczu
 (\$RECG_SES)

Rozpatrywane aspekty
 rozpoznawania barszczu
 zawiera Tabela 11.

Tabela 11




Ilustracja 10: Powiększenie punktów klasyfikujących obiekty na zobrazowaniu. Na podanym przykładzie - 2 typy barszczu i tło.

Podzadanie	2.5.1.3	Sesje rozpoznawanie barszczu	\$RECG_SES	Zastosowane wartości
Aspekt	2.5.1.3.1	nr sesji	\$RECG_SES_ID	NA
Aspekt	2.5.1.3.2	scenariusz sesji	\$RECG_SES_AIM	Sklasyfikuj zobrazowany teren na obszary „barszcz” i „tło”. Oraz na barszczliście, łodygi i tło
Aspekt	2.5.1.3.2	software	\$RECG_SES_SOFT	eCognition Essential Trial 13.1

Podzadanie	2.5.1.3	Sesje rozpoznawanie barszczu	\$RECG_SES	Zastosowane wartości
Aspekt	2.5.1.3.4	parametry sesji	\$RECG_SES_PAR	Domyślne
Aspekt	2.5.1.3.5	dane wejściowe	\$RECG_SES_INPUT	Fragmenty Ortofoto
Aspekt	2.5.1.3.6	dane wyjściowe	\$RECG_SES_OUTPUT	Zrzuty ekranu
Aspekt	2.5.1.3.7	czas obliczeń	\$RECG_SES_TIME	NA
Aspekt	2.5.1.3.7	użyty komputer	\$RECG_SES_HARDWARE	NA
Aspekt	2.5.1.3.8	zapis danych	\$RECG_SES_OUTPUT_SAVING	roboczy

Przebieg rozpoznawania



Ilustracja 11 Segmentacja fragmentów zobrazowania z barszczem barszczu na zdjęciu 2018-09-17 Gorki_Lot_4_D4N_IMG_2018-09-17_A7R3_04_0055.jpg czerwony – barszcz zielone części, żółty – barszcz suche pędy, niebieski – pozostałe pokrycie (tło). Ustawienia: scale 70, shape 0.55, compactness 0.8, klasyfikator – SVM

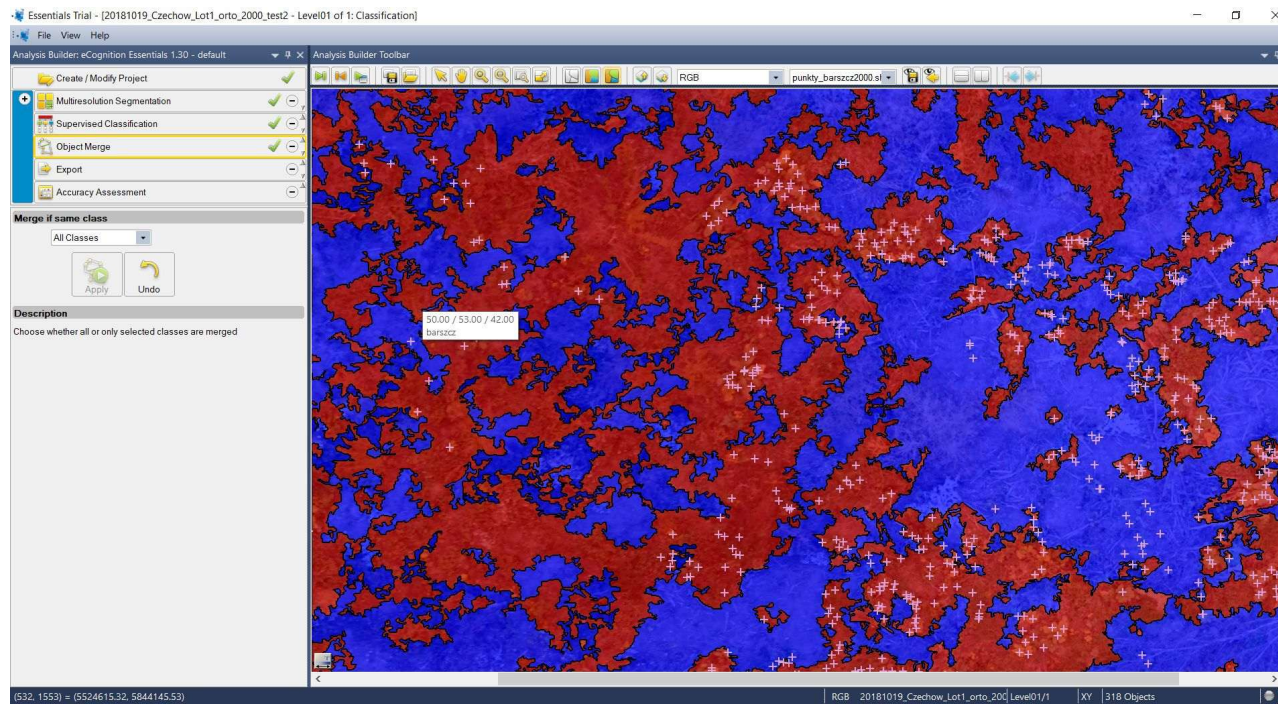
Do klasyfikacji wykorzystano metodą obiektowej analizy obrazów (OBIA - ang. Object Based Image Analysis), która wykorzystuje zaawansowane algorytmy segmentacji rastra. Na podstawie barwy pikseli i ich ułożenia, piksele grupowane są w homogeniczne obiekty – segmenty. Zwartość, kształt segmentów i poziom szczegółowości zadawany algorytmem decyduje o liczbie segmentów. Wynikowa liczba segmentów powinna dopasować do wielkości klasyfikowanych obiektów, np. wielkości liści lub płatów barszczu. Dobór właściwych parametrów segmentacji dokonuje się metodą „prób i błędów”, tak aby uniknąć nadmiernej liczby bardzo małych segmentów. W kolejnym etapie segmenty, czyli obiekty (grupy pikseli) są klasyfikowane do zdefiniowanych klas. Metody OBIA są lepsze dla zobrazowań wysoko-rozdzielczych (piksel < 5cm), w porównaniu do klasyfikacji tradycyjnej bazującej tylko na jasności pikseli w poszczególnych kanałach.

1. etap ocena zdjęć, wybór zdjęć do klasyfikacji. Klasyfikację wykonano na obrazach z października, na których barszcze jest widoczny w postaci uschniętych, jasnożółtych długich pędów, często przechylonych lub leżących na ziemi oraz zielonych lub zielono-żółtych młodych liści odziomkowych
2. Przeprowadzenie klasyfikacji w programie eCognition z podziałem na 3 klasy barszcz uschnięty, barszcz zielony, pozostałe obiekty
3. Przygotowanie danych treningowych dla programu eCognition, jako warstwa punktowa z lokalizacjami obiektów przyporządkowanych do powyższych 3 klas (ponad 100 punktów dla każdej klasy).
4. Parametry segmentacji: algorytm – multiresolutio, scale – 70, color – 0.5, smoothnes – 0.7
5. Algorytm klasyfikacji: Bayes

Wyniki rozpoznawania

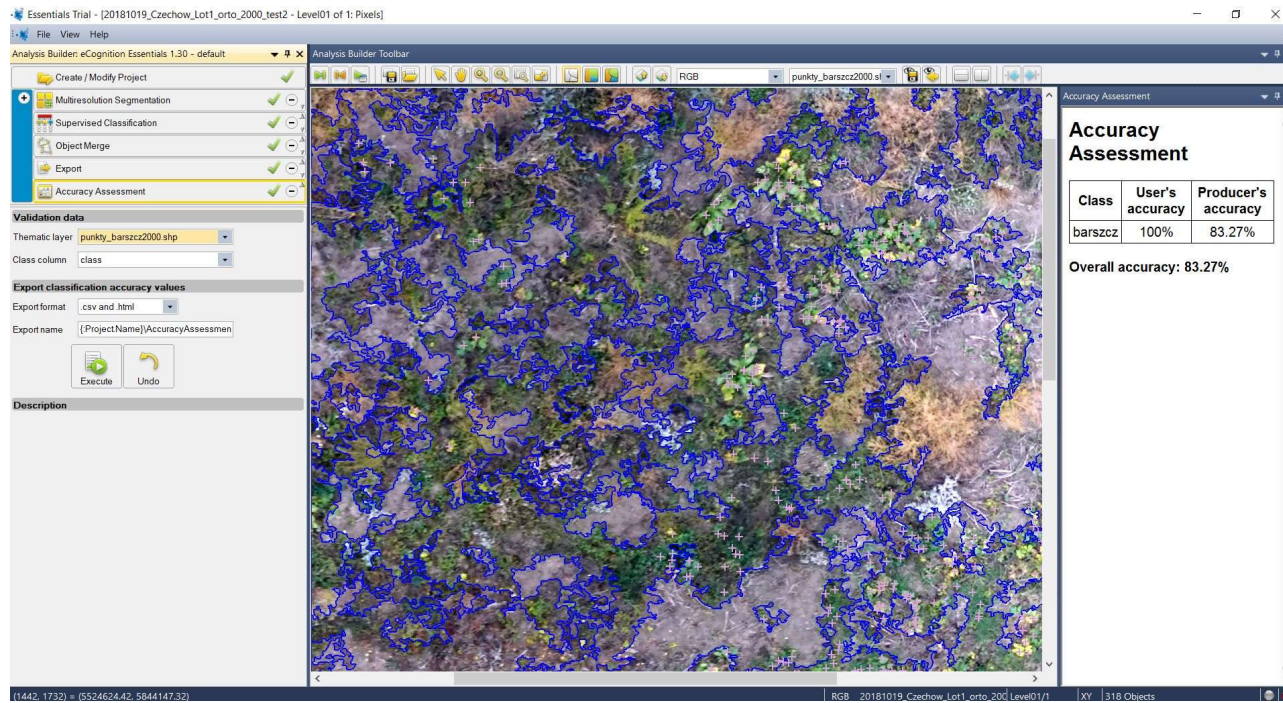
Klasyfikacja barszcz-tło

Najlepszą skuteczność rozpoznawania uzyskano w dla zdjęcia 20181019 Czechów Lot1_orto_2000 test2 w programie E-cognition.



Czechów Lot1_orto_2000 test2 w programie E-cognition.

Ilustracja 12 Przebieg klasyfikacji zdjęcia 20181019

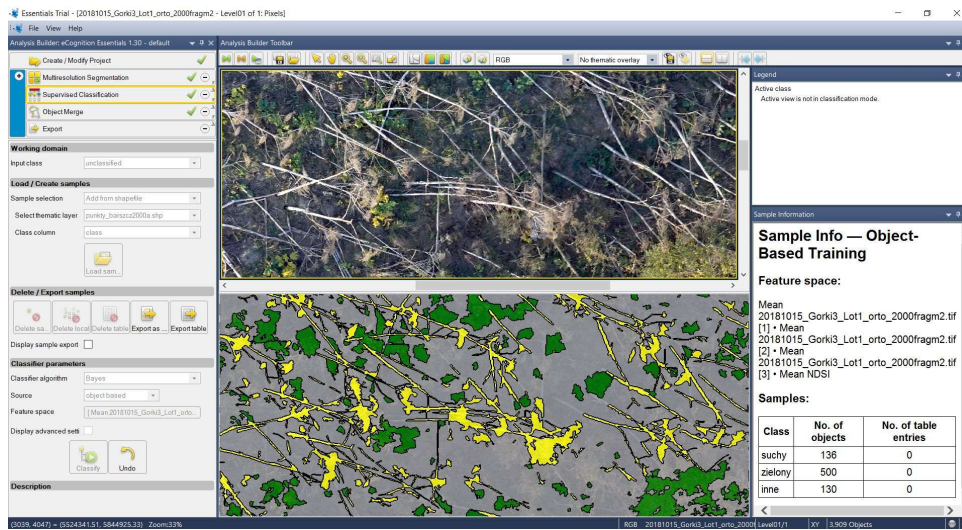


Ilustracja 13: Rezultat klasyfikacji zdjęcia 20181019 Czechów Lot1_orto_2000 test2 w programie E-cognition.

Skuteczność klasyfikacji zdjęcia 20181019 Czechów Lot1_orto_2000 test2 w programie E-cognition wyniosła **.83,2%**.

Rozpoznawanie dwóch typów barszczy: zielone liście osobników juwenilnych, suche łodygi osobników owocujących + tło

Najlepszą skuteczność rozpoznawania uzyskano w dla zdjęcia 20181015 Górki3 Lot1_orto_2000fragm2 w programie E-cognition.



20181015 Górki3 Lot1_orto_2000fragm2 w programie E-cognition

Ilustracja 14 Przebieg klasyfikacji zdjęcia



Ilustracja 15 Rezultat klasyfikacji zdjęcia 20181015 Górki3
 Lot1_orto_2000fragm2 w programie E-cognition

Skuteczność klasyfikacji zdjęcia 20181019 Czechów Lot1_orto_2000 test2 w programie E-cognition wyniosła **.84,4%**.

Wnioski merytoryczne

1. Klasa suchego barszczu jest mylona z odkrytą glebą, barszcz zielony może być mylony z innymi zieloną roślinnością.
 1. Optymalne ustawienia kolejnych etapów zbioru obrazów i rozpoznawania
 2. Nalot, fotopunkty terenowe (GCP), zebranie pomocniczych danych w terenie (zdjęcia naziemne aparatem z GPSem)
 3. Przetwarzanie zdjęć, mozaikowanie, generowanie ortofotomapy, DSM, podział na fragmenty nie większe niż 5000x5000 pikseli
 4. Korekta graficzna ortofotomapy (poprawa kontrastu, podkreślenie krawędzi, odszumienie)
 5. Przygotowanie danych treningowych i weryfikacyjnych (wykorzystanie lokalizacji barszczu ze zdjęć naziemnych, fotointerpretacja barszczu, wygląd na fotografiach jako wskazówki interpretacyjne) – kilkaset punktów, min. po 100 na barszcz i inne pokrycie, najlepiej >200
 6. Dane RE (kanały R, G, B, NIR), generowanie maski terenów nieroślinnych na podstawie wskaźników roślinnych np. NDVI
 7. Klasyfikacja obiektowa w eCognition Essential Trial 13.1 (OBIA)
 1. - segmentacja Multiresolution, ustalenie wartości parametrów programu metodą prób i błędów na wycinku, aby segmentacja najlepiej wyznaczała kontury barszczu, na podstawie dotychczasowych prób na obrazach jesiennych wartości parametrów należy ustawić na: scale 50-70, shape 0.5-0.6, compactness 0.6-0.8

2. - zaznaczenie próbki segmentów z barszczem i bez barszczu (ręcznie lub automatycznie na podstawie treningowej warstwy punktowej w formacie .shp)
3. - klasyfikacja segmentów – dotychczas najlepiej sprawdził się algorytm SVM
2. Testowa klasyfikacja w eCognition na 2 klasy barszcz i nie-barszcz ma problem z poprawną segmentacją – liście zlewają się z zielonym otoczeniem, który nie jest barszczem lub brak wyraźnych granic liście (rozmyte przejście w szarawe tło podłoża), wydzielone segmenty są mieszanką barszczu i nie-barszczu.
3. Lepsze efekty uzyskano na zdjęciach wrześnieowych z dużymi liśćmi niż na zdjęciach październikowych.
4. Klasyfikacja obiektowa przy pomocy eCognition Essential Trial 13.1 jest obiecującą metodą.
5. eCognition trial brak możliwości zapisania projektu i eksportu warstwy wektorowej po segmentacji i klasyfikacji.
6. W następnym zadaniu 2.5.2. Scope Extension należy:
 1. wypróbować software inny niż eCognition: algorytm klasyfikacji Random Forest w R, QGIS-OTB plugin <https://www.orfeo-toolbox.org/CookBook/Recipes.html>, Semi-Automatic Classification Plugin (SCP) is a free open source plugin for QGIS (tylko klasyfikacja pikselowa) oraz inne algorytmy dostępne w środowisku R
 2. Przetestować klasyfikację metodą Random Forest w środowisku programistycznym R
 3. Przeprowadzić szczegółową ocenę dokładności (dokładność całkowita, przeszacowania, niedoszacowania), rozważyć opracowanie protokołu wizualnej kontroli wyników, wprowadzenie ewentualnych ręcznych poprawek, powiązywania i zachowywania wraz z wynikami klasyfikacji obrazowań i warstw poklasyfikacyjnych, map z lokalizacją, raportów szczegółowych.

WNIOSKI KOŃCOWE

- **W toku obu scenariuszy rozpoznawania (1 typ barszczu + tło, oraz 2 typy barszczy + tło) uzyskano maksymalna dokładność całkowita 83 i 84%.**
- **Oznacza to, że skuteczność wymagana w Milestone # została osiągnięta.**
- **Zadanie 2.5.1. ProofOfConcept zostało zrealizowane.**

•
Załącznik

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Dział	1.	Założenia	\$ARG_ASSUMPT	Założenia przyjmowane na początku opracowania algorytmu		
Poddział	1.1	algorytm ma umożliwić identyfikację barszczu w terenie na podstawie zdjęć i dodatkowych danych	\$ARG_ASSUMPT_DATA			
Poddział	1.2	algorytm ma mieć charakter adaptacyjny, czyli umożliwić stopnie zwiększanie jakości i poszerzanie zakresu warunków możliwości rozpoznawania	\$ARG_ASSUMPT_ADAPT			
Poddział	1.3	algorytm ma być oszczędny w wykorzystaniu danych, mocy obliczeniowej, czasu	\$ARG_ASSUMPT EFFIC			
Poddział	1.4	algorytm ma być odporny na braki danych	\$ARG_ASSUMPT EFFIC			
Poddział	1.5	algorytm ma być hierarchiczny, czerpać wskazania do decyzji z danych na innych poziomach szczegółowości	\$ARG_ASSUMPT SMART			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Poddział	1.6	algorytm ma być open-source, parametryzacja – tajemnica przedsiębiorstwa	\$ARG_ASSUMPT_OPEN			
Dział	2.	Rozpoznawanie	\$HM_REC_G	Działania polegające na rozpoznawania barszczy		
Poddział	2.1	Otrzymanie zlecenia	\$HM_CONTR	Proces pozyskania zlecenia	[0,1]	
Zadanie	2.1.1	region (województwo)	\$HM_CONTR_REG		[nazwa ze zbioru]	
Zadanie	2.1.2	obszar opracowania	\$HM_CONTR_WORK	, np. gmina, osoba prawna lub fizyczna	[nazwa ze zbioru]	
Zadanie	2.1.3	stanowisko, np. fragment gminy, w którym wstępnie określono możliwość wystąpienia barszczu	\$HM_CONTR_SITE		[nazwa z atlasu]	
Zadanie	2.1.4	zamawiający	\$HM_CONTR_ENTITY	Podmiot, który udziela zamówienia	[nazwa]	
Poddział	2.2	Wstępna ocena występowania barszczu	\$HM_CONTR_INIT_ASSESS	Służy wytypowaniu miejsc do wykonania oblotu		
Zadanie	2.2.1	Dane od zamawiającego	\$HM_CONTR_INIT_ENTITY_DATA	Dane wstępne udostępnione przez zamawiającego, na ogół dotyczą działek ewidencyjnych dotkniętych barszczem		
Zadanie	2.2.2	Dane z atlasu stanowisk	\$HM_CONTR_REG	Dane z atlasu stanowisk		
Podzadanie	2.2.2.1	w regionie	\$HM_CONTR_REG	Stanowiska (województwo, powiat lub 50km dookoła terenu opracowania)		
Aspekt	2.2.2.1.1	gatunki,	\$HM_CONTR_REG_TAXA	gatunki występujące na terenie	[nazwy]	mały,
Aspekt	2.2.2.1.2	liczba stanowisk	\$HM_CONTR_REG_SITE_NR	Liczba stanowisk w regionie	[numeric]	

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Aspekt	2.2.2.1.3	dane o rozmieszczeniu	\$HM_CONTR_REG_SITE_DATA	Zbiór danych z danymi stanowisk	[tabela CSV, SpatialPointDataFrame]	
Aspekt	2.2.2.1.4	trend zmian	\$HM_CONTR_REG_TREND	Rośnie, stabilny maleje		
Podzadanie	2.2.2.2	w sąsiedztwie -	\$HM_CONTR_NEIG	sąsiednie gminy		
Aspekt	2.2.2.2.1	gatunki,	\$HM_CONTR_NEIG_TAXA	gatunki występujące na terenie		
Aspekt	2.2.2.2.2	liczebność lub zagęszczenie populacji	\$HM_CONTR_NEIG_DENS,			
Aspekt	2.2.2.2.3	Frekwencja stadiów rozwoju populacji	\$HM_CONTR_NEIG_PHASE,	duże, ma wpływ na skuteczność rozpoznania i potem działania	[inicjalne, pośrednie, terminalne]	3
Aspekt	2.2.2.2.4	najbliższe stanowiska	\$HM_CONTR_REG_NEAREST			
Podzadanie	2.2.2.3	barszcze na terenie opracowania	\$HM_CONTR_WORK			
Aspekt	2.2.2.3.1	gatunki,	\$HM_CONTR_WORK_TAXA	gatunki występujące na terenie, jeżeli można je wyróżnić, jeżeli nie – zakładamy mieszańcowe		1
Aspekt	2.2.2.3.2	wykaz stanowisk	\$HM_CONTR_WORK_SITE_DATA	jeżeli terenem opracowania jest gmina, wykaz miejscowości, jeżeli mniejszy obszar – nazwa miejscowości		
Aspekt	2.2.2.3.3	liczba stanowisk	\$HM_CONTR_WORK_SITE_NR	Im więcej, tym więcej barszczu, stanowisko niesamodzielne		
Aspekt	2.2.2.3.3	trend zmian	\$HM_CONTR_WORK_WORK_SITE_NR_TREND	Im większy wzrost, tym łatwiej będzie zniszczyć barszcz, a stanowisko samodzielne		
Aspekt	2.2.2.3.4	najbliższe stanowiska	\$HM_CONTR_WORK_SITE_NEAREST	Im bliżej, tym więcej barszczu, stanowisko niesamodzielne		
Zadanie	2.2.3	Model SDM	\$HM_CONTR_WORK_IA_ISDM	Model iSDM, zastosowany do oceny możliwości wystąpienia w kwadracie 4m		

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podzadanie	2.2.3.1	predyktory	\$HM_CONTR_WORK_IA_ISDM_PREDICTOR	Zmienne dla terenu: NMT, NMPT, BDOT_10k, inne.		
Podzadanie	2.2.3.2	zmienne zależne	\$HM_CONTR_WORK_IA_ISDM_01	\$HM_CONTR_REG_SITE_DATA		
Podzadanie	2.2.3.3	algorytm	\$HM_CONTR_WORK_IA_ISDM_ALGO	rodzaje zastosowanych algorytmów w modelu, domyślnie RandomForest		
Podzadanie	2.2.3.4	rozdzielczość	\$HM_CONTR_WORK_IA_ISDM_PIX	rozdzielczość modelu, domyślnie 4m; do takiej wartość będą sprowadzone predyktory		
Podzadanie	2.2.3.5	jakość modelu	\$HM_CONTR_WORK_IA_ISDM_ACCUR	wartość AUC lub ROC		
Podzadanie	2.2.3.6	projekcja aktualna	\$HM_CONTR_WORK_IA_ISDM_PROJECT	jak model wyobraża sobie aktualne występowanie barszczu		
Podzadanie	2.2.3.7	prognoza	\$HM_CONTR_WORK_IA_ISDM_PREDICT	jak model prognozuje rozmieszczenie barszczu w przyszłości		
Zadanie	2.2.4	Obszary wytypowane do nalotu	\$HM_CONTR_WORK_IA_FL_PROP	Na podstawie danych od zamawiającego, danych z atlasu i/lub modelu SDM – lista proponowanych obszarów do wykonania oblotów		
Podzadanie	2.2.4.1	Mapa obszarów	\$HM_CONTR_WORK_IA_FL_PROP_MAP	Mapa obszarów w pliku KML, SHP etc.		4
Podzadanie	2.2.4.2	Wstępna charakterystyka	\$HM_CONTR_WORK_IA_FL_PROP_CHAR	Wstępny zakres kluczowych parametrów terenowych na terenie opracowania		4
Poddział	2.3	Planowanie i realizacja lotów	\$STRIP	Planowanie i realizacja lotów		
Zadanie	2.3.1	Wyjazd	\$STRIP	Loty są organizowane w wyjazdy; w zależności od odległości od bazy i terenu do nalotu		
Podzadanie	2.3.1.1	odległość od bazy	\$STRIP_PAR_DISTANCE	Odległość drogowa		6

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podzadanie	2.3.1.2	liczba dni	\$STRIP_PAR_DAYS			4
Podzadanie	2.3.1.3	liczba lotów	\$STRIP_PAR_FL_NR			4
Zadanie	2.3.2	Parametry lotu	\$STRIP_FL			
Podzadanie	2.3.2.1	typ użytego UAV	\$STRIP_FL_UAV		[nazwa ze zbioru]	8
Podzadanie	2.3.2.2	wysokość AGL	\$STRIP_FL_AGL	Założona wysokość wykonania zdjęć	[numeric]	8
Podzadanie	2.3.2.3	lokalizacja z RTK	\$STRIP_FL_RTK	Czy zdjęcia były lokalizowane z RTK na pokładzie UAV	[0,1]	6
Podzadanie	2.3.2.3	planowana wielkość groundpiksela	\$STRIP_FL_GPIX	Wartość w cm	[numeric]	8
Podzadanie	2.3.2.5	numer lotu	\$STRIP_FL_NR	Unikalny dla dnia		
Podzadanie	2.3.2.6	rok	\$STRIP_FL_YR	Unikalny dla dnia		
Podzadanie	2.3.2.7	miesiąc	\$STRIP_FL_MONTH	Unikalny dla dnia	[nazwa ze zbioru]	
Podzadanie	2.3.2.8	faza fenologiczna	\$STRIP_FL_PHEN_SEASON	Absolutnie kluczowy parametr warunkujący to jak wyglądają barszcze i ich tło,	[nazwa z listy]	10
Podzadanie	2.3.2.9	pora dnia – światło kolorystyka	\$STRIP_FL_DAYTIME	Absolutnie kluczowy parametr warunkujący to jak wyglądają barszcze i ich tło, wstępnie od 10:00 do 16:00, zależnie od długości dnia		8
Aspekt	2.3.2.10	godzina startu	\$STRIP_FL_HHMM	Parametr techniczny		2
Aspekt	2.3.2.11	zachmurzenie całkowite	\$STRIP_FL_CLOUDS	Parametr dodatkowy wpływający na ilość i rozkład światła (kierunkowe, czy bezkierunkowe)		6
Aspekt	2.3.2.12	wilgotność względna	\$STRIP_FL_RH	Parametr dodatkowy wpływający na rozproszenie światła		6

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Aspekt	2.3.2.13	wiatr	\$STRIP_FL_WIND	Parametr dodatkowy wpływający na stabilność UAV i ostrość zdjęć (machanie roślinami)		8
Aspekt	2.3.2.14	czynniki zaburzające	\$STRIP_FL_DIST	Inne czynniki zaburzające		8
Aspekt	2.3.2.15	zapylenie	\$STRIP_FL_DIST_PM	Parametr dodatkowy wpływający na fakturę i kolorystykę powierzchni liści		6
Aspekt	2.3.2.16	dym	\$STRIP_FL_DIST_PM	Parametr dodatkowy wpływający na fakturę i kolorystykę powierzchni liści		6
Aspekt	2.3.2.17	problemy techniczne	\$STRIP_FL_DIST_TECH	Problemy techniczne w trakcie lotu, awarie, błędy w ustawieniach itp..		8
Zadanie	2.3.3	barszcze w płacie objętym lotem	\$STRIP_HM_FL	Natężenie zasiedlenia terenu lotu przez barszcz		
Podzadanie	2.3.3.1	gatunki,	\$STRIP_HM_FL_TAXA	domyślnie mieszańce		2
Podzadanie	2.3.3.2	liczebność lub zagęszczenie populacji	\$STRIP_HM_FL_DENS,	% obszarów 4x4 zawierających barszcz		6
Podzadanie	2.3.3.3	stadium rozwoju populacji, stadium rozwoju płatu, struktura wielkości / statusu osobników	\$STRIP_HM_FL_PHASE,			6
Zadanie	2.3.4	Parametry krajobrazu objętego lotem	\$STRIP_FL_LAND	Absolutnie kluczowy parametr określający możliwości transferability modeli		
Podzadanie	2.3.4.1	CORINE Land Cover	\$STRIP_FL_LAND_CLC	Typ pokrycia terenu wg CLC pozoim III.		2
Podzadanie	2.3.4.1	BDOT_10k	\$STRIP_FL_LAND_BDOT_10k	Typ pokrycia terenu wg BDOT 1:10000		6

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podzadanie	2.3.4.2	zróznicowanie wysokości gruntu	\$STRIP_FL_LAND_NMT_VAR	Parametry na podstawie NMT		6
Podzadanie	2.3.4.3	zróznicowanie wysokości szczytu roślinności,	\$STRIP_FL_LAND_NMPT_VAR	Parametr na podstawie NMPT		6
Podzadanie	2.3.4.4	zróznicowanie wysokości względnej roślinności,	\$STRIP_FL_LAND_NMP_VAR	Parametr na podstawie NMP		8
Podzadanie	2.3.4.5	szczególne problemy	\$STRIP_FL_LAND_PROBL	Inne ważne cechy obszaru objętego lotem		6
Poddział	2.4	Przechowanie i obróbka zdjęć	\$STRIP_FL_IMG			
Zadanie	2.4.1	Miejsce i standardy zapisu	\$STRIP_FL_IMG_SAVE			
Zadanie	2.4.2	Nazewnictwo	\$STRIP_FL_IMG_NAME_CODE			
Zadanie	2.4.3	Zapis plików i metadanych	\$STRIP_FL_IMG_METADATA			
Zadanie	2.4.4	udostępnianie	\$STRIP_FL_IMG_SHARE			
Zadanie	2.4.5	Przetwarzanie zdjęć na ortofotomapę	\$STRIP_FL_IMG_ORTO			
Podzadanie	2.4.5.1	Program	\$STRIP_FL_IMG_ORTO_SOFT			
Aspekt	2.4.5.1.1	nazwa	\$STRIP_FL_IMG_ORTO_SOFT_NAME			
Aspekt	2.4.5.1.2	parametry generowania	\$STRIP_FL_IMG_ORTO_SOFT_SETT			
Podzadanie	2.4.5.2	właściwości ortofotomapy	\$STRIP_FL_IMG_ORTO			
Aspekt	2.4.5.2.1	ground pixel	\$STRIP_FL_IMG_ORTO_GRPIX			
Aspekt	2.4.5.2.2	format pliku	\$STRIP_FL_IMG_ORTO_FORM			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Aspekt	2.4.5.2.3	geolokalizacja	\$STRIP_FL_IMG_ORTO_GEOLOC			
Aspekt	2.4.5.2.4	rozmiar pliku	\$STRIP_FL_IMG_ORTO_FILESIZE			
Podzadanie	2.4.5.3	kontrola jakości odwzorowania	\$STRIP_FL_IMG_ORTO_QC			
Aspekt	2.4.5.3.1	rozmycia,	\$STRIP_FL_IMG_ORTO_QG_BLUR			
Aspekt	2.4.5.3.2	rozbieżność geolokalizacji	\$STRIP_FL_IMG_ORTO_QC_GEOLOC			
Zadanie	2.4.6	Podział ortofotomapy na płyty (TILE)	\$STRIP_FL_IMG_ORTO_TILE			
Podzadanie	2.4.6.1	program	\$STRIP_FL_IMG_ORTO_TILE_SOFT			
Podzadanie	2.4.6.2	nazewnictwo	\$STRIP_FL_IMG_ORTO_TILE_NAMING			
Podzadanie	2.4.6.3	rozmiar [m]	\$STRIP_FL_IMG_ORTO_TILE_SIZE			
Poddział	2.5	Budowa algorytmu rozpoznawania	\$RECG_ALGO			
Zadanie	2.5.1	Proof of concept	\$RECG			
Podzadanie	2.5.1.1	Presekcja algorytmów rozpoznawania	\$RECG_PRESEL			
Podzadanie	2.5.1.2	Wyznaczanie obiektów klasyfikacji	\$RECG_BGR			
Aspekt	2.5.1.2.1	Wybór zdjęć do wstępnego rozpoznawania (tło) pokrycie terenu,	\$RECG_BGR			
Podaspekt	2.5.1.2.1.1	pokrycie terenu,	\$RECG_BGR_LC			
Podaspekt	2.5.1.2.1.2	roślinność	\$RECG_BGR_VEG			
Podaspekt	2.5.1.2.1.3	typ fizjonomiczny	\$RECG_BGR_PHYS			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podaspekt	2.5.1.2.1.4	liczba gatunków,	\$RECG_BGR_SPNR			
Podaspekt	2.5.1.2.1.5	wysokość,	\$RECG_BGR_H			
Podaspekt	2.5.1.2.1.6	warstwowość	\$RECG_BGR_LAYERS			
Podaspekt	2.5.1.2.1.7	zaburzenia	\$RECG_BGR_DISTURB			
Aspekt	2.5.1.2.2	Wyznaczanie obiektów do klasyfikacji	\$RECG_HM_PTS			
Podaspekt	2.5.1.2.2.1	wielkość punktów	\$RECG_HM_PTS_SIZE			
Podaspekt	2.5.1.2.2.2	liczba punktów	\$RECG_HM_PTS_NR			
Podaspekt	2.5.1.2.2.3	zagęszczenie	\$RECG_HM_RECOG			
Podaspekt	2.5.1.2.2.4	dane punktów				
Podzadanie	2.5.1.3	Sesje rozpoznawanie barszczu	\$RECG_SES			
Aspekt	2.5.1.3.1	nr sesji	\$RECG_SES_ID			
Aspekt	2.5.1.3.2	scenariusz sesji	\$RECG_SES_AIM			
Aspekt	2.5.1.3.2	software	\$RECG_SES_SOFT			
Aspekt	2.5.1.3.4	parametry sesji	\$RECG_SES_PAR			
Aspekt	2.5.1.3.5	dane wejściowe	\$RECG_SES_INPUT			
Aspekt	2.5.1.3.6	dane wyjściowe	\$RECG_SES_OUTPUT			
Aspekt	2.5.1.3.7	czas obliczeń	\$RECG_SES_TIME			
Aspekt	2.5.1.3.7	użyty komputer	\$RECG_SES_HARDWARE			
Aspekt	2.5.1.3.8	zapis danych	\$RECG_SES_OUTPUT_SAVING			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podzadanie	2.5.1.4	Kontrola jakości rozpoznania	\$RECG_SES_QC			
Aspekt	2.5.1.4.1	uzyskana jakość w modelu wewnętrznym	\$RECG_SES_QC_VAL			
Aspekt	2.5.1.4.2	wyznaczony próg jakości rozpoznania	\$RECG_SES_QC_VAL_THRESH			
Aspekt	2.5.1.4.3	przekroczenie wyznaczonego progu	\$RECG_SES_QC_VAL_THRESH			
Aspekt	2.5.1.4.4	Wstępne wyznaczenie zskresów stosowania	\$RECG_SES_QC_VAL_THRESH			
Zadanie	2.5.2	Scope extension Powtarzanie zadania 2.5.1. z zapisem metadanych	\$RECG_SCOPEEXT			
Podzadanie	2.5.2.1	Wyznaczenie zakresu testów	\$RECG_PAR_SPACE			
Aspekt	2.5.2.1.1	zakres przestrzeni parametrów, dla których może występować barszcz	\$RECG_PAR_SPACE_HM_TESTED			
Aspekt	2.5.2.1.2	zakres przestrzeni parametrów, dla których był testowany barszcz	\$RECG_PAR_SPACE_HM_TRESH_PASSED			
Aspekt	2.5.2.1.3	zakres przestrzeni parametrów, dla których wyznaczony próg jakości rozpoznania został przekroczony	\$RECG_PAR_SPACE_HM_TRESH_MISSED			
Aspekt	2.5.2.1.4	zakres przestrzeni parametrów, dla których wyznaczony próg jakości rozpoznania nie został przekroczony	\$RECG_PAR_SPACE_HM_NEXT			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Aspekt	2.5.3.1.5	zakres przestrzeni parametrów, dla których wyznaczony próg jakości rozpoznania może być osiągnięty	\$RECG_PAR_SPACE_NEXT_SCEN			
Podzadanie	2.5.3.2	Wskazanie parametrów nowych nalotów	\$RECG_SES_INDQC			
Aspekt	2.5.3.2.1	uzyskana jakość w modelu wewnętrznym	\$RECG_SES_INDQC_VAL			
Aspekt	2.5.3.2.2	wyznaczony próg jakości rozpoznania	\$RECG_SES_INDQC_VAL_THRESH			
Aspekt	2.5.3.2.3	przekroczenie wyznaczonego progu	\$RECG_SES_INDQC_VAL_THRESH_PASSED			
Podzadanie	2.5.3.3	Automatyzacja rozpoznania poprzez skryptowanie	\$RECG_AUT			
Podzadanie	2.5.3.4	Dołączanie nowych algorytmów (AOS)	\$RECG_AOC			
Podzadanie	2.5.3.5	Optymalizacja	\$RECG_OPTIM			
Aspekt	2.5.3.5.1	Budowa metamodelu dla jakości rozpoznania	\$RECG_OPTIM_META			
Aspekt	2.5.3.5.2	Budowa metamodelu dla jakości rozpoznania	\$RECG_OPTIM_TUNING			
Zadanie	2.5.4	Production ready	\$RECG_GM			
Podzadanie	2.5.4.1	Weryfikacja i dokumentacja funkcji dla algorytmów rozpoznawania	\$RECG_GM_PUB			
Aspekt	2.5.4.1.1	Pakiet R	\$RECG_GM_PUB_R			
Aspekt	2.5.4.1.2	Publikacja metodyczna	\$RECG_GM_PUB_SCI			

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Podzadanie	2.5.4.2	Tworzenie narzędzia wspomagania decyzji i rozszerzac stosowanie	\$RECG_GM_SOFT			
Podzadanie	2.5.4.3	Wdrożenie narzędzia i dostosowanie do warunkow uzytkowania	\$RECG_GM_APPL			
Dział	3.	Raportowanie	\$SURVEY_REPORT	Raportowanie rozpoznawania		
Dział	4.	Usuwanie barszczy	\$REMOVAL	Usuwanie zobrazowanych osobników		
Poddział	4.1	Wezytanie danych o rozmieszczeniach	\$REMOVAL_AREA			
Poddział	4.2	Ocena przydatności technik	\$REMOVAL_TECH_ASSESS			
Zadanie	4.2.1	koszt	\$REMOVAL_TECH_ASSESS_COST			
Zadanie	4.2.2	przewidywana efektywność	\$REMOVAL_TECH_ASSESS_EFF			
Zadanie	4.2.3	skutki uboczne	\$REMOVAL_TECH_ASSESS_SIDE			
Poddział	4.3	Przydzial technik do obszarów	\$REMOVAL_TECH			
Poddział	4.4	Planowanie misji	\$REMOVAL_MISSION			
Poddział	4.5	Realizacja zwalczania	\$REMOVAL_ACTION			
Poddział	4.6	Ocena skuteczności technik	\$REMOVAL_ACT_QA			
Zadanie	4.6.1	koszt poniesiony	\$REMOVAL_ACT_QA_COST			
Zadanie	4.6.1	efektywność	\$REMOVAL_ACT_QA_EFF			
Zadanie	4.6.1	skutki uboczne	\$REMOVAL_ACT_QA_SIDE			
Poddział	5.1	Raportowanie	\$REMOVAL_REPORT	Raportowanie usuwania		

Level	Nr	Działanie	Parametr	Opis	Typ zmiennej	Wpływ na działanie
Poddział	6.1	Odbiory	\$REMOVAL_ACCEPT	Odbiory, weryfikacja, poprawki		

Materiały do raportu końcowego II etapu

Zagadnienie technologiczne


W toku prac w ramach etapu zespół Specjalistów ds. Kaukaskich Barszczy wspólnie z Kierownikiem Projektu pracował nad implementacją urządzeń służących do niszczenia kaukaskich barszczy z użyciem dronów. W odniesieniu do algorytmu była to część 4 związana z usuwaniem barszczy.

Tabela 1 Działy algorytmu rozpoznawania i zwalczania kaukaskich barszczy

Parametr	L0		Opis
\$ARG_ASSUMPT	1	Założenia	Założenia przyjmowane na początku opracowania algorytmu
\$HM_RECG	2	Rozpoznawanie	Działania polegające na rozpoznawaniu barszczy
\$SURVEY_REPORT	3	Raportowanie	Raportowanie rozpoznawania
\$REMOVAL	4	Usuwanie barszczy	Usuwanie zobrazowanych osobników
\$REMOVAL_REPORT	5	Raportowanie	Raportowanie usuwania
\$REMOVAL_ACCEPT	6	Odbiory	Odbiory, weryfikacja, poprawki

Wstępna ocena przydatności

W pierwszej kolejności przeprowadzono analizę metod zwalczania, obejmując nią zarówno wymienione w projekcie,

- opryski,
- ścinanie części nadziemnych,
- mazakowanie, 

jak i uzupełniająco inne, które w ostatnim czasie stały się bardziej dostępne:

- iniekcja związków roślinobójczych,
- wykopywanie świdrem,,
- frezowanie.



Ocena wielokryterialna

Wytypowane metody zwalczania poddano analizie wielokryterialnej

Tabela 2 Analiza wielokryterialna metod zwalczania barszczy.

Właściwości metod	Metody założone w projekcie			Metody dodatkowe		
	Oprysk	Mazakowanie	Ścinanie pedów	Wykopywanie	Iniekcja dopędowa	Frezowanie korzenia
Skuteczność						
Skuteczność w przejściowym zniszczeniu barszczy	●●	?	●●	●●●	●	●
Skuteczność w definitywnym zniszczeniu barszczy	x	?	x	●●●	●●●	●
Możliwość zamontowania na systemie UAV	●●●	●●	●●	?	●	●●●
Wydajność	●●●	●	●●●	●	●	●
Średnio	2	0,75	1,75	1,75	1,5	2
Możliwości implementacji						
Dostępność gotowych rozwiązań dla UAV	●●●	x	x	x	x	x
Istnieją niededykowane rozwiązania możliwe do implementacji na UAV	●●	●	●●●	x	●	●●●
Oczekiwana łatwość rozwiązania problemów technicznych	●●●	x	●●	x	●●●	●●
Niski koszt implementacji	●●	●	●●	?	●	●●●
Średnio	2	0,4	1,4	0	1	1,6
Skutki uboczne						
Nieprowadzenie wzrostu ładunku FK w wypadku niepowodzenia zwalczania	x	●	x	●●●	●●●	●●
Brak	●●●	●●	x	x	●	x

Właściwości metod	Metody założone w projekcie			Metody dodatkowe		
	Oprysk	Mazakowanie	Ścinanie pędów	Wykopywanie	Iniekcja dopędowa	Frezowanie korzenia
zanieczyszczenia narzędzi ciecżą oleistą z FK z pędów i liści						
Brak zanieczyszczenia otoczenia substancjami niebezpiecznymi	x	●	●●●	●●●	●	●●●
Brak zniszczenia roślinności w otoczeniu	x	●	●	●●	●●	●
Brak zagrożenia dla obsługi naziemnej	●	●	●	●	●	●
Średnio	0,8	1,2	1	1,8	1,6	1,4
Łącznie	4,8	2,35	4,15	3,55	4,1	5

Z analizy wielokryterialnej wynika, że spośród planowanych do implementacji metod zwalczania mazakowanie wypada zdecydowanie niekorzystniej, niż wszystkie metody alternatywne. W związku z tym, do fazy testów sprzętowych wytypowano 3 metody, które otrzymały najwyższe punktacje: opryski, ścinanie pędów oraz frezowanie korzenia.

Metody testowano począwszy od najwyżej punktowanych w ocenie wielokryterialnej.

Testy sprzętowe

Frezowanie

W ramach testów korzystano z istniejących rozwiązań – wiertarko-wkrętarki z opcją uderzenia o napięciu 18V, prędkości obrotowej do 2300 obr/min z gotowym frezem typu sękownik o szerokości 40mm. Każda próba objęła 5 powtórzeń czynności.



Ilustracja 1 Frez użyty w testach.

Próba nr 1 – frezowanie w roślinności trawiastej

W pierwszej próbie testowano możliwość realizacji frezowania pod naciskiem jedynie własnego ciężaru wiertarki z baterią w glebie ze ściółką i częściami podziemnymi roślin z dużym udziałem traw.



Ilustracja 2 Frezowanie w glebie z runem trawiastym.



Ilustracja 3 Frez owija się liśćmi traw.

Frez zagłębił się łatwo w runie i ściółce, docierając do warstwy mineralnej. W czasie wiercenia w 5 powtórzeniach na 5 owijały się wokół niego liście i wojłok martwych liści traw, uniemożliwiając dalszą pracę.



Ilustracja 4 Frez wymaga ręcznego czyszczenia po jednym zastosowaniu.

Wynik próby uznano za negatywny.

Próba nr 2 – frezowanie w roślinności trawiastej pozbawionej lokalnie ściółki

Frezowanie próbowano zrealizować w roślinności identycznej, jak w próbie 1, ale pozbawionej ściółki.



Ilustracja 5 Frezowanie w roślinności trawiastej pozbawionej ściółki.

Niestety we wszystkich powtórzeniach najmniejszy, nawet przypadkowy kontakt obracającego się frezu z długimi liśćmi roślin trawiastych powoduje natychmiastowe owinięcie się ich wokół frezu i zablokowanie frezu, równoległe z dystorsją osi frezowania.



Ilustracja 6 Dystorsja osi frezowania i owinięcie się liśćmi traw.

Wynik próby – negatywny. Frezowanie w roślinności trawiastej jest możliwe, ale bardzo utrudnione.

Próby nr 3 – frezowanie w roślinności dwuliściennej z dodatkowym dociskiem



Ilustracja 7 Frezowanie w roślinności dwuliściennej.

Frez za każdym razem zagłębiał się w roślinności na pełną głębokość, w 2 powtórzeniach na 5 owijały się wokół niego liście



Ilustracja 8 Niekiedy frez pozostawał jedynie zabrudzony ziemią.

Wynik próby – pozytywny. Frezowanie w glebie jest możliwe, pod warunkiem braku w otoczeniu roślin o długim, ciągnącym się kształcie.

Próba nr 5. Frezowanie w roślinności dwuliściennej z użyciem ciężaru własnego wkrętarki



Ilustracja 9 Frezowanie w roślinności dwuliściennej pod naciskiem masy własnej wkrętarki.

Wynik próby – pozytywny. Frez wkręca się pod własnym ciężarem w glebę piaszczystą w roślinności dwuliściennej.

Próba nr 5. - Frezowanie w części podziemnej rozetki rośliny dwuliściennej chabra nadreńskiego z użyciem ciężaru własnego wkrętarki



Ilustracja 10 Frezowanie korzenia spichrzowego pod rozetką.

Frez zagłębił się na pełną głębokość, ale w 3 powtórzeniach na 5 owinął się ogonkami liściowymi liści rozetki, a w 5 przypadkach na 5 zbaczał z linii frezowania. Korzeń spichrzowy pod rozetką za każdym razem pozostawał nietknięty. Ponadto, przez cały czas konieczne było powstrzymanie powstającego momentu obrotowego.



Ilustracja 11 Nietknięta część podziemna rozetki.

Wynik próby – negatywny – przy frezowaniu z naciskiem równym ciężarowi wkrętarki rozetka nie została wyfrezowana.

Próba 6 – Frezowanie w części podziemnej rozetki rośliny dwuliściennej z użyciem dodatkowej siły



Ilustracja 12 Frezowanie korzenia spichrzowego z użyciem dodatkowej siły.

Pomimo przykładania siły pionowej oraz powstrzymywania momentu obrotowego frez w 5 przypadkach na 5 zbaczał z linii frezowania.

Wynik próby – negatywny. W żadnym przypadku nie udało się rozdrobnić części podziemnej stosując frezowanie od góry.

Wnioski dotyczące frezowania

1. Frezowanie w glebie poprzez warstwę roślinności napotyka na problemy związane z owijaniem się części roślin na frezie, powstawaniem dużego momentu obrotowego, koniecznego do skompensowania momentu obrotowego oraz zbaczeniem z wyznaczonej osi frezowania, niezależnie od przykładanej siły pionowej zwróconej w dół, czy pod własnym ciężarem zestawu do wiercenia czy też większej.

2. Frezowanie nie nadaje się do implementacji na systemach dronowych w pierwszej kolejności.

Cięcie

W tej próbie próbowano przetestować cięcie łodyg roślin za pomocą narzędzia o napędzie elektrycznym, które teoretycznie może być zamontowane na dronie: akumulatorowych pilarek z gładkim ostrzem tnącym o średnicy 85 i 125 mm oraz akumulatorowej piły tarczowej o średnicy ostrza 90mm. Poszczególne czynności powtarzano 5 razy.

Próba nr 1 – cięcie cienkich łodyg roślin pilarką 85mm

Na początek zdecydowano o podjęciu próby cięcia cienkich łodyg roślin, w tym przypadku nawłoci.



Ilustracja 13 Pomyślne ścięcie pędu.

Niestety łodygi odchodziły się w kierunku przeciwnym do punktu przyłożenia ostrza oraz ześlizgiwały się po ostrzu zgodnie z kierunkiem jego obrotu. Dopiero, kiedy pęd po ześlizgnięciu zatrzymał się na osłonie ostrza pilarki, został przecięty.

Próba nr 2 – cięcie cienkich łodyg roślin pilarką 125mm

W próbie wykorzystano pilarkę o prędkości obrotowej 8000 obr./min. I średnicy tarczy 125 mm. Jako roślina testowa służyła bylica pospolita.

Wynik próby był identyczny, jak przy pilarce o mniejszej średnicy. Łodyga była odpychana, po czym ześlizgiwała się i była niekiedy ucinana, kiedy została zablokowana o osłonę ostrza.



Ilustracja 14

Wynik próby – częściowo pozytywny. Większe obroty i prędkość obrotowa ostrza pilarki nie usuwają poprzednich problemów. Warto przetestować urządzenia tnące umożliwiające nagarnianie łądy ku ostrzu tnącemu. Warto też przetestować cięcie na grubszych łądach.

Próba nr 3 – cięcie grubych łąd roślin pilarką 125mm



Ilustracja 15 Cięcie pędu rdestowca pilarką 125 mm.

W próbie, jako model grubej i sztywnej łądy o dużej średnicy użyto rdestowca japońskiego. Przy małej sile docisku, ostrze odmiennie, niż przy łądach cienkich, nie powodowało odchylenia się łądy, natomiast podobnie jak poprzednio, ślizgało się po powierzchni pędu. Przyłożenie dużej siły powodowało zakleszczanie się płaszczyzn cięcia na ostrzu powodując jego zablokowanie.



Ilustracja 16 Zatrzymane ostrze pilarki po zakleszczeniu.

Wynik próby – negatywny. Pilarka nie jest w stanie przeciąć grubej łodygi rośliny z powodu zakleszczania się ostrza. Konieczne jest testowanie innych rozwiązań z ostrzami zębatymi, tworzącymi grubszą przestrzeń cięcia.

Próba nr 4 – cięcie cienkich łodyg roślin piłą tarczową 85mm



Ilustracja 17 Akumulatorowa piła tarczowa.

W próbie wykorzystano piłę tarczową o średnicy ostrza 85 mm i prędkości obrotowej 2300 obr./min.

Wszystkie powtórzenia cięcia cienkich łodyg były udane.

Wynik próby – pozytywny. Piła tarczowa nie wykazuje mankamentów pilarki. Trzeba przetestować ją na roślinach o większej średnicy.



Ilustracja 18 Akumulatorowa piła tarczowa pomyślnie ścięła cienką łodygę rośliny.

Próba nr 5 – cięcie średnich i grubych łodyg roślin piłą tarczową 85mm



Ilustracja 19 Próba cięcia piłą tarczową łodygi średnio grubej.

W próbie wykorzystano podobny model grubszych łodyg, jak przy pilarce – rdestowiec japoński.

Niestety grube łodygi, mające też większą sztywność, nie pozwoliły na wystarczające zagłębienie się ostrza piły na tyle, by je przeciąć. Nie dochodziło jednak do zakleszczenia się ostrza w łodydze.



Ilustracja 20 Pomyślne przecięcie średniej łodygi piłą 85mm.



Ilustracja 21: Brak możliwości przecięcia grubej łodygi piłą 85mm.

Wynik próby – częściowo pozytywny. Piła pomyślnie tnie grube łodygi o średnicy mniejszej, niż wysięg ostrza poza płaszczyznę ogranicznika.

Wnioski dotyczące cięcia

1. Cięcie łodyg o różnej grubości może być realizowane za pomocą narzędzi akumulatorowych, nadających się do zamontowania na dronie.
2. Narzędzia o ostrzach zębatych lepiej nadają się do cięcia, niż ostrza gładkie.
3. Wysięg ostrza, dający możliwość przecięcia łodygi lub ogonka liściowego barszczu powinien mieć ok. 50mm.
4. Należy rozważyć możliwość wykonania narzędzi z użyciem technologii o zmniejszonej masie, np. z włókna węglowego, aby zmniejszyć masę własną i zwiększyć czas pracy na baterii.

Rozwiązanie przeznaczone do montowania na dronie

Dalsze próby przeprowadzono z użyciem specjalnie skonstruowanej głowicy tnącej o lekkiej konstrukcji, przeznaczonej do montowania na dronie.

Próba nr 1 – cięcie cienkich łądyg

Próby przeprowadzono z użyciem cienkich łądyg oleśnika górskiego.

Pierwsza próba przeprowadzona z użyciem lekkiej głowicy tnącej zakończyła się negatywnie – ostrze spowodowało spalenie się silnika z powodu zbyt późnego odłączenia zasilania.

Wynik próby – negatywny. Konieczne przeprojektowanie umożliwiające odejście łądygi od ostrza w razie zakleszczenia.

Próba nr 2 – cięcie cienkich łądyg przeprojektowaną głowicą.

Po przeprojektowaniu głowica powinna umożliwić bezpieczne cięcie roślin.



Ilustracja 22: Lekka głowica tnąca po przeprojektowaniu.

Próba nr 2 – cięcie cienkich łądyg przeprojektowaną głowicą

Po przeprojektowaniu głowica pomyślnie cięła cienkie łądygi roślin.



Ilustracja 24 Pomyślny wynik próby.
Ilustracja 25 Cięcie średnio grubych łodyg przeprojektowaną głowicą

Wnioski – nowy kształt osłony zabezpiecza przed zakleszczaniem się ostrza.

Próba nr 3 – cięcie średnio grubych łodyg przeprojektowaną głowicą



Ilustracja 25

Cięcie średnio grubych łodyg głowicą przyniosło mieszane wyniki. W części powtórzeń głowica ślizgała się po powierzchni łodygi.


W innych powtórzeniach pomyślnie przecięła łodygę, pod warunkiem przyłożenia większej siły bocznej skierowanej w ku łodydze. Powodowało to jednak zmniejszenie się prędkości obrotowej ostrza i groziło zakleszczeniem.



Ilustracja 26

Wynik próby – mieszany. Lekka głowica może ciąć średniej grubości pędy roślin. Testy na grubych łodygach powinny być wykonane w przyszłości po zastosowaniu w głowicy silników o większej mocy, sprzęgła i ewentualnie ostrzy stalowych z nakładkami pogrubiającymi, które będą zwiększały szerokość szczeliny roboczej ostrza tnącego i przeciwdziałały zakleszczeniom.

Opryski

W ramach testów sprzętowych wykorzystano gotową fragment gotowej implementacji urządzenia do oprysku z dronów - #Agras T16 - Agricultural Spraying Drone.  układ tryskacza składa się z pompki BLDC, regulatora jej prędkości obrotowej ESC wraz z czujnikiem pustego zbiornika oraz ramiona z zamontowanymi tryskaczami. Długość ramion to 180 cm. Podłączono 4 szt tryskaczy.



Ilustracja 27

Celem było sprawdzenie, ile czasu zajmie opróżnienie 0,25 wody. Po uruchomieniu pompy na bieg maksymalny opróżnienie 0,25l wody zajęło 38s. Ponieważ całość podwozia i zbiornika ma masę 1,5 kg, to łączna masa z pełnym zbiornikiem (10 l) osiągnie 11,5 kg. Łącznie z masą części napędowej drona (6kg) da to masę 17,5 kg. Po doliczeniu 3 szt baterii (każda po 2,5 kg) daje łączną masę startową 25 kg. Trzeba zauważyć że podczas startu dron będzie ważył 25 kg ale podczas lądowania już tylko 15 kg. Maksymalny czas lotu z masą 25 kg to 21 minut (15 m/s) a przy masie 15 kg to już 41 minut. Należy założyć że łączny czas misji będzie wynosił ok 30 minut. Pamiętając że długość ramion to 180 cm a szerokość tryskania to 3m, podczas lotu możliwe będzie opryskanie obszaru o szerokości 3m i długości $30 * 60 * 15 = 27$ km. Odliczając zakręty (dron wtedy zwalnia) będzie to ok 23 km, co przekłada się na obszar 81 ha. Przy założeniu poprawek na dodatkowe zaburzenia lotu, można założyć, że całkowite opróżnienie zbiornika cieczy roboczej umożliwi oprysk średnio ok. 70 ha, a przy obfitym zraszaniu (10 m/s) to $\frac{2}{3}$ tej wartości czyli ok. 47 ha.

Wynik próby – pozytywny. Przy zastosowaniu posiadanych dronów i zestawu do oprysków można będzie pomyślnie realizować z drona punktowe opryski nawet dużych stanowisk barszczu.

Wnioski końcowe

1. Na podstawie analizy wielokryterialnej trzy spośród wszystkich rozpatrywanych metod: frezowanie, ścinanie i opryskiwanie uznano za nadające się do przetestowania z użyciem technologii akumulatorowych nadających się do zamontowania na dronie.
2. Frezowanie okazało się nieskuteczne wobec części podziemnych roślin, towarzyszyło mu owijanie się frezu liśćmi a głowica zbaczała z wyznaczonej trasy frezowania. Jedynie frezowanie boczne z przyłożeniem ukośnym i dynamicznym kierowaniem frezu w kierunku części podziemnej kończyło się sukcesem. Wymagałoby to jednak montowania frezu na wysięgniku mającym charakter gimbała, mogącego dodatkowo generować siłę docisku oraz przeciwdziałania momentowi obrotowemu. Na chwilę obecną nie jest to rozwiązanie opłacalne. Można również spróbować wykorzystać frezy o innej konstrukcji.
3. Ścinanie części nadziemnych roślin można realizować z użyciem zębatych elementów tnących, jednak problem stanowi zakleszczanie się ostrza, powodujące ryzyko spalenia się silnika, oraz odpychania się roślin. Lekka głowica tnąca może ciąć małe i średnie łodygi roślin, ale przed testami na grubych łodygach wskazane jest zamontowanie silnika o większej mocy, technologii umożliwiającej wysprzęglenie w razie zakleszczenia oraz ostrzy metalowych z nakładkami poszerzającymi grubość szczeliny cięcia i przeciwdziałających zakleszczeniu.
4. Oprysk z wykorzystaniem elementów dostępnej komercyjnie technologii okazał się najłatwiejszy w implementacji i może w zasadzie zostać wykorzystany jako element systemu. Może być stosowany do opryskiwania stanowisk barszczu o powierzchni do 70 ha w czasie jednego lotu, w zależności od zadanego wydatku cieczy roboczej. Z uwagi na brak możliwości precyzyjnego lokalizowania aplikacji cieczy roboczej wskazane jest stosowanie jej w gęstych, zwartych płatach lub z wykorzystaniem substancji czynnych o niskim poziomie szkodliwości.



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Raport sprzętowy

Jednego z wypożyczonych dronów przystosowaliśmy do lotów z kamerami.
Oto on:



widok z przodu



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



widok prawego boku



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



widok z lewego boku




widok z tyłu: przerobiona obudowa akumulatorów umożliwiająca loty zimą.



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok z góry






Fundusze Europejskie
Inteligentny Rozwój


Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Końcówka ramienia, silniki regulatory oraz oświetlenie nawigacyjne



Lewy bok zbliżenie, widać wiązkę do gimbału oraz wyjścia anten do modemu



Przednia osłona kamery FPV



Jako najbardziej reprezentatywne wybrano 46 stanowiska w okolicy Gorzowa Wlk. i Miłkowa o średniej powierzchni ok 25 ha każde. Łącznie 1150 ha.

Wykonano loty kalibracyjne i 60 nalogów testowych po ok. 20 min każdy. Potem wykonano serię 200 nalogów po ok. 25 min każdy celem pobrania danych. W sumie wszystkich lotów wykonano 387 o łącznym czasie (razem z lotami kalibracyjnymi) ok 7.000 minut (ok. 117 godzin).

W między czasie platforma była 4 razy serwisowana (silniki, śmigła, baterie itp.)

Wykonano ok. 200.000 zdjęć kamerą SONY A7R3 oraz ok 1.000.000 zdjęć kamerą RedEdge-M.

Do każdej serii zdjęć dołączono plik z geolokacjami zdjęć.

Złożono 82 ortofotomapy z kamery SONY A7R3 oraz 78 z kamery RedEdge-M



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Platforma do niszczenia Barszczy



Widok z tyłu widać przerobioną obudowę na baterie (max 4 szt) do lotów w zimę



Widok lewej strony



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok z przodu



Widok z prawej strony



Fundusze
Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok z przodu z zamontowanym zestawem do oprysków. Nogi na pierwszych testach pozostały aby chronić dość delikatny zbiornik i pompę



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Przód zbiornika z wlewem z tyłu widać regulator obrotów pompy



Wykonane mocowanie ramiona do oprysków i jego mocowanie do stałego podwozia



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok na poziomy zawias ramienia i wewnętrzny tryskacz z zieloną głowicą



Widok na zewnętrzny tryskacz (same tryskacze to element kupiony)



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok ramienia złożonego na poziomym zawiasie



Widok całego ramienia złożonego na pionowym zawiasie do transportu




Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Widok pod zbiornik: widać pompę wysokowydajną i główny zawór ciecży



U góry zbiornika (gdzie oryginalnie powinny być baterie) umocowaliśmy regulator dla pompy

Z takim zestawem przeprowadzono 82 loty (po 30 minut każdy)

Latano nad 4 lokacjami (Górki, Czechów, Miłków oraz Janczewo)



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Podczas testowych lotów (regulacyjnych) ustalono właściwy przepływ cieczy oraz typ dyszy (zielona).

Każdą lokację oblatano 20 razy przy różnych warunkach: rano, południe i wieczór, wysokość nad łanem 5 10 20 i 30 metrów oraz z różnymi kierunkami wiatru

Najlepsze rezultaty daje lot na małej wysokości do 10 m nad łanem, rano kiedy nie ma jeszcze wiatru.

W sumie opryskaliśmy ok 2.000 ha.

Wnioski: Metoda skuteczna przy niskich nalotach i polecana w szczególności dla miejsc trudno dostępnych.

Do przeprowadzenia testów weryfikujących poprawność systemu jako całość, wybraliśmy dwie lokacje Miłków oraz Górki. Naloty polegały na wypuszczeniu w trybie automatycznym pierwszej platformy i pobranie materiałów do analizy. Kiedy algorytm zainstalowany na komputerze wyznaczył stanowiska do niszczenia wypuszczaliśmy również w trybie automatycznym drugiego drona do oprysków. Zazwyczaj badany obszar nie był cały pokryty barszczem więc druga maszyna wykonywała krótszy lot w konfiguracji dwie baterie i 10l płynu co starczało na bezpieczny 15 minutowy lot podczas którego opryskiwaliśmy wyznaczone stanowiska.

Z uwagi na Covid-19 udało nam się wykonać tylko 32 loty z których:

1. 26 zakończyło się 100% wynikiem (wszystkie barszcze znalezione pierwszą platformą opryskaliśmy)
2. 3 loty w których nie opryskaliśmy tylko część (76%, 88% i 82%) z uwagi na ilość barszczy i zbyt mały czas lotu platformy opryskowej
3. 2 loty opryskowe się nie odbyły z uwagi na brak znalezionych barszczy
4. 1 lot się nie odbył ze względu na pogodę – zaczęło padać

Skuteczność oprysków badaliśmy oceniając naocznie czy odpowiednie partie terenu są opryskane (ciecz miała czerwony barwnik spożywczy biodegradowalny).



Fundusze Europejskie
Inteligentny Rozwój

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



Podsumowanie całego projektu

Współpraca na poziomie etapu pierwszego i drugiego, czyli wyznaczanie za pomocą algorytmu z pierwszego etapu stanowisk barszczy i niszczenie ich opryskami (etap 2) wypadła dobrze. Wyznaczanie miejsc do oprysków na podstawie danych z algorytmu wyszło na poziomie ponad 94%.

Jak to zbadaliśmy?

Pozwoliliśmy automatycznie działać algorytmowi i za jego pomocą zostały wyznaczone stanowiska do oprysków. Podczas wizji lokalnej powierzchnie do oprysków pokrywały 98% miejsc faktycznych stanowisk barszczy, a w 4% pokrywały tereny całkowicie bez barszczy. Uznaliśmy więc skuteczność na 94%.

Potem startował dron opryskowy i leciał by wykonać zabiegi opryskowe. Jakość oprysków ocenialiśmy naocznie. Wykonano 32 loty z których:

1. 26 zakończyło się 100% wynikiem (wszystkie barszcze znalezione pierwszą platformą opryskaliśmy)
2. 3 loty w których nie opryskaliśmy tylko część (76%, 88% i 82%) z uwagi na ilość barszczy i zbyt mały czas lotu platformy opryskowej
3. 2 loty opryskowe się nie odbyły z uwagi na brak znalezionych barszczy
4. 1 lot się nie odbył ze względu na pogodę – zaczęło padać.

Wnioski są następujące:

1. 100% pokrycie opryskami nastąpiło w przypadku 81,25% stanowisk.
2. 100% działanie (uwzględniając brak lotów z uwagi na brak barszczy do niszczenie) nastąpiło w przypadku 87,5% stanowisk
3. W 3,125% przypadków lot się nie odbył (w sensie pierwszy lot się odbył a drugi nie)
4. W 9,375% przypadków wykonano i pierwszy i drugi lot, ale drugi lot nie pokrył całości stanowisk (średnio 82%) z powodu braku czasu lotu (koniec pojemności baterii)
5. Jeśli dodać częściowe pokrycie stanowisk płynem, należ proporcjonalnie dodać do całkowitej skuteczności 87,5% jeszcze 82% z 9,375% skuteczności częściowej czyli 7,68%. Razem więc skuteczność pracy powiązanej pierwszego i drugiego etapu to 95,18%.
6. System jako całość nadaje się do implementowania jako usługa biznesowa.

**INFORMACJA KOŃCOWA Z REALIZACJI PROJEKTU
W RAMACH DZIAŁANIA POIR.01.01.01 PROGRAMU OPERACYJNEGO INTELIGENTNY
ROZWÓJ**

Data wpływu informacji:	
Korekta Informacji końcowej¹ nr	

1. Informacja końcowa

- A. składana w sytuacji osiągnięcia oczekiwanych wyników prac B+R oraz zasadności realizacji części wdrożeniowej projektu** ■
- B. składana w sytuacji, gdy dalsze prowadzenie badań przemysłowych lub prac rozwojowych nie doprowadzi do osiągnięcia zakładanych wyników albo gdy po zakończeniu ww. badań lub prac wdrożenie ich wyników jest bezcelowe** □

Powód rezygnacji z realizacji części badawczej projektu / wdrażania wyników prac B+R:

1. nieosiągnięcie kamienia milowego □
2. dalsze badania przemysłowe lub prace rozwojowe nie doprowadzą do osiągnięcia zakładanych wyników □
3. brak opłacalności wdrożenia □
4. inne □

należy podać jakie.....

2. Dane o projekcie

Nr umowy o dofinansowanie: **POIR.01.01.01-00-0189/17**

Tytuł projektu: „**Prace badawczo-rozwojowe nad zautomatyzowaniem procesu inwentaryzacji i niszczenia Barszczu Sosnowskiego Heracleum Sosnowskyi i Barszczu Mantegazziego Heracleum Mantegazzianum za pomocą systemów bezzałogowych**”

Data rozpoczęcia realizacji projektu²: 2018-01-01

Data zakończenia realizacji projektu³: 2021-03-31

¹W przypadku przekazania przez IP uwag do Informacji końcowej Beneficjent składa korektę Informacji końcowej. Korekta sporządzana jest również w przypadku, gdy Beneficjent uzna za konieczne wprowadzenie zmian do złożonej już Informacji końcowej.

² Zgodnie z umową uwzględniającą wszystkie aneksy.

³ Zgodnie z umową uwzględniającą wszystkie aneksy.

3. DANE BENEFICJENTA:

Nazwa **NETWORK PARTNERS Tomasz Machnicki Sp.J.**

Dane osoby sporządzającej informację:

Imię i nazwisko: **mgr inż. Jacek Jabłoński**

Telefon **787-999-808** e-mail: **jacek.jablonski@networkpartners.pl**

4. KONSORCJANCI I PODWYKONAWCY WSPÓŁPRACUJĄCY PRZY REALIZACJI PROJEKTU (jeśli dotyczy):

Należy wskazać pełne nazwy Konsorcjantów oraz Podwykonawców, którzy brali udział w realizacji Projektu w zakresie prowadzenia prac badawczych.

Nie dotyczy

5. INFORMACJA O WYKONANYCH PRACACH BADAWCZYCH I ICH WYNIKACH

5.1. OPIS PRZEPROWADZONYCH PRAC B+R W PROJEKCIE

*W tabeli w kolumnie nr 2 należy wykazać wszystkie etapy badawcze zaplanowane do zrealizowania w projekcie (przez Beneficjenta i Konsorcjanta/ów) zgodnie z wnioskiem o dofinansowanie, z uwzględnieniem umowy o dofinansowanie oraz wszystkich aneksów. W kolumnie nr 3 należy opisać prace B+R przeprowadzone w ramach poszczególnych etapów badawczych (wskazując jednocześnie podmiot wykonujący dany etap/część etapu – Partner/podwykonawcę). **Nie należy** wymieniać zadań niezwiązanych z pracami badawczo-rozwojowymi, np. zadań z zakresu zarządzania projektem, promocją itp.*

W przypadku niezrealizowania zadania badawczego lub jego niepełnego wykonania, należy jedynie wskazać ten fakt, a szczegółowy opis przyczyn zamieścić w pkt. 5.2.

Maksymalna liczba znaków opisu jednego zadania badawczego nie może przekraczać 3000 znaków.

Lp	Nr i nazwa zadania badawczego	Opis przeprowadzonych prac B+R
1.	2.	3.
1	Etap I Przeprowadzenie prac badawczych nad opracowaniem algorytmu do automatyzacji rozpoznania barszczy kaukaskich przy pomocy systemów bezzałogowych i	Lista wykonanych prac w ramach pierwszego etapu projektu: 1. Opracowanie zamówień publicznych 1.1. Opracowano trzy zamówienia publiczne. 1.2. Wybrano najkorzystniejsze oferty 1.3. Podpisano umowy 1.4. Przyjęto sprzęt na stan 2. Kalibracja i dostosowanie dronów do potrzeb projektu 2.1. Instalacja sprzętu komputerowego 2.2. Instalacja oprogramowania na w/w 2.3. Uruchomienie sieci i przetestowanie działania

	kamer wielospektralnych	<p>2.4. Odbiór dwóch dronów</p> <p>2.5. Dostosowanie ich do potrzeb projektu</p> <p>3. Wybór stanowisk do oblotu</p> <p>3.1. Wybrano stanowiska w okolicy Gorzowa Wlkp. jako najbardziej reprezentatywne</p> <p>3.2. Ilość stanowisk 46 o łącznej powierzchni ok 25 ha każde. Łącznie 1150 ha</p> <p>3.3. Sprawdzono również inne stanowiska, w sumie 34 lokalizacje</p> <p>4. Pierwsze loty kalibracyjne</p> <p>4.1. Wykonano serię nalogów celem ustalenia wysokości AGL nalogów i typu obiektywu oraz prędkości lotów</p> <p>4.2. Za najbardziej optymalne warunki uznano:</p> <p>4.2.1. Wysokość 100m AGL</p> <p>4.2.2. Prędkość poziomą 10 m/s</p> <p>4.2.3. Obiektyw 55 mm</p> <p>5. Wykonanie serii nalogów testowych</p> <p>5.1. Wykonano serię 60 nalogów testowych</p> <p>5.2. Wyregulowano autopilota</p> <p>5.3. Ustalono parametry konfiguracyjne aparatu</p> <p>6. Składanie mozaik i analiza danych</p> <p>6.1. Złożono mozaiki z nalogów testowych</p> <p>6.2. Zunifikowano proces ich tworzenia</p> <p>6.3. Przetestowano 4 aplikacje do ich tworzenia (AgiSoft, Pix4D, EnsoMOSAIC, APS)</p> <p>6.4. Wybrano Pix4D jako najkorzystniejsza</p> <p>7. Ustalenie procedur nalogów docelowych</p> <p>7.1. Ustalono logistykę wyboru miejsc startowych</p> <p>7.2. Ustalono listę sprzętu potrzebnego podczas nalogów</p> <p>7.3. Ustalono procedury logistyczne bytowania</p> <p>8. Wykonanie nalogów nad stanowiskami docelowymi</p> <p>8.1. Zaplanowano 283 nalogy</p> <p>8.2. Wykonano plany misji do tychże nalogów</p> <p>8.3. Wykonano serię 200 nalogów</p> <p>8.4. Nalogy wykonano nad 15 różnymi lokalizacjami</p> <p>8.5. Wykonano 200.000 zdjęć kamerą SONY A7R3 oraz ok 1.000.000 zdjęć kamerą RedEdge-M</p> <p>8.6. Do każdej serii zdjęć dołączono plik z geolokacjami</p> <p>8.7. Złożono 82 mozaiki z kamery SONY A7R3 oraz 78 z kamery RedEdge-M</p> <p>9. Analiza danych</p> <p>9.1. Zespół specjalistów przeprowadził analizę tych zdjęć oraz wizje lokalne - raport</p> <p>10. Ocena efektywności</p> <p>10.1. Współczynnik wykonania nalogów do zaplanowanych 70%</p> <p>10.2. Współczynnik wykonania przydatnego materiału fotograficznego 95%</p>
2	Etap II - Przeprowadzenie prac badawczych nad opracowaniem algorytmu niszczenia	<p>1) Badania nad metodami niszczenia oraz ich funkcjonalnością i skutecznością w walce z barszczem kaukaskim.</p> <p>2) Opracowanie systemu precyzyjnego utrzymywania wysokości nad łanem roślin i/lub nad glebą.</p>

barszczy kaukaskich różnymi metodami za pomocą systemów bezzałogowych

- 3) Automatyczna klasyfikacja odpowiedniej metody niszczenia na podstawie wyników I etapu;
- 4) Testowanie opracowanych metod w warunkach laboratoryjnych.
- 5) Loty treningowe w celu ustalenia procedur stosowania opracowanych metod niszczenia barszczy w terenie.

Wstępna ocena przydatności

W pierwszej kolejności przeprowadzono analizę metod zwalczania, obejmując nią zarówno wymienione w projekcie, opryski, ścinanie części nadziemnych, mazakowanie, jak i uzupełniająco inne, które w ostatnim czasie stały się bardziej dostępne: iniekcja związków roślinobójczych, wykopywanie świdrem, frezowanie.

Ocena wielokryterialna

Wytypowane metody zwalczania poddano analizie wielokryterialnej

Z analizy wielokryterialnej wynika, że spośród planowanych do implementacji metod zwalczania mazakowanie wypada zdecydowanie niekorzystniej, niż wszystkie metody alternatywne. W związku z tym, do fazy testów sprzętowych wytypowano 3 metody, które otrzymały najwyższe punktacje: opryski, ścinanie pędów oraz frezowanie korzenia. Metody testowano począwszy od najwyższej punktowanej w ocenie wielokryterialnej.

Opracowany algorytm umożliwi zwalczanie niepożądanych roślin z wykorzystaniem systemów bezzałogowych poprzez ich skaszanie, mazakowanie, iniekcję oraz opryski. W toku badań uzyskano maksymalną skuteczność niszczenia barszczy metodą opryskową. Na polu testowym o powierzchni 1h pokrytej barszczami w ok 60% przeprowadzono nalotu z tryskaczami. Uzyskano powtarzalne wyniki zwalczania 93% oraz uszkodzenia roślin tła ok 7%.

Odrzucono metody niszczenia:

Mazakowanie: zbyt długi czas niszczenia (ok 4 minut na jedną roślinę)

Iniekcję: zbyt długi czas niszczenia (ok 17 minut na jedną roślinę)

Ścinanie: bardzo trudne do implementacji na statkach BSP oraz długi czas ścinania pojedynczej rośliny i niebezpieczeństwo uszkodzenia drona.

Wybrano jako najkorzystniejszą metodę OPRYSKI Osiągnięto wynik lepszy niż zakładano we wniosku o dofinansowanie. We wniosku zakładano, że algorytm zostanie uznany za skuteczny, gdy osiągnie wynik na poziomie 85%.

(Szczegółowy opis dostępny w raporcie z badań).

PR-NWF-01/Z23

3	<p>Etap III - Integracja opracowanych algorytmów, połączenie elementów składowych w jeden, złożony i zautomatyzowany system, umożliwiający jednoczesny proces inwentaryzacji i niszczenia barszczy kaukaskich za pomocą systemów bezzałogowych</p>	<p>Pierwsze działania tego etapu dotyczyły udoskonalenia głowic niszczących, tak aby były bardziej kompaktowymi. Podjęto próby połączenia wszystkich w jedną zamienną w szybki sposób. Założeniem było aby głowice stosujące płyny (czyli do mazakowanie, iniekcji i oprysków) ostatecznie były połączone w jedną, natomiast głowica koszącą pozostawiona niezależnie.</p> <p>W dalszej kolejności przewidziano prace nad automatycznym tworzeniem planu lotu na potrzebę niszczenia roślin, z wykorzystaniem danych pozyskanych automatycznie z inwentaryzacji za pomocą UAV. Ponieważ drony wykorzystane do inwentaryzacji są inaczej wyposażane i konstruowane niż drony do niszczenia, do wykonania pełnej usługi według opracowanych algorytmów potrzebne były dwie floty.</p> <p>Współpraca na poziomie etapu pierwszego i drugiego, czyli wyznaczanie za pomocą algorytmu z pierwszego etapu stanowisk barszczy i niszczenie ich opryskami (etap 2) wypadła dobrze. Wyznaczanie miejsc do oprysków na podstawie danych z algorytmu wyszło na poziomie ponad 94%.</p> <p>Weryfikacja nastąpiła poprzez automatyczne działanie algorytmu, za pomocą którego wyznaczone zostały stanowiska do oprysków. Podczas wizji lokalnej powierzchnie do oprysków pokrywały 98% miejsc faktycznych stanowisk barszczy, a w 4% pokrywały tereny całkowicie bez barszczy. Uznaliśmy więc skuteczność na 94%.</p> <p>(Szczegółowy opis dostępny w raporcie z badań).</p>
---	--	---

5.2. OPIS ZAKRESU, PRZYCZYN I SKUTKÓW EWENTUALNEGO NIEPEŁNEGO WYKONANIA ZADAŃ BADAWCZYCH (jeśli dotyczy)

W przypadku, gdy nie zrealizowano wszystkich etapów prac określonych we wniosku o dofinansowanie lub etapy prac wykonano w niepełnym zakresie (z uwzględnieniem umowy o dofinansowanie oraz wszystkich aneksów), należy szczegółowo opisać zakres, przyczyny i ewentualne skutki niezrealizowania etapów lub niepełnego wykonania etapów prac, w szczególności w odniesieniu do założonych celów projektu. Zgodnie ze wskazaniem zawartym w kolumnie nr 3 w tabeli w pkt. 5.1.

Nie dotyczy, projekt został zrealizowany.

5.3. WYKAZ DOKUMENTÓW POTWIERDZAJĄCYCH PRZEPROWADZENIE ORAZ WYNIKI PRAC B+R

Należy wymienić dokumenty potwierdzające przeprowadzenie badań przemysłowych, prac rozwojowych i prac przedwdrożeniowych (jeśli dotyczy) oraz dokumenty potwierdzające ich wyniki (przykładowo księgi badań, plany badań, terminarze badań, wyniki laboratoriów analitycznych, certyfikacje, akredytacje, zgłoszenia patentowe, dokumentacja techniczna, raporty/sprawozdania z prac etc.).

Dodatkowo w kolumnie nr 4 należy zamieścić opis dokumentu, jeśli z jego nazwy nie wynika, jakich prac B+R dotyczy.

Uwaga:

W trakcie oceny eksperckiej na zakończenie projektu, mającej na celu weryfikację i potwierdzenie zrealizowania umowy o dofinansowanie, Beneficjent zobowiązany jest do dostarczenia dokumentów (w wersji elektronicznej na płycie CD) potwierdzających przeprowadzenie prac B+R wymienionych w tabeli oraz ich wyniki.

Na żądanie eksperta Beneficjent będzie zobowiązany do dostarczenia również innych materiałów (w wersji elektronicznej), niezbędnych do weryfikacji prac wykonanych w ramach projektu.

Lp.	Nazwa dokumentu	Nr ewidencyjny (jeśli dotyczy)	Opis
1.	2.	3.	4.
1.	SPRAWOZDANIE Z PRAC BADAWCZO – ROZWOJOWYCH W PROJEKCIE „Prace badawczo-rozwojowe nad zautomatyzowaniem procesu inwentaryzacji i niszczenia Barszczu Sosnowskiego Heracleum Sosnowskyi i Barszczu Mantegazziego Heracleum Mantegazzianum za pomocą systemów bezzałogowych”		Raport szczegółowo opisuje poszczególne etapy projektu, sposoby ich realizacji oraz wyniki tych prac.

5.4. OPIS UZYSKANYCH WYNIKÓW PRAC B+R

Należy wskazać i opisać uzyskane wyniki prac B+R. W przypadku, gdy uzyskane dotychczas wyniki prac B+R wskazują na bezcelowość ich kontynuacji bądź wdrożenia, należy podać szczegółową argumentację przemawiającą za zaprzestaniem prowadzenia prac B+R bądź zaniechaniem wdrożenia ich wyników. Opis nie powinien przekraczać **12000 znaków**.

Podane informacje będą podstawą dla eksperta do stwierdzenia czy brak zasadności kontynuacji projektu jest wynikiem okoliczności niezależnych od Beneficjenta (przy zachowaniu przez niego należytej staranności oraz postępowaniu zgodnie z umową o dofinansowanie przy realizacji projektu).

Projekt został zrealizowany.

5.5 OPIS PRAC PRZEDWDROŻENIOWYCH (jeśli dotyczy)

Nie dotyczy

6. STOPIEŃ I SPOSÓB REALIZACJI ZAŁOŻONYCH CELÓW PROJEKTU

*W odniesieniu do prac badawczych opisanych w pkt. 5.1 oraz ich wyników wskazanych w pkt. 5.4 należy określić, jak realizacja poszczególnych etapów przyczyniła się do osiągnięcia celów projektu zdefiniowanych we wniosku o dofinansowanie. Należy wskazać **stopień realizacji** tych celów oraz powody ewentualnego nieosiągnięcia danego celu/częściowego osiągnięcia danego celu.*

W wyniku przeprowadzonych prac badawczo-rozwojowych powstał kompletny system wraz z raportem i wynikami z oblotów, umożliwiający świadczenie usługi inwentaryzacji i niszczenia barszczy kaukaskich za pomocą systemów dronowych. Zautomatyzowany proces inwentaryzacji i niszczenia umożliwia skuteczność na poziomie powyżej 94%.

7. PRZYCZYNY NIEOSIĄGNIĘCIA WARTOŚCI DOCELOWYCH WSKAŹNIKÓW PRODUKTU (jeśli dotyczy)

Bazując na informacjach zawartych we wniosku o płatność końcową, należy odnieść się do wszystkich wskaźników produktu, które nie zostały zrealizowane w 100% zgodnie z umową o dofinansowanie (z uwzględnieniem ostatniego aneksu zawierającego zmiany umowy w zakresie wielkości wartości docelowych wskaźników). Należy opisać przyczyny nieosiągnięcia wartości docelowych tych wskaźników.

*Opis powinien obejmować **nie więcej niż 5000 znaków**.*

Opis przyczyn nieosiągnięcia docelowych wskaźników produktu: nie dotyczy, wszystkie wskaźniki produktu zostały zrealizowane.

8. PRZYCZYNY BRAKU CELOWOŚCI KONTYNUACJI REALIZACJI CZĘŚCI BADAWCZEJ PROJEKTU BĄDŹ WDROŻENIA WYNIKÓW PRAC B+R (jeśli dotyczy)

W przypadku rezygnacji z dalszego prowadzenia prac B+R bądź wdrożenia wyników prac B+R ze względów ekonomicznych (brak opłacalności wdrożenia) Beneficjent zobowiązany jest przedstawić szczegółową argumentację uzasadniającą swoją decyzję w kontekście (jeśli dotyczy):

- rozwoju oferty konkurencji, który nastąpił od czasu złożenia wniosku o dofinansowanie,
- możliwej do uzyskania ceny (z uwzględnieniem kosztów wdrożenia, produkcji, marży),
- cech funkcjonalnych przedmiotu wdrożenia w zestawieniu z potrzebami potencjalnych odbiorców,
- innych aspektów decydujących o spodziewanym niepowodzeniu komercjalizacji wyników projektu.

PR-NWF-01/Z23

Opis nie powinien przekraczać **15000 znaków**.

Podane informacje będą podstawą dla eksperta do stwierdzenia, czy brak zasadności kontynuacji projektu jest wynikiem okoliczności niezależnych od Beneficjenta (przy zachowaniu przez niego należytej staranności oraz postępowaniu zgodnie z umową o dofinansowanie przy realizacji projektu).

Nie dotyczy

9. WYKAZ PROTOTYPÓW/INSTALACJI PILOTAŻOWYCH/DEMONSTRATORÓW WYTWORZONYCH W PROJEKCIE ORAZ SPOSÓB ICH WYKORZYSTANIA

W pkt. 9 należy wskazać, czy w wyniku realizacji projektu wytworzony został prototyp/installacja pilotażowa etc. (pkt 9.1) oraz opisać przewidywany sposób wykorzystania prototypu w okresie trwałości projektu (pkt 9.2).

9.1. Czy w wyniku realizacji projektu wytworzony został prototyp/installacja pilotażowa/demonstrator?

TAK

NIE

9.2. Opis wykorzystania wytworzonego w projekcie prototypu/installacji pilotażowej/demonstratora w okresie trwałości projektu (jeśli dotyczy)

W związku z tym, że prototyp systemu został opracowany w oparciu o aparaturę sprzętową wynajętą na okres realizacji projektu nie będzie on wykorzystywany w okresie trwałości projektu.

10. WYKAZ PRZEPROWADZONYCH KONTROLI REALIZACJI PROJEKTU

W tabeli należy zaznaczyć (znakiem „X”) wszystkie przeprowadzone kontrole w danym roku, których przedmiotem był projekt.

W przypadku kontroli przeprowadzonej przez daną instytucję dokonującą kontroli więcej niż jeden raz w danym roku należy wskazać liczbę przeprowadzonych kontroli projektu w tym roku (np. w przypadku przeprowadzonych przez IP w danym roku dwóch kontroli na miejscu, we właściwej komórce należy wskazać liczbę „2”).

Wpisanie w daną komórkę znaku „X” oznacza, że kontrola została przeprowadzona przez daną instytucję w tym roku tylko raz.

Uwaga:

W tabeli nie należy wykazywać kontroli/weryfikacji dokumentacji finansowej przeprowadzanej na zlecenie NCBR ani wizyt monitorujących przeprowadzanych przez pracowników NCBR w trakcie realizacji projektu.

Wykaz przeprowadzonych kontroli projektu

NAZWA INSTYTUCJI DOKONUJĄCEJ KONTROLI	2017	2018	2019	2020	2021	2022
Instytucja Pośrednicząca (NCBR)		x	x			
Instytucja Zarządzająca (MliR)						
Urząd Kontroli Skarbowej			x			
Europejski Trybunał Obrachunkowy						
Komisja Europejska						
Inny podmiot kontrolujący						

11. SPOSOBY UPOWSZECHNIANIA WYNIKÓW PROJEKTU, PROMOCJI - np. publikacje w czasopismach recenzowanych (należy podać: nazwisko i imię autora, tytuł publikacji, "tytuł czasopisma" rok wydania, numer czasopisma, numery stron); wystąpienia konferencyjne i seminaria (należy podać: nazwisko i imię autora, tytuł wystąpienia, nazwa konferencji, miejsce konferencji, referat/plakat); inne (nie wymienione powyżej np. materiały promocyjne, informacyjne, szkoleniowe, edukacyjne)

Opis upowszechniania wyników projektu
Publikacje: - „Przegląd Komunalny nr 5/2020”, strona 18 Tytuł: Inwentaryzacja i niszczenie toksycznych kaukaskich barszczy z użyciem dronów”; - „ZIELEŃ MIEJSKA NR 05/2020”, strona 10 Tytuł: INWENTARYZACJA I NISZCZENIE TOKSYCZNYCH KAUKASKICH BARSZCZY Z UŻYCIEM DRONÓW”.

12. DZIAŁANIA INFORMACYJNO-PROMOCYJNE W RAMACH REALIZOWANEGO PROJEKTU

Czy w ramach projektu prowadzone są działania informacyjno – promocyjne zgodnie zapisami § umowy o dofinansowanie dot. tych działań?

TAK

NIE

(W przypadku odpowiedzi „TAK” należy opisać, jakie działania są realizowane w ramach obowiązków informacyjno – promocyjnych projektu. W przypadku odpowiedzi „NIE”, należy opisać dlaczego Beneficjent nie wypełnia tych obowiązków oraz jakie i kiedy zostaną wprowadzone środki zaradcze w tym zakresie.)

Zmodyfikowano stronę www aby informowała o realizacji projektu z PO IR Działanie 1.1.1. oraz umieszczono tablicę informującą o realizacji projektu w widocznej dla wszystkich lokalizacji, w miejscu realizacji projektu, która obecnie zostanie przeredagowana na tablicę pamiątkową.

PR-NWF-01/Z23

Ponadto zredagowano publikacje dla 2 czasopismach branżowych o projekcie wraz z adnotacją o jego współfinansowaniu przez UE.

13. OŚWIADCZENIE BENEFICJENTA*

Oświadczam, że kierownik B+R, kierownik zarządzający projektem oraz osoby wykonujące w zastępstwie ich obowiązki nie były i nie są jednocześnie wykonawcami jakichkolwiek prac po stronie podwykonawcy, w tym nie pozostawały i nie pozostają w stosunku służbowym lub innej formie współpracy z podwykonawcą (dotyczy stosunku pracy, stosunków cywilnoprawnych lub innych form współpracy).

Oświadczam, że jestem świadomy odpowiedzialności karnej wynikającej z art. 297 Kodeksu karnego⁴ dotyczącej składania nierzetelnych, pisemnych oświadczeń co do okoliczności o istotnym znaczeniu dla uzyskania wsparcia.



Podpis (imię i nazwisko)

⁴*) Dotyczy konkursów:

- Konkurs 5/1.1.1/2017 – dla MŚP
 - Konkurs 6/1.1.1/2017 – dla dużych i konsorcjów przedsiębiorstw
 - Konkurs 1/4.1.1/2017/POIR - BRIK
 - Konkurs 2/4.1.1/2017/POIR - WP z Lubelskim
 - Konkurs 9/1.2/2017/POIR Konkurs IUSER – II
 - Konkurs 1/4.1.1/2018/POIR – WP INGA
 - Konkurs 1/4.1.2/2018/POIR – RANB
 - Konkurs 1/1.1.1/2018 – konkurs dla mikro-, małych i średnich przedsiębiorców
 - Konkurs 2/1.1.1/2018 – konkurs dla przedsiębiorców innych niż mikro-, mali i średni oraz konsorcjów przedsiębiorstw
 - Konkurs 3/1.1.1/2018 – konkurs dla mikro-, małych i średnich przedsiębiorstw, które otrzymały certyfikat Seal of Excellence
 - Konkurs 1/4.1.4/2018/POIR Projekty aplikacyjne
 - Konkurs 1/1.2/2018/POIR INNOship
 - Konkurs 2/1.2/2018/POIR Innomoto
 - Konkurs 3/1.2/2018/POIR InnoNeuroPharm
 - Konkurs 4/1.1.1/2018 – konkurs dla MŚP
 - Konkurs 2/4.1.1/2018/POIR – WP Łódzkie
 - Konkurs 5/1.1.1/2018 – dla dużych oraz konsorcjów przedsiębiorstw
 - Konkurs 3/4.1.1.2018 - WP Śląskie
- Wszystkie konkursy od 2019 r.

Zgodnie z art. 297 § 1 kodeksu karnego, „Kto, w celu uzyskania dla siebie lub kogo innego, od banku lub jednostki organizacyjnej prowadzącej podobną działalność gospodarczą na podstawie ustawy albo od organu lub instytucji dysponujących środkami publicznymi - kredytu, pożyczki pieniężnej, poręczenia, gwarancji, akredytywy, dotacji, subwencji, potwierdzenia przez bank zobowiązania wynikającego z poręczenia lub z gwarancji lub podobnego świadczenia pieniężnego na określony cel gospodarczy, elektronicznego instrumentu płatniczego lub zamówienia publicznego, przedkłada podrobiony, przerobiony, poświadczający nieprawdę albo nierzetelny dokument albo nierzetelne, pisemne oświadczenie dotyczące okoliczności o istotnym znaczeniu dla uzyskania wymienionego wsparcia finansowego, instrumentu płatniczego lub zamówienia, podlega karze pozbawienia wolności od 3 miesięcy do lat 5”.