

POLITECHNIKA POZNAŃSKA  
WYDZIAŁ AUTOMATYKI, ROBOTYKI I ELEKTROTECHNIKI  
INSTYTUT AUTOMATYKI I ROBOTYKI  
ZAKŁAD UKŁADÓW ELEKTRONICZNYCH  
I PRZETWARZANIA SYGNAŁÓW



**ROZPRAWA DOKTORSKA**

**SYSTEM SZTUCZNEJ INTELIGENCJI WSPOMAGAJĄCY  
WYKONYWANIE AUTONOMICZNYCH OPRYSKÓW  
SADOWNICZYCH**

**DOKTORANT: MGR INŻ. PIOTR GÓRAL**

**PROMOTOR:**

**PROF. DR HAB. INŻ. ADAM DĄBROWSKI**

**PROMOTOR POMOCNICZY:**

**DR INŻ. PAWEŁ PAWŁOWSKI**

**POZNAŃ 2024**

Składam serdeczne podziękowania dla mojego promotora  
Pana prof. dr hab. inż. Adama Dąbrowskiego  
oraz promotora pomocniczego  
Pana dr inż. Pawła Pawłowskiego  
za pomoc i zaangażowanie oraz wiele trafnych uwag i spostrzeżeń,  
które były pomocne podczas pisania rozprawy.  
Wyrazy wdzięczności przekazuję także dla  
Pana dr inż. Karola Piniarskiego,  
Pana mgr inż. Mariusza Pawlaka  
oraz sadownika Pana Huberta Fibigra i rodzinie.  
Ponadto dedykuję rozprawę doktorską pamięci poległym w obronie Ojczyzny.



## Streszczenie

Temat podjęty w rozprawie doktorskiej jest związany z badaniami nad innowacyjnymi metodami wykonywania zautomatyzowanych oprysków sadowniczych. Analizie poddany został aktualny stan wiedzy związanej z systemami sztucznej inteligencji stosowanymi w ogrodnictwie. Przygotowana została propozycja systemu sztucznej inteligencji w celu wspomaganie wykonywania autonomicznych oprysków sadowniczych. Opracowane rozwiązania uwzględniają potrzeby ograniczenia ilości stosowanych środków chemicznych oraz oszczędności wody wykorzystywanej do oprysków. Do przeprowadzania badań eksperymentalnych wykorzystane zostały głównie modele głębokich splotowych sieci neuronowych.

W skład stanowiska badawczego włączono maszyny: wybrany model ciągnika sadowniczego oraz wybrany model opryskiwacza sadowniczego. Maszyny te zostały zmodernizowane poprzez wyposażenie w układ bezprzewodowej automatyki. Za koordynację działania układu bezprzewodowej automatyki odpowiada system sterowania, którego adaptacja pozwala na autonomiczne poruszanie się zespołu maszyn w granicach nadanej autonomii. Zainstalowany modułowy podsystem wizyjny umożliwia sterowanie ciągnikiem, rozpoznawanie wysokości i stanu rozwojowego drzew. Pełni również rolę monitoringu inspekcyjnego plantacji.

Dane z modułowego podsystemu wizyjnego trafiają do systemu sztucznej inteligencji, gdzie zostają przetwarzane przez algorytmy wizyjne. Następnie dane te podlegają programowemu zestawieniu z bazą danych strategii ochronnych przed chorobami i szkodnikami sadowniczymi, prognozami meteorologicznymi oraz komunikatami sadowniczymi. Krok ten pozwala na wygenerowanie sygnalizacji wspomagającej plantatora w podjęciu decyzji o konieczności wykonania danego oprysku. Po zatwierdzeniu sygnalizacji realizowany jest zabieg ochronny z wykorzystaniem zmodernizowanego ciągnika sprzęgniętego z opryskiwaczem przeznaczonym do wykonywania autonomicznych oprysków sadowniczych.

Przedstawiona propozycja systemu sztucznej inteligencji i zaawansowanego technologicznie dedykowanego systemu sterowania ciągnikiem autonomicznym wraz z opryskiwaczem sadowniczym, skutkuje zwiększeniem ochrony środowiska i człowieka minimalizując szkodliwe skutki wykonywania oprysków chemicznych w sadownictwie.

## **Abstract**

The topic discussed in the doctoral dissertation is related to research on innovative methods of performing automated orchard spraying. The current state of knowledge related to artificial intelligence systems used in horticulture was analyzed. A proposal has been prepared to artificial intelligence system to support autonomous orchard spraying. The developed solutions take into account the need to reduce the amount of chemicals used and save water used for spraying. Mainly deep convolutional neural network models were used to conduct experimental research.

The research station included machines: a selected model of an orchard tractor and a selected model of an orchard sprayer. These machines have been modernized by being equipped with a wireless automation system. The control system is responsible for coordinating the operation of the wireless automation system, the adaptation of which allows the set of machines to move autonomously within the limits of the granted autonomy. The installed modular vision subsystem allows you to control the tractor and recognize the height and development status of trees. It also serves as inspection monitoring of the plantation.

Data from the modular vision subsystem goes to the artificial intelligence system, where it is processed by vision algorithms. Then, these data are programmatically compared with a database of protective strategies against fruit diseases and pests, meteorological forecasts and orchard announcements. This step allows you to generate signals that support the grower in deciding whether a given spraying is necessary. After approval of the signal, protective treatment is carried out using a modernized tractor coupled with a sprayer designed to perform autonomous orchard spraying.

The presented proposal of an artificial intelligence system and a technologically advanced dedicated autonomous tractor control system with an orchard sprayer, results in increased environmental and human protection by minimizing the harmful effects of chemical spraying in orchards.

## Lista skrótów

<b>A</b>	
ACF: aggregated channel features.....	30
AHRS: attitude and heading reference system.....	24
<b>B</b>	
BBCH: Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie	56
BoVW: bag of visual words.....	17
<b>C</b>	
CDFS: colour-depth fusion segmentation..	44
CNN: convolutional neural network.....	30
CPU: central processing unit.....	83
<b>D</b>	
DNN: deep neural network.....	68
DL: deep learning.....	9
DWT: discrete wavelet transform.....	38
<b>F</b>	
FN: false negatives.....	78
FP: false positives.....	78
<b>G</b>	
GLCM: grey-level co-occurrence matrix...	38
GNSS: global navigation satellite system...	24
GPS: global positioning system.....	23
GSM: global system for mobile telecommunication.....	34
<b>H</b>	
HOG: histogram of orientem gradients.....	30
HSV: hue saturation value.....	29
<b>I</b>	
ICF: integral channel features.....	30
<b>K</b>	
KNN: k-nearest neighbours.....	38
<b>L</b>	
lidar: light detection and ranging.....	24
<b>M</b>	
LBP: local binary patterns).....	17
LL: low low.....	38
<b>M</b>	
MAE: mean absolute error.....	70
MAPE: mean absolute percentage error....	70
ML: machine learning.....	9
MSE: mean squared error.....	70
M-SVM: multiclass suport vector machine.	17
<b>N</b>	
NasNet: neural architecture search network.....	76
<b>P</b>	
PA: precision agricultur.....	17
PCA: principal component analysis.....	38
PLC: programmable logic controller.....	81
PWM: pulse width modulation.....	41
<b>R</b>	
R-CNN: region based convolutional neural networks.....	18
RGB: red, green, blue.....	29
RIM: relative infection measure.....	26
RMS, ang. root mean square.....	43
ROI, ang. region of interest .....	29
RTK-DGPS: real time kinematic-differential global positioning system.....	24
<b>S</b>	
SVM: support vector machine.....	17
<b>T</b>	
TN: true negative.....	78
TP: true positive.....	78
<b>U</b>	
UDP: user datagram protocol.....	24
<b>W</b>	
WiFi: wireless fidelity	

## Spis treści

Streszczenie .....	4
Abstract .....	5
Lista skrótów .....	6
1. Wprowadzenie .....	9
1.1 Problematyka pracy.....	9
1.2 Cel pracy i teza naukowa .....	13
1.3 Zakres i struktura pracy .....	13
1.3.1 Publikacje autora w czasopismach i materiałach konferencyjnych .....	15
2. Stan wiedzy i technologii w obszarze nowoczesnego ogrodnictwa .....	16
2.1 Sztuczna inteligencja w ogrodnictwie .....	16
2.2 Przemysł 4.0 i ogrodnictwo precyzyjne .....	19
2.3 Automatyka i robotyka w ogrodnictwie .....	21
2.4 Rozpoznawanie chorób drzew i szkodników ogrodnictwa .....	26
2.4.1 Infekcje grzybowe.....	26
2.4.2 Szkodniki owoców .....	27
2.5 Systemy wizyjne w sadownictwie .....	29
2.5.1 Akwizycja obrazu .....	29
2.5.2 Wstępne przetwarzanie .....	29
2.5.3 Klasyfikacja obiektów .....	30
2.5.4 Automatyczne rozpoznawanie szkodników w sadownictwie .....	31
2.5.5 Automatyczne rozpoznawanie chorób w sadownictwie.....	35
2.5.6 Metody wizyjnej nawigacji pojazdu realizującego inteligentny oprysk .....	42
3. Propozycja systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych .....	46
3.1 Główne elementy systemu .....	46
3.2 Modułowy system wizyjny .....	50
3.2.1 Wizyjny moduł monitorujący szkodniki.....	50
3.2.2 Wizyjny moduł sterujący ciągnikiem .....	51
3.2.3 Wizyjny moduł sterujący automatycznym opryskiwaczem.....	52
3.2.4 Wizyjna predykcja zapotrzebowania na środki ochrony drzew owocowych .....	58
3.3 Główny algorytm decyzyjny .....	61
3.4 Splotowe sieci neuronowe .....	68
3.4.1 Trenowanie głębokich modeli CNN .....	69

3.4.2 Zastosowane modele CNN .....	73
3.4.3 Model Xception .....	74
3.4.4 Model NasNetLarge.....	76
3.4.5 Metodyka oceny.....	78
4. Część eksperymentalna .....	79
4.1 Plan eksperymentów .....	79
4.2 Stanowisko badawcze .....	80
4.2.1 Modernizacja ciągnika i opryskiwacza sadowniczego do pracy w trybie autonomicznym ..	80
4.2.2 Architektura systemu sterowania .....	83
4.2.3 Aplikacja sterująca.....	86
4.3 Szczegółowe wyniki badań i eksperymentów .....	87
4.3.1 Wyniki przetwarzania obrazów z funkcją augmentacji danych.....	87
4.3.2 Wyniki detekcji szkodników sadowniczych .....	89
4.3.3 Wyniki detekcji wysokości drzew .....	90
4.3.4 Wyniki rozpoznawania stanów rozwojowych drzew .....	92
4.3.5 Wyniki rozpoznawania infekcji drzew sadowniczych .....	94
4.4 Końcowe wyniki badań i eksperymentów .....	96
4.4.1 Oszczędności wody i środków chemicznych .....	96
4.4.2 Zmniejszenie emisji środowiska i ochrona operatora .....	99
5. Wnioski końcowe i podsumowanie przeprowadzonych badań .....	100
Bibliografia: .....	102



# 1. Wprowadzenie

## 1.1 Problematyka pracy

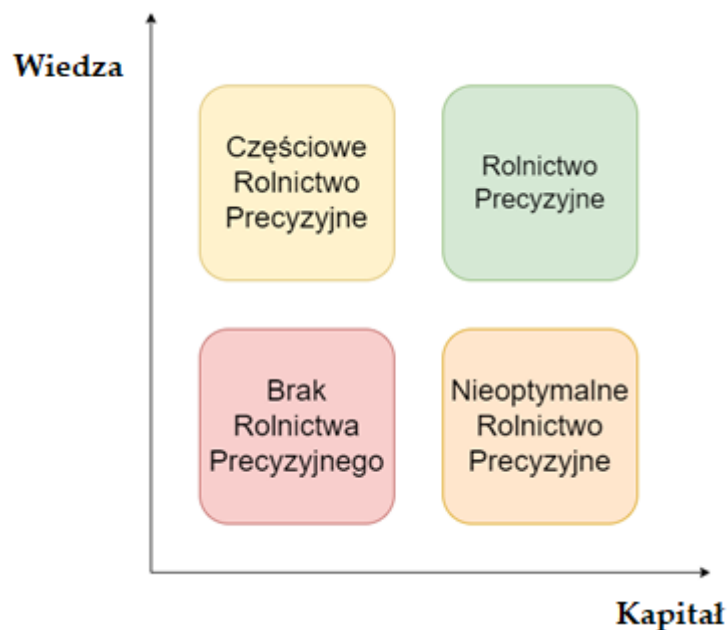
Zapotrzebowanie na żywność wzrasta wraz ze wzrostem światowej populacji ludności. Prognozy Organizacji Narodów Zjednoczonych wskazują, że populacja ludności do 2050 roku wzrośnie z obecnych 7.8 miliarda do około 9.8 miliarda. W tym czasie prognozuje się jedynie wzrost gruntów uprawowych o około 4%. Tendencja ta wymaga poszukiwania rozwiązań dla produkcji rolniczej w oparciu o możliwości sztucznej inteligencji w celu podniesienia wydajności produkcji przy uwzględnieniu bezpieczeństwa produkowanej żywności.

Przechodzenie od rolnictwa ekstensywnego do intensywnego, zapoczątkowane w drugiej połowie XX wieku, nie jest obecnie wystarczające oraz wiąże się z nakładami na produkcję i wymaga siły roboczej nieproporcjonalnej do osiągniętych zysków. Głównie z powodów migracji wiejsko-miejskiej w ostatnich latach spada sama zasobność siły roboczej do pracy w rolnictwie. Producenci żywności poszukują zatem rozwiązań poprzez wdrażanie nowoczesnych technologii, które wspomagają utrzymanie rentowności produkcji i podnoszą jednocześnie jej wydajność. W ostatnich latach zauważa się coraz większą rolę systemów sztucznej inteligencji, które wspomagają produkcję w branży rolniczej i ogrodniczej.

Wdrażanie innowacyjnych technologii produkcji stosowanych w rolnictwie jest obecnie prowadzone głównie w oparciu o automatyzację z wykorzystaniem sztucznej inteligencji (ML/DL, ML, ang. machine learning, DL, ang. deep learning) [1] i systemów zrobotyzowanych [2]. Opracowywane są rozwiązania, które realizują zadania wykrywania i klasyfikacji chorób roślin [3], detekcji chwastów [4], zliczania owoców [5] itp. Firmy produkujące ciągniki rolnicze posiadają już w swoich ofertach modele, które pozwalają na autonomiczne prowadzenie oraz integrację z inteligentnymi maszynami uprawowymi [6], [7].


Rozwój zastosowań sztucznej inteligencji w automatyzacji rolnictwa umożliwił powstanie tzw. rolnictwa precyzyjnego (PA, ang. precision agriculture) optymalizującego obszary produkcji żywności, które minimalizuje koszty i efektywnie zwiększa wyniki produkcyjne. Większość gospodarstw w krajach rozwijających się to jednostki obszarowo małe, powstają więc trudności w stosowaniu technologii precyzyjnego rolnictwa. Główne ograniczenia hamujące wdrażanie nowoczesnych technologii w tych gospodarstwach są związane, poza małymi rozmiarami, także z rozdrobnionymi gruntami, wysokimi kosztami adaptacji technologii precyzyjnego rolnictwa oraz brakiem profesjonalnego wsparcia. Ograniczenia te z reguły wypierają korzyści z wdrażania nowoczesnych technologii przekładające się na wyższą wydajność produkcji oraz ochronę środowiska. Rozwiązaniem w przyspieszeniu absorpcji technologii precyzyjnego rolnictwa może być zatem prosta, przyjazna i nisko kosztowa technologia z profesjonalnym wsparciem doradczo-usługowym [8].

Autorzy pracy [8] dokonali analizy stanu wdrożenia technologii precyzyjnego rolnictwa. Poddając analizie dochody małych i średnich gospodarstw można zauważyć, że bariera ekonomiczna stanowi główne ograniczenie we wdrażaniu ciągników autonomicznych. Ważnym aspektem jest również wiedza związana z korzyściami płynącymi z wdrażania innowacyjnych technologii. Według badań zaprezentowanych w [8] połączenie tych dwóch czynników jest wyznacznikiem do podejmowania decyzji inwestycyjnych w obszarze rozwiązań dedykowanych dla precyzyjnego rolnictwa. Brak dostatecznego kapitału jest źródłem wprowadzania tylko częściowych rozwiązań, natomiast brak wiedzy powoduje nieoptymalne wykorzystanie wdrożonych rozwiązań (rys. 1.1).



Rys 1.1 Zależność głównych czynników wprowadzania technologii precyzyjnego rolnictwa [8]

Według raportu [9], prognozowany jest ciągły wzrost wartości rynkowej rozwiązań w obszarach precyzyjnego rolnictwa, wykorzystania robotów rolniczych oraz monitoringu produkcji. Z wymienionych obszarów największy, tj. kilkukrotny przyrost wartości inwestycji w zakresie sztucznej inteligencji jest przewidywany dla rolnictwa precyzyjnego (rys. 1.2). Największe znaczenie tego obszaru wynika z faktu bezpośredniego oddziaływania rozwiązań sztucznej inteligencji na cały proces produkcji. Wiąże się to właściwą analizą czynników środowiskowych, które skutkują podejmowaniem dalszych działań w obszarach wykorzystujących roboty do wykonywania zadań. Przytoczyć tu można przykłady precyzyjnego rozpoznawania symptomów występowania chorób i szkodników na roślinach w tym na owocach do zbioru, które przekładają się bezpośrednio, na jakość produktów. Z tych powodów w obszarze automatycznej precyzyjnej detekcji chorób i szkodników drzew owocowych znajdować się będą kluczowe czynniki decydujące o wydajności produkcji i bezpieczeństwie produkowanej żywności.



Rys 1.2 Prognoza wzrostu wartości nowoczesnych rozwiązań w rolnictwie [9]

Generalnie, jedną z kluczowych zasad w produkcji żywności jest ograniczenie a nawet eliminacja szkodliwych pozostałości środków chemicznych wykorzystywanych w przemyśle spożywczym, przy czym jedne z podstawowych produktów, które służą do przetwórstwa spożywczego, to owoce. Zwiększające się w ostatnich latach koszty produkcji wymagają również od ogrodników poszukiwania nowych rozwiązań w produkcji, które bez uszczerbku na jakości produktów ograniczać będą nakłady na stosowane środki ochrony roślin, koszty robocizny i użycie wody. Wskazane jest również, aby poszukiwane rozwiązania w oparciu o nowoczesne technologie przyczyniały się do podnoszenia ekologiczności produktów, ochrony zdrowia a także uwzględniały dbałość o zasoby naturalne Ziemi.

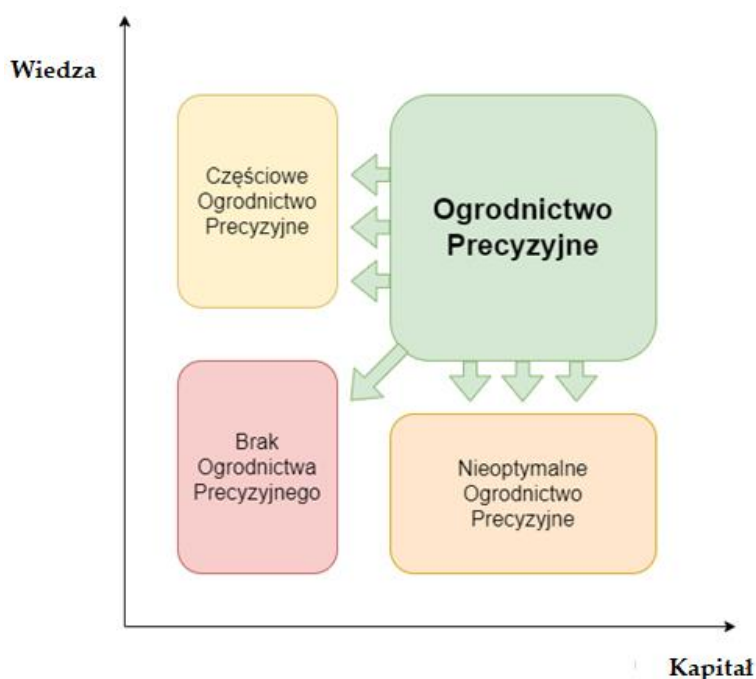
Istotą w minimalizacji ilości stosowanych środków chemicznych na plantacjach sadowniczych jest odpowiednie monitorowanie zagrożenia wystąpienia chorób i szkodników oraz detekcja drzew kwalifikujących się do oprysków. Ochrona zdrowia personelu realizującego wykonywanie oprysków sadowniczych może być realizowana poprzez zmniejszanie ich uciążliwości i szkodliwości. Efekty te można uzyskać wdrażając technologie zdalnego sterowania pojazdów autonomicznych, w których głównym źródłem danych będą informacje z czujników wizyjnych. Przetworzone informacje z kamer, poza wykorzystaniem do prowadzenia autonomicznego ciągnika i opryskiwacza, wyposażonego w system sterowania stosujący algorytmy sztucznej inteligencji, mogą być wykorzystywane także do automatycznej inspekcji plantacji uprawowej.

Systemy wizyjne, które dotychczas stosowane były głównie w przemyśle motoryzacyjnym, lotniczym i geodezyjnym, zaczynają pełnić coraz większą rolę w zastosowaniach rolniczych i ogrodniczych. Bezpośrednie korzyści, które wynikają z ich zastosowania wiążą się z minimalizacją strat powodowanych przez nieprecyzyjne wykonywanie zabiegów agrotechnicznych. Wykorzystywane są także w autonomicznych robotach uprawowych do wspomaganie prowadzenia, mapowania uprawy i kontroli jakości produktów. Aplikacje bazujące na sygnale wizyjnym realizować mogą zadania w oparciu o zastosowanie sztucznych sieci neuronowych. W sadownictwie pozwalają one przede wszystkim na realizację automatycznej wizyjnej inspekcji upraw. Inspekcja wizyjna może mieć na celu wczesną sygnalizację infekcji oraz klasyfikację stanów rozwojowych drzew lub automatyczną kalibrację parametrów oprysku, co łącznie prowadzi do zmniejszenia zużycia wody i stosowanych środków. Pozyskane w trakcie inspekcji wizyjnej dane z uprawy sadowniczej, wraz z informacjami meteorologicznymi i opracowanymi strategiami ochronnymi drzew, mogą być integrowane w systemie sztucznej inteligencji, który zarządza produkcją sadowniczą. Głównym zadaniem takiego systemu jest wspomaganie sadownika w podejmowaniu decyzji o wykonaniu zabiegu ochronnego w odpowiednim terminie.

W niniejszej pracy pokazano, że w krajach wysoko rozwiniętych, o wysokiej kulturze upraw, gospodarstwa ogrodnicze posiadają zdolności inwestycyjne, pozwalające wdrażać innowacyjne osiągnięcia techniczne kwalifikowane do obszaru sztucznej inteligencji. Odmienne - jak już wcześniej wspomniano - kształtują się możliwości inwestycyjne gospodarstw o poziomie rozwoju gospodarki niższym lub zbliżonym do typowego poziomu gospodarstw w Polsce. Z historycznego punktu widzenia mechanizacja rolnictwa wdrażana globalnie na szeroką skalę po zakończeniu II wojny światowej do Polski dotarła ze znacznym opóźnieniem. Co więcej, poziom technologiczny urządzeń znacznie odbiegał od ówczesnych rozwiązań wdrażanych równolegle w krajach choćby Europy Zachodniej. Zaznaczyć należy, że obecnie w Polsce istnieją obszary przemysłu ogrodniczego, w których technologie związane z produkcją kwalifikowane mogą być do ścisłej światowej czołówki. Wyróżnić tu można uprawy prowadzone pod osłonami (szklarnie, tunele foliowe). Równocześnie, w wielu innych obszarach (w tym sadownictwie) osiągnięcie konkurencyjności technologicznej jest sprawą przyszłości.

Z danych Głównego Urzędu Statystycznego, dotyczących średniej cisałości gospodarstw sadowniczych w Polsce można wywnioskować, że nasz kraj, w obszarze produkcji sadowniczej, zalicza się do gospodarek rozwijających się. W Polsce 77 % gospodarstw ogrodniczych stanowią gospodarstwa o powierzchni do 10 hektarów. Jest to odsetek zbliżony do innych krajów, których gospodarki są w okresie rozwoju. Liczba zarejestrowanych ciągników w Polsce wynosi około 1.5 mln sztuk. Ponad połowę z nich stanowią stare technologicznie, używane przez wiele lat modele ciągników marki: Ursus C-330 i C-360, Massey Ferguson MF-235 i MF-255 oraz Władymirec T-25. Modele te są wciąż najczęściej użytkowanymi ciągnikami w gospodarstwach sadowniczych. Na świecie odsetek przestarzałych technologicznie maszyn pozostających w użyciu jest zróżnicowany, w zależności od stopnia rozwoju gospodarczego poszczególnych państw.

Zestawienie powyższych danych z analizą globalnych czynników związanych z wdrażaniem technologii precyzyjnego ogrodnictwa pozwala na wyciągnięcie wniosku, że poza grupą niewielkich gospodarstw ogrodniczych, które dysponują środkami finansowymi na świadome wdrażanie technologii precyzyjnego ogrodnictwa, w najbliższych latach dominować będzie wdrażanie tylko częściowych rozwiązań. Wniosek ten wskazuje na wyznaczenie głównego kierunku badawczego, którego realizacja odbywać się może w oparciu o modernizację użytkowanych w gospodarstwach ciągników i maszyn w sposób umożliwiający ich włączenie w systemy sztucznej inteligencji wspomagające wykonywanie autonomicznych oprysków sadowniczych. Podejście, w którym adaptacja nowoczesnej architektury automatyki sprzętowej jest dedykowana dla użytkowanych w branży ciągników i maszyn uprawowych powodować będzie znaczący wzrost potencjalnych wdrożeń, przy istotnie niższych nakładach finansowych niż przy wdrażaniu nowych maszyn. Relację tą przedstawiono na rysunku 1.3. Pokazano na nim kierunki rozszerzania się obszaru wdrażania Ogrodnictwa Precyzyjnego przy zróżnicowanym nakładzie kapitału i wiedzy. Odpowiednie wykorzystanie najnowszej wiedzy może zmniejszyć wymagane nakłady kapitału.



Rys. 1.3 Zależność głównych czynników wprowadzania technologii precyzyjnego ogrodnictwa z uwzględnieniem wykorzystania użytkowanych ciągników i maszyn (opracowanie własne)

## 1.2 Cel pracy i teza naukowa

### Cel pracy:

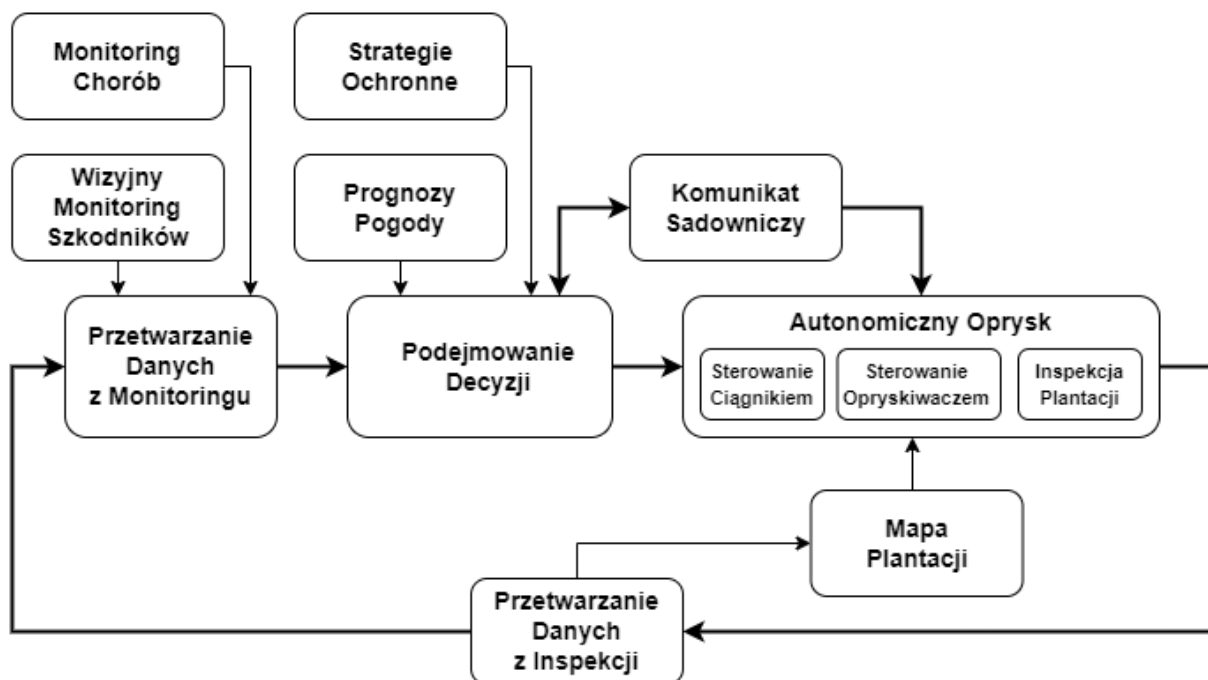
Celem badawczym rozprawy doktorskiej jest zastosowanie metod sztucznej inteligencji do wspomagania podejmowania decyzji o zabiegach sadowniczych, minimalizujących liczbę oprysków i ilość wykorzystywanych w tym celu środków ochrony roślin, a także do eliminacji bezpośredniego udziału operatora, czyli do zapewnienia pełnej ochrony człowieka od ekspozycji na stosowane środki chemiczne.

### Teza naukowa:

Dzięki zastosowaniu zaproponowanego inteligentnego systemu wizyjnego do rozpoznawania chorób i szkodników drzew owocowych oraz detekcji drzew, a także opracowanego zrobotyzowanego bezzałogowego sprzętu do oprysków sadowniczych, zapewnia się poprawę precyzji oprysków, ograniczenie ilości stosowanych środków chemicznych i wody, poprawę jakości owoców a ponadto ochronę sadownika przed ekspozycją na szkodliwe środki chemiczne.

## 1.3 Zakres i struktura pracy

Niniejsza rozprawa przedstawia propozycję systemu wizyjnego wykorzystującego sztuczną inteligencję, w którym algorytmy automatycznej analizy obrazów drzew owocowych oraz obrazów chorób i szkodników sadowniczych są wykorzystywane w celu precyzyjnego planowania i wykonywania oprysków (rys. 1.4).



Rys. 1.4 Schemat blokowy systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych (opracowanie własne)

W pracy zrealizowano następujące zadania szczegółowe:

- opracowanie systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych, w którym algorytmy wizyjne:
  - wykonują inspekcję plantacji
  - dokonują detekcji szkodników drzew na pułapkach feromonowych
  - sygnalizują konieczność wykonania oprysku
  - wspomagają poruszanie się ciągnika po plantacji sadowniczej
  - klasyfikują stan rozwojowy drzew
  - realizują detekcję wysokości drzew
- modernizacja ciągnika sadowniczego i opryskiwacza poprzez:
  - budowę podsystemu bezprzewodowej automatyki do bezzałogowego sterowania ciągnikiem
  - budowę podsystemu bezprzewodowej automatyki sterującej opryskiwaczem
- przygotowanie autorskiej bazy zdjęć do trenowania wybranych modeli sztucznych sieci neuronowych
- badanie dokładności metod wykorzystywanych do automatycznej analizy obrazów oraz do oszczędzania wody ze środkami ochrony roślin dzięki zastosowanemu wizyjnemu systemowi sterowania automatycznym opryskiwaczem sadowniczym

Struktura pracy jest następująca. W rozdziale II przedstawiono aktualny stan wiedzy i technologii w obszarze nowoczesnego ogrodnictwa i sadownictwa. W rozdziale III zawarto propozycje systemu sztucznej inteligencji, wspomagającego podejmowanie decyzji i wykonywanie autonomicznych oprysków sadowniczych w oparciu o dane wizyjne, dane meteorologiczne i bazę strategii ochronnych oraz przedstawiono wybrane zagadnienia z obszaru splotowych sieci neuronowych. Rozdział IV przedstawia wyniki badań eksperymentalnych i analizę wyników. W rozdziale V zamieszczono wnioski końcowe i podsumowanie zrealizowanych badań.

### 1.3.1 Publikacje autora w czasopismach i materiałach konferencyjnych

- Artykuły w czasopismach:

1. Góral, P.; Pawłowski, P.; Piniarski, K.; Dąbrowski, A. Multi-Agent Vision System for Supporting Autonomous Orchard Spraying. *Electronics* 2024, 13, 494. <https://doi.org/10.3390/electronics13030494>
2. Góral, P. Pawłowski P., Dąbrowski A., „Modułowy system wizyjny do autonomicznych inspekcji i oprysków sadowniczych” *Przegląd Elektrotechniczny*, ISSN 0033-2097, R. 98 Nr 2/2022 - s. 70-75, doi:10.15199/48.2022.02.14,
3. Góral P., Pawłowski P., Dąbrowski A., „System bezprzewodowego zdalnego sterowania dla pojazdu autonomicznego” *Przegląd Elektrotechniczny*, ISSN 0033-2097, R. 95 Nr 10/2019 - s. 114-117, doi:10.15199/48.2019.10.25
4. Góral P., Pawłowski P, Dąbrowski A., "Precise 3D vision based measurements of gearwheels" 2022 *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan, Poland, 2022, pp. 161-166, doi: 10.23919/SPA53010.2022.9928022,
5. Góral, P., Pawłowski, P., Nowacki, W., Wróbel, J. (2023). Elektroniczne zabezpieczenie antykradzieżowe dla pojazdów osób o specjalnych potrzebach. *Wojskowe systemy logistyczne* , 59 (2), 287-298. <https://doi.org/10.37055/slw/186380>

- Prezentacje konferencyjne:

1. Góral P. „Adaptacja technologii sterowania pojazdem autonomicznym w zastosowaniach wojskowych”, Konferencja naukowo-techniczna pt. „Pojazdy autonomiczne – wyzwania oraz szanse dla gospodarki i obronności państwa”. Warszawa 15-16.11.2023,
2. Nowacki W., Góral P., Pawłowski P., Dąbrowski A., „Niskobudżetowy system wizyjny do automatycznych pomiarów na stanowisku zrobotyzowanym”, XXII Krajowa Konferencja Elektroniki KKE 2023, Darłowo, 11.06-15.06.2023, 2023
3. Góral P., Pawłowski P, Dąbrowski A., "Precise 3D vision based measurements of gearwheels" 2022 *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan, Poland, 2022
4. Góral P., Pawłowski P., Dąbrowski A. „System wizyjny autonomicznego opryskiwacza sadowniczego”, XX Krajowa Konferencja Elektroniki KKE 2021, Darłowo, 05.09-09.09.2021
5. Góral, P. Pawłowski P., Dąbrowski A. „System bezprzewodowego zdalnego sterowania dla pojazdu autonomicznego”, XVIII Krajowa Konferencja Elektroniki KKE 2019, Darłowo, 02.06-06.06.2019, 2019

## 2. Stan wiedzy i technologii w obszarze nowoczesnego ogrodnictwa

### 2.1 Sztuczna inteligencja w ogrodnictwie

W podrozdziale przedstawiono wybrane kluczowe obszary zastosowań sztucznej inteligencji w ogrodnictwie. Pojęcie sztucznej inteligencji utożsamiane jest z imitacją inteligencji człowieka w odniesieniu do sposobu myślenia, ucznia się i rozwiązywania problemów w granicach zaprojektowanego systemu [10]. Obecny poziom rozwoju systemów sztucznej inteligencji pozwala na ich zastosowanie niemal we wszystkich obszarach związanych z produkcją ogrodnictw, gdzie wykorzystywać mogą algorytmy uczenia maszynowego, w tym sztuczne sieci neuronowe.

W ogrodnictwie zadania takie jak: opryski drzew, szacowanie plonu a nawet zbiór owoców wykonywać zaczynają autonomiczne roboty wykorzystujące technologię automatyzacji. Rysunek 2.1 przedstawia wyodrębnione obszary ogrodnictwa, w których wykonywane zadania mają bezpośredni wpływ na jakość produkowanych owoców. Są to: diagnostyka chorób i szkodników, inteligentne opryski, roboty ogrodnicze oraz przewidywanie plonów [10]. W każdym z tych obszarów zauważa się tendencję do wykorzystywania algorytmów opartych głównie na głębokim uczeniu maszynowym. Wymagania, które stawiane są dla sztucznej inteligencji to przede wszystkim identyfikowanie genetycznego zagrożenia ze strony szkodników i chorób upraw na bardzo wczesnym etapie rozwoju, inteligentna identyfikacja bazująca na monitoringu czynników meteorologicznych oraz inspekcja upraw w czasie rzeczywistym. Precyzja realizacji wymienionych wymagań przekłada się bezpośrednio na wykonywanie oprysków ochronnych przez przystosowane roboty ogrodnicze i inteligentne opryskiwacze optymalizujące zużycie wody ze środkami ochronnymi. Dane z monitoringu wykorzystywane przez zautomatyzowane opryskiwacze służyć mogą również innym systemom do realizacji zadań takich jak przewidywanie plonów, czy określanie terminu zbioru owoców. Sztuczna inteligencja realizować może zadania stawiane w obszarze ogrodnictwa dzięki algorytmom obliczeniowym zawierające w swojej strukturze architektury sztucznych sieci neuronowych [11],[12],[13].



Rys. 2.1 Kluczowe obszary zastosowań sztucznej inteligencji w ogrodnictwie [10]



Z wyodrębnionych obszarów na rysunku 2.1 najważniejsza jest diagnostyka chorób i szkodników. Realizacja tego zadania jest koniecznością w każdej uprawie i ma na celu zmniejszenie głównych strat w uprawach wpływających na wydajność ekonomiczną. Klasycznie, czynności lustracyjne na plantacjach wykonywane są przez ekspertów prowadzących uprawę lub ogrodników z doświadczeniem eksperckim.

Typowa metoda odłowu owadów będących przyczyną szkodników w uprawach ogrodniczych wykorzystuje pułapki z atraktorami wabiącymi. Pułapki takie rozmieszczane są w ilościach dobieranych do powierzchni uprawy. Odłowione szkodniki zostają następnie ręcznie zliczane, co jest pracochłonne i wymaga specjalistycznej wiedzy. Postęp nauki spowodował rozwój technologii monitoringu upraw w oparciu o wykorzystanie systemów wizyjnych. Przetwarzanie obrazu z technikami segmentacji pozwala na wykrycie szczególnych cech owadów. Tego typu metody wykorzystywane są już powszechnie w uprawach ogrodniczych pod osłonami i w produkcji cytrusów. W pracy [14] do wykrywania szkodników uszkadzających kwiaty wykorzystano maszynę wektorów nośnych SVM (SVM, ang. support vector machine). Akwizycja obrazów odbywa się z użyciem aparatu cyfrowego umieszczonego na efektorze końcowym ramienia robota mobilnego. Robot porusza się po torze między rzędami uprawowymi i sterowany jest za pomocą oprogramowania zrealizowanego w środowisku LabVIEW firmy National Instruments. Następnie, wykonane zdjęcia poddane zostają analizie i przetwarzaniu w programie MATLAB celem detekcji szkodnika na powierzchni kwiatów. W pracy [15] przedstawiona została metoda rozpoznawania dwóch gatunków szkodników w uprawie pomidora oparta na algorytmie worka słów wizualnych BoVW (BoVW, ang. bag of visual words). W produkcji cytrusów zastosowanie wizji maszynowej pozwala na wykrywanie plam chorobowych [16] oraz klasyfikację chorób. Praca [16] przedstawia metody wykrywania uszkodzeń roślin uprawnych wykorzystujące zoptymalizowaną segmentację ważoną oraz klasyfikację chorób za pomocą M-SVM (M-SVM, ang. multiclass support vector machine). Zastosowanie w wykrywaniu chorób liści znajdują także metody lokalnych wzorców binarnych (LBP, ang. local binary patterns) przedstawione w pracy [17].

Wybór i zastosowanie właściwej metody przetwarzania danych z monitoringu są kluczowe pod względem podejmowania dalszych czynności związanych z doбором odpowiedniego oprysku ochronnego dla plantacji. Od precyzyjnej identyfikacji szkodników i chorób zależy, zatem przyjęcie strategii zwalczania zagrożenia plantacji, która ma bezpośredni wpływ na produkowany owoc i wydajność produkcji.

Kolejny obszar produkcji ogrodniczej, w którym realizowane jest wykonanie przyjętej strategii zwalczania zidentyfikowanych wcześniej szkodników i chorób, to opryski ochronne. Dąży się do tego, aby zadania oprysków ochronnych mogły pełnić roboty ogrodnicze. Są one odpowiedzią na uciążliwość wykonywanych oprysków i zapełniają mogą braki siły pracowniczej w ogrodnictwie. Mobilne, autonomiczne, zrobotyzowane platformy są projektowane, konstruowane i wyposażane w systemy sztucznej inteligencji pozyskujące informacje ze środowiska otoczenia robota i inne dane służące do realizacji zadań. Poza opryskami ochronnymi [18] znajdują zastosowanie do siewu i sadzenia [19], pielęgnacji upraw [20] oraz zbiorów owoców [21]. Wprowadzenie inteligentnych oprysków do produkcji ogrodniczej poprawia skuteczność ich stosowania, zmniejsza koszty oraz minimalizuje szkodliwe oddziaływanie dla środowiska [22]. Algorytmy sztucznej inteligencji wykorzystujące wizję maszynową pozwalają na kontrolę dawki i ilości wypryskiwanej cieczy tylko w konieczne obszary lub miejsca drzew. Uwzględnić mogą także wielkość drzew oraz fazę rozwoju.

Bardzo ważnym obszarem wpływającym na wydajność plantacji ogrodniczej i odpowiednią jakość owoców jest przewidywanie plonów [23]. Proces ten rozpoczyna się już na etapie kwitnienia. Analizowane jest wówczas stadium rozwojowe kwiatu, na podstawie którego określa się konieczność wykonania zabiegu przerzedzania środkami chemicznymi, w celu redukcji nadmiernej liczby kwiatów. Zbieg ten jest szczególnie ważny ze względu na określenie daty szczytu kwitnienia i wymaga

cyklicznej lustracji przez cały okres kwitnienia plantacji. Potencjalny skutek wykonania tego zabiegu w niewłaściwym czasie wiąże się z nadmierną liczbą owoców, którym drzewa lub krzewy nie są w stanie dostarczyć składników odżywczych i owoce nie dorastają do konsumpcyjnej wielkości lub powstaje niedobór owoców ze względu na zniszczenie nadmiernej liczby kwiatów. W pracy [24] podjęto się zbudowania zautomatyzowanego systemu wizyjnego wyznaczającego na podstawie intensywności kwitnienia datę wykonania zabiegu przerzedzania chemicznego. Do detekcji kwiatów wykorzystano algorytm R-CNN (R-CNN, ang. region based convolutional neural networks) przedstawiony w pracy [25] jako algorytm bazowy. Zaimplementowano także sieć VGG-16 [26] wstępnie przeszkoloną na zbiorze danych ImageNet [27].

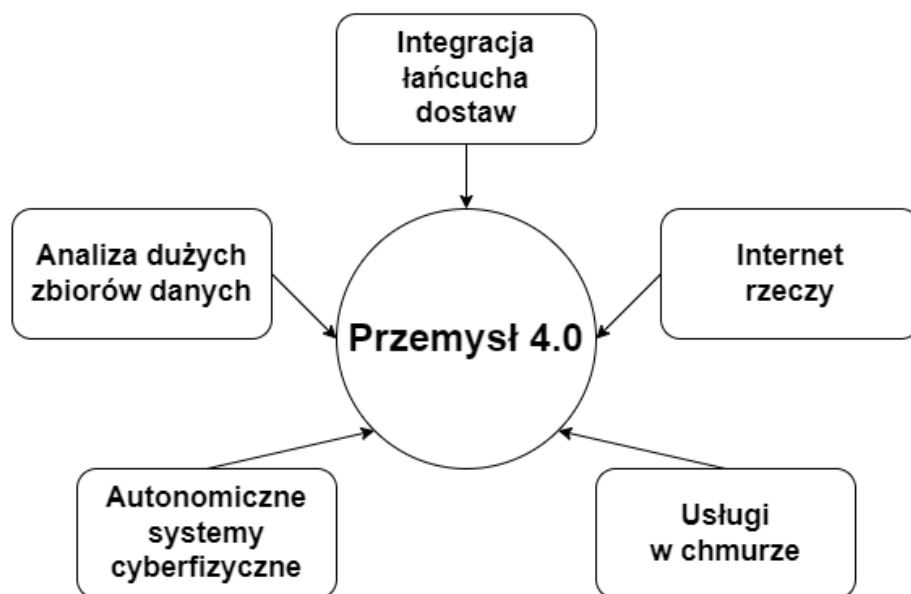
Poza procesem szacowania ilości kwiatów w okresie wzrostu owoców, w oparciu o algorytmy sztucznych sieci neuronowych wykonywanych może być szereg innych automatycznych detekcji owoców. Wykrywanie odbywać się może na podstawie koloru, głębi, kształtu [28] i probabilistycznej transformaty Houga [29]. Informacje z detekcji mogą zostać wykorzystane do wspomagania podejmowania decyzji o nawożeniu dolistnym lub oceny stopnia wybarwienia owoców. Wykonywane może być także automatyczne mapowanie plonów przed zbiorami [30] z wykorzystaniem modelu sieci YOLOv4 [31], w celu zaplanowania sprzedaży lub ilości miejsca potrzebnego do przechowania owoców.

Poza wyodrębnionymi obszarami ogrodnictwa, w których opisano przykłady zastosowań systemów sztucznej inteligencji istnieją inne, w których wdrażane są analogiczne rozwiązania [32], [33], [34]. W niniejszej rozprawie skupiono się na badaniach w obszarach:

- mających bezpośredni wpływ na jakość produkowanych owoców
- autonomicznego i zrobotyzowanego wykonywania inteligentnych oprysków
- komputerowo wspomaganego podejmowania decyzji o konieczności wykonania zabiegów.

## 2.2 Przemysł 4.0 i ogrodnictwo precyzyjne

Przemysł 4.0, zwany czwartą rewolucją przemysłową, z perspektywy podejścia opisanego przez autorów [35], [36], może być identyfikowany w pięciu obszarach innowacyjnych technologii: autonomicznych systemach cyberfizycznych, usługach w chmurze, analizie dużych zbiorów danych, Internecie rzeczy i integracji łańcucha dostaw (rys. 2.2). Integracja technologiczna tych obszarów w fabryce przemysłowej oznacza komunikowanie się autonomicznych komponentów systemu i realizację zadań bez konieczności zaangażowania człowieka [37], [38]. Dostęp do usług w chmurze zapewnia współużytkowanie tych samych zasobów danych przez kilku użytkowników i niezbędną moc obliczeniową [39]. Analiza dużych zbiorów danych obejmuje procesy i metody które wymagają przetwarzania i obróbki w czasie rzeczywistym dużej ilości danych, z różnych źródeł, w użyteczne dla systemu informacje [35]. Internet rzeczy stwarza nowe możliwości interakcji człowiek-maszyna, łącząc poszczególne komponenty systemu produkcyjnego takie jak: maszyny, czujniki i produkty w sposób umożliwiający komunikację. Przemysł wykorzystujący tak zorganizowany system produkcji wymaga również odpowiedniej integracji łańcucha dostaw, często nie dotyczącej konkretnej technologii, a integracji procesów poza granicami fabryki przemysłowej z wykorzystaniem metod sztucznej inteligencji [37].

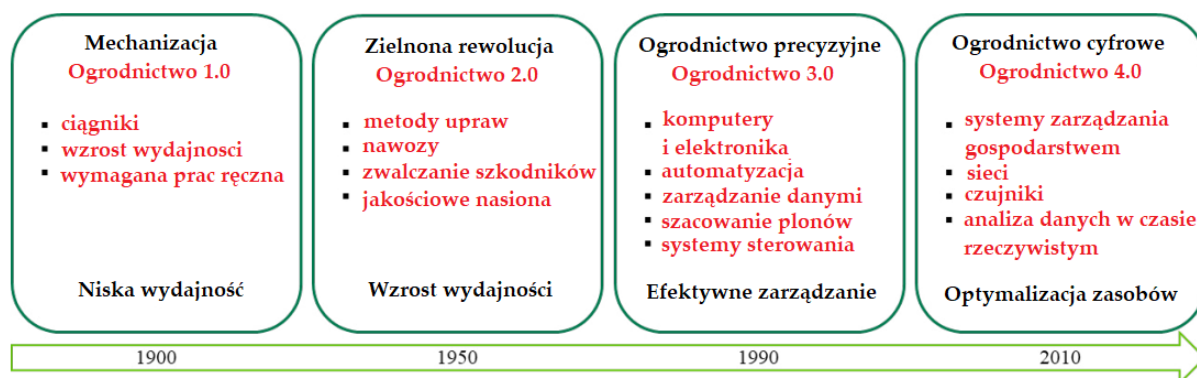


2.2 Główne obszary rozwoju Przemysłu 4.0 [37]

Podobnie do Przemysłu 4.0, fazy rozwoju technologicznego wdrażane w ogrodnictwie, a także przodujące czynniki rozwojowe przekształciły branżę ogrodniczą od Ogrodnictwa 1.0 do Ogrodnictwa 4.0 (rys. 2.3). Klasyfikację rozpoczyna faza mechanizacyjna, której początek uznawany jest w okresie wprowadzenie ciągników i maszyn. Przyczyniły się one do uzyskiwania wyższej wydajności w produkcji owoców i warzyw. Kolejna faza (2.0) była skutkiem wdrażania badań biologicznych, w wyniku których pojawiły się wysokowydajne odmiany nasion, nawozy i pestycydy. Ogrodnictwo 2.0 spowodowało zdecydowane zwiększenie wydajności w produkcji ogrodniczej, jednak równocześnie pojawiło się pewne zagrożenie związane z bezpieczeństwem produkowanej żywności. Rozwój elektroniki i wdrożenia komputerów pozwoliły na przekształcenie produkcji ogrodniczej w kolejną fazę Ogrodnictwa 3.0. Wdrażane technologie dały możliwości efektywnego i precyzyjnego zarządzania produkcją owoców i warzyw, wprowadzania systemów sterowania oraz automatycznych metod szacowania plonów. Obecnie, cyfryzacja ogrodnictwa polega na wyposażaniu upraw w czujniki aktywizujące i analizujące dane w czasie rzeczywistym, komunikujące się poprzez sieci

teleinformatyczne. Osiągnięcia kolejnych faz rozwojowych ogrodnictwa, uzupełnione o systemy sztucznej inteligencji przetwarzające dane, pozwalają na optymalizację w produkcji ogrodniczej i sukcesywne podnoszenie wzrostu wydajności. Obszar uprawy zaczyna być rozumiany jako uproszczona perspektywa fabryki lub zakładu przemysłowego, w którym produkcja odbywa się z uwzględnieniem ochrony środowiska i bezpieczeństwa produkowanych owoców. Z tego podejścia wynika bezpośrednia korzyść dla zdrowia konsumentów.

Analizując osiągnięcia Przemysłu 4.0 związane z produkcją w procesach zautomatyzowanych i interakcji człowiek-maszyna oraz maszyna-człowiek zauważa się, że rozwiązania te adoptowane są bezpośrednio do Ogrodnictwa 4.0. Faza ta w ogrodnictwie jest obecnie intensywnie rozwijana i przewidywać można wyodrębnianie kolejnych poziomów technologicznych, przekształcających wyobrażenie o formie prowadzenia upraw ogrodniczych.



2.3 Główny kierunek rozwoju od Ogrodnictwa 1.0 do Ogrodnictwa 4.0 [40]

Ogrodnictwo 4.0 klasyfikowane jest według stopnia zaawansowania wykorzystywanej technologii cyfryzacji wspomagającej produkcję [40]. Wyróżnia się trzy poziomy technologiczne:

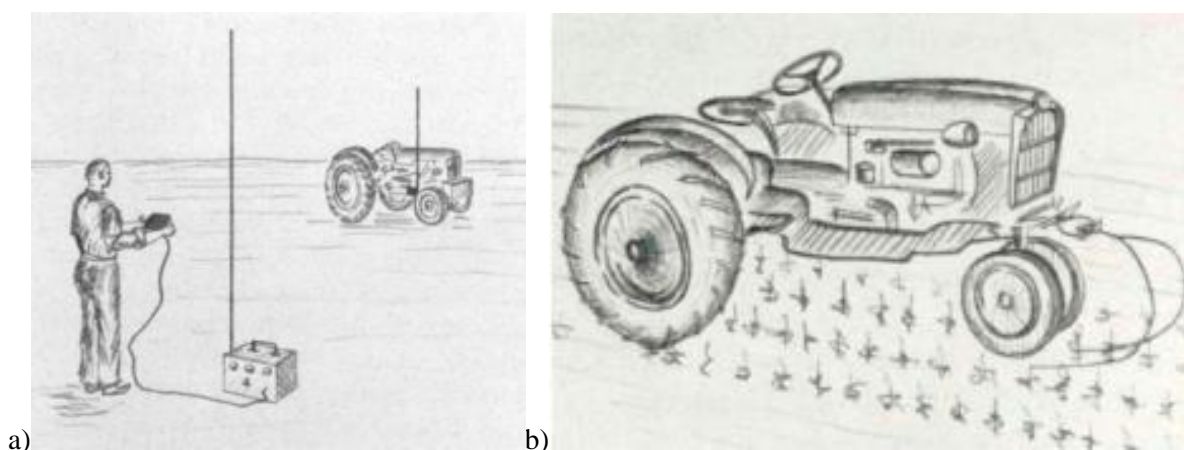
- poziom 1 – wykorzystywanie czujników monitorujących uprawy
- poziom 2 – przetwarzanie danych z monitoringu wspomagające decyzyjność
- poziom 3 – automatyzacja produkcji z wykorzystaniem systemów autonomicznych.

Wyodrębnienie przedstawionych poziomów jest w pełni uzasadnione i poparte analizą stanu wiedzy przedstawioną w podrozdziale 2.1.

## 2.3 Automatyka i robotyka w ogrodnictwie

Pierwsze badania w kierunku realizacji autonomicznych pojazdów w rolnictwie sięgają lat dwudziestych XX wieku, kiedy to Stanach Zjednoczonych opublikowano technikę prowadzenia ówczesnych ciągników według trajektorii wyznaczonej przez bruzdy na polach uprawnych [41]. Znaczny postęp w zwiększaniu autonomiczności pojazdów spowodował wykorzystanie do sterowania łączność radiowej. W czasie II wojny światowej wykorzystywane były niewielkie pojazdy sterowane drogą radiową, które w swojej konstrukcji przypominały małe czołgi, wypełniane zazwyczaj materiałami wybuchowymi. Po zdalnym wprowadzeniu takiego pojazdu na obszar przeciwnika następowała zdalna detonacja „bomby pułapki” [42, s. 19].

Po II wojnie światowej, ówczesne technologie, wykorzystywane głównie przez wojsko zaczęły być wdrażane do zastosowań cywilnych. W latach pięćdziesiątych zostało opracowanych szereg koncepcji sterowania bezprzewodowego ciągników rolniczych. Publikacje datowane na 1955 rok wskazują, że ciągnik marki Fordson Major był jednym z pierwszych prototypów ciągników wyposażonych w odbiornik sygnału radiowego (rys. 2.4a). Wykorzystanie 6-kanalowego nadajnika umożliwiło sterowanie za pomocą przekaźników układem hydraulicznym manewrującym ciągnikiem. W prototypowych rozwiązaniach zwracano szczególną uwagę na funkcje bezpieczeństwa, która w przypadku awarii zasilania lub utraty zasięgu sygnału radiowego była w stanie zatrzymać przepływ paliwa przez pompę w celu wyłączenia silnika. Prawidłowa praca kanałów transmisyjnych sygnalizowana była lampkami kontrolnymi zamontowanymi na panelu ciągnika. W kolejnych latach rozwijano technologię sterowania radiowego ciągników. W 1957 roku przedstawiono możliwość zadawania operatorowi prowadzącemu ciągnik sygnałów sterujących umożliwiających równoległe kierowanie drugim ciągnikiem, który został wyposażony w odbiornik, przekaźniki i hydrauliczny system sterowania. Później, w układach sterowania ciągnikami zaczęto wykorzystywać pierwsze cewki czujnikowe, które generowały sygnał oddziałujący poprzez wielostopniowe przekaźniki na układ hydrauliczny służący do obsługi kierownicy. Rozwiązanie to (rys. 2.4b) umożliwiło prowadzenie ciągnika po wyznaczonej prostej i pozwalało operatorowi na poświęcenie mniejszej uwagi na kontrolę wizualną trajektorii jazdy ciągnika [43].



Rys. 2.4 Pierwsze bezzałogowe metody sterowania ciągników rolniczych: a) koncepcja sterowania radiowego ciągnika Fordson [43], b) Szkic z 1958 roku przedstawiający koncepcje wykorzystania czujników toru jazdy [43]

Pierwsze wdrożenia wspomagające prowadzenie ciągnika w środowisku rzeczywistym datowane są na przełom lat 50-tych i 60-tych XX wieku. W pracach polowych zaprezentowany został wówczas ciągnik IMA (rys. 2.5a), do którego pierwotnych, ręcznych dźwigni sterujących dołączono elektryczne siłowniki. Ciągnik ten był sterowany poprzez przełączanie obwodów elektrycznych za

pomocą urządzenia radioelektrycznego. W tamtym okresie wdrażać zaczęto również systemy, które pozwalały na automatyczne podążanie za prostą lub lekko zakrzywioną bruzdą w ciągnikach gąsienicowych dużej mocy (Rys 2.5b). Przedstawione wdrożenia systemów sterowania radiowego opierały się na zdawaniu sygnałów sterujących i oddziaływaniu, poprzez elementy wykonawcze, hydrauliczne lub elektryczne, na dźwignie sterujące jazdą ciągnika. Nadzór na poprawnością realizacji każdej z operacji pełnił operator, który utrzymywał wzrokowy kontakt z prowadzonym pojazdem.



a)




b)

Rys. 2.5 Pierwsze wdrożenia ciągników bezzałogowych w rolnictwie:  
a) Ciągnik IMA zdalnie prowadzony ze stanowiska operatora [43],  
b) Ciągnik gąsienicowy S80 przystosowany do zdalnego prowadzenia [43]

Pierwsza prototypowa wersja bezzałogowego, programowalnego ciągnika powstała w latach 60-tych, pod nazwą BOPS-1960 (rys. 2.6a,b). Prototyp ten określić można, ze względu na zaprogramowany sposób sterowania umożliwiający poruszanie się ciągnika w rzeczywistym środowisku pracy, przez oznaczony czas bez ingerencji operatora, pierwszym ciągnikiem autonomicznym. Silniki i siłowniki elektryczne manewrowały dźwignią sprzęgła, hamulca, przepustnicy i hydraulicznym podnośnikiem. Nadzór nad elementami wykonawczymi pełniła jednostka nazwana mechanicznym programatorem krzywkowym. Programator sterował jednostką kierunkową i silnikami elektrycznymi sprzęgniętymi z odpowiednimi dźwigniami. Jednostka ta wydawała w odpowiednim czasie polecenia zgodnie z zaprogramowaną konfiguracją. Za utrzymanie kierunku jazdy i wykonywanie manewrów nawrotu o 90° odpowiadał żyroskop. Z przodu ciągnika zamontowany był mechaniczny czujnik bezpieczeństwa, który zatrzymywał ciągnik w przypadku najechania na przeszkodę.





Rys. 2.6 a) Pierwszy programowalny ciągnik autonomiczny BOPS-1960 [43] b) Panel sterowania ciągnika [43]

W latach 80-tych zaczęły powstawać koncepcje wykorzystania systemów wizyjnych do sterowania. Powstały pierwsze roboty do zbioru pomarańczy [44]. Roboty te ciągnięte były na platformie przez ciągnik i potrafiły identyfikować dojrzały owoc pomarańczy, analizując sekwencję wideo. Zrobotyzowany zbiór owoców umożliwiała specjalna konstrukcja ramienia roboczego. Poniżej przedstawiono fotografię elementów robota i jednostki sterującej (rys. 2.7).



Rys. 2.7 Pierwszy robot do zbioru owoców pomarańczy sterowany systemem wizyjnym [44]

Dane uzyskane z przetwarzania sygnału wizyjnego zaczęto wykorzystywać również do nawigacji ciągnika, który prowadzony był poprzez wyznaczanie trajektorii jazdy z obrazów otoczenia. Zastosowanie to jest ważne i intensywnie rozwijane, ponieważ od precyzji systemu nawigacji zależy poruszanie się robota z określoną dokładnością. Dodatkowo, globalne systemy pozycjonowania (GPS, ang. global positioning system) nie zapewniają skutecznej i wystarczająco dokładnej nawigacji w sadach, gdzie roboty poruszają się pod koronami drzew [45].

Współczesne ciągniki autonomiczne wykorzystywane w gospodarstwach rolniczych i sadowniczych można uznać za kolejne fazy rozwojowe koncepcji zapoczątkowanych w latach pięćdziesiątych ubiegłego wieku. Obecnie, metody sterowania jazdy i zadań autonomicznych wykorzystują zaawansowane technologie informatyczne. Połączenie funkcji jazdy autonomicznej z wykonywaniem zabiegów uprawowych przyczyniło się do powstania autonomicznych ciągników i pojazdów zrobotyzowanych mogących pracować na plantacjach. Dla upraw warzyw i owoców prowadzonych pod osłonami dostępne są już zrobotyzowane pojazdy gąsienicowe, które zastępują

człowieka w wykonywaniu prac szczególnie uciążliwych, takich jak np. opryski chemiczne. Prowadzone są również testy prototypowych rozwiązań przeznaczonych dla sadownictwa [46].

Przedstawiony na rysunku 2.8 elektryczny robot gaśnicowy realizować może autonomiczny oprysk winnicy. Pojazd ten umożliwi transport wody około 200 litrów i poruszanie się z maksymalną prędkością 3 km/h. Jest przystosowany do 8-godzinnej pracy w cyklu automatycznym, po czym wymaga ładowania baterii. Sterowanie pojazdem jest możliwe dzięki wyposażeniu go w kamerę stereowizyjną, odbiorniki RTK-DGPS (RTK-DGPS, ang. real time kinematic-differential global positioning system) oraz GNSS (GNSS, ang. Global Navigation Satellite System), system odniesienia położenia i kierunku AHRS (AHRS, ang. attitude and heading reference system), dalmierz skanera laserowego, czujniki ultradźwiękowe i enkodery silnika [47].



Rys. 2.8 Widok robota elektrycznego w trakcie pracy autonomicznej [47]

Dane z czujników służą do określenia pozycji i położenia pojazdu oraz odtwarzania trajektorii jazdy i omijania przeszkód. System sterowania zrealizowany został z użyciem minikomputera Raspberry Pi 3. Komunikacja w systemie sterownia wykorzystuje protokół sieciowy UDP (UDP, ang. user datagram protocol). Kamera stereowizyjna pełni funkcje czujnika wykrywającego przeszkody i pozwala na obserwację otoczenia poruszającego się robota. Robot z napędem elektrycznym sprzężony jest z opryskiwaczem, składającym się z układu hydraulicznego i modułu elektroniki sterującej. W skład układu hydraulicznego wchodzi: elektryczny zawór regulujący ciśnienie, czujnik ciśnienia, przepływomierz oraz elektrozawory umożliwiające dopływ cieczy do pionowych rurek na których zamieszczone są dysze wysokociśnieniowe rozpylające ciecz. System posiada czujnik prędkości wiatru sygnalizujący przekroczenie doświadczalnie ustalonego progu, zapewniającego pokrycie pyłem opryskiwanych roślin. Podczas ruchu, robot automatycznie aktywuje poszczególne zawory we właściwym punkcie trasy, według zaplanowanej mapy opryskiwania.

Na rysunku 2.9 przedstawiony został kolejny przykład autonomicznego robota do oprysków w sadzie. Podbudowę robota stanowi pojazd gaśnicowy sterowany przy zastosowaniu radaru laserowego, połączonego z radarem ultradźwiękowym. Pojazd napędzany jest silnikami elektrycznymi. Do napędu pompy zintegrowanej z robotem opryskiwacza i powietrznego wentylatora odśrodkowego zastosowany został dodatkowy silnik spalinowy. Zapewnia on odpowiednią moc dla powietrznego wentylatora odśrodkowego wdmuchującego pył w często gęstą koronę drzew. W zależności od wysokości wykrywanych drzew otwierane są kolejne dysze opryskiwacza umieszczone obustronnie na dwóch rurkach w kształcie łuku. Robot porusza się według precyzyjnie zaplanowanej trasy i ma możliwość detekcji przeszkód. Głównym czujnikiem pozwalającym na wyznaczenie mapy sadu jest lidar (lidar, ang. light detection and ranging). W oparciu o skonstruowaną mapę planowane są ścieżki przejazdu. Sterownik odtwarza zadaną trajektorię wykorzystując do rozpoznawania i omijania przeszkód czujniki radaru ultradźwiękowego i laserowego [48].





Rys. 2.9 Moduły autonomicznego robota sadowniczego [48]

Polskim opracowaniem systemu sterowania ciągnikiem autonomicznym i opryskiwaczem sadowniczym jest Auto Drive – system jazdy autonomicznej firmy GOtrack. System Auto Drive (rys. 2.10) umożliwia bezzałogową (w trybie autonomicznym) pracę odpowiednio zmodernizowanego ciągnika i opryskiwacza. Do pozycjonowania ciągnika z opryskiwaczem wykorzystywane są dane nawigacyjne z systemu GPS-RTK oraz lokalne urządzenia wizyjne. Funkcje jakie posiada system to: zdalne uruchamianie i gaszenie silnika, autonomiczne prowadzenie z rozpoznawaniem przeszkód na drodze. Tor jazdy i parametry sterujące opryskiwaczem w trakcie przejazdów są odtwarzane z wcześniej zgromadzonych danych i monitorowane w trakcie przejazdów. System dedykowany jest do oprysków sadowniczych, koszenia trawy oraz zabiegów agregacji. Programowanie systemu polega na wykonaniu przejazdu referencyjnego i zapisaniu utworzonych danych. Na tej podstawie realizowane są kolejne przejazdy autonomiczne. Do zainstalowania opracowanego systemu sterowania w klasycznym ciągniku wymagane jest zamontowanie dodatkowych napędów, czujników i jednostki sterującej. Odpowiedniego przystosowania wymaga również opryskiwacz poprzez zainstalowanie elektrozaworów, czujników ciśnienia i czujników prędkości. W ofercie firmy GOtrack dostępna jest opcja wyposażenia ciągnika w kamery wraz z implementacją algorytmów wykorzystujących sztuczną inteligencję do wykrywania i klasyfikowania obiektów: człowiek, zwierzęta, drzewa, pojazdy, ogrodzenie [49].



Rys. 2.10 Ciągnik i opryskiwacz sadowniczy z zainstalowanym systemem Auto Drive [49]

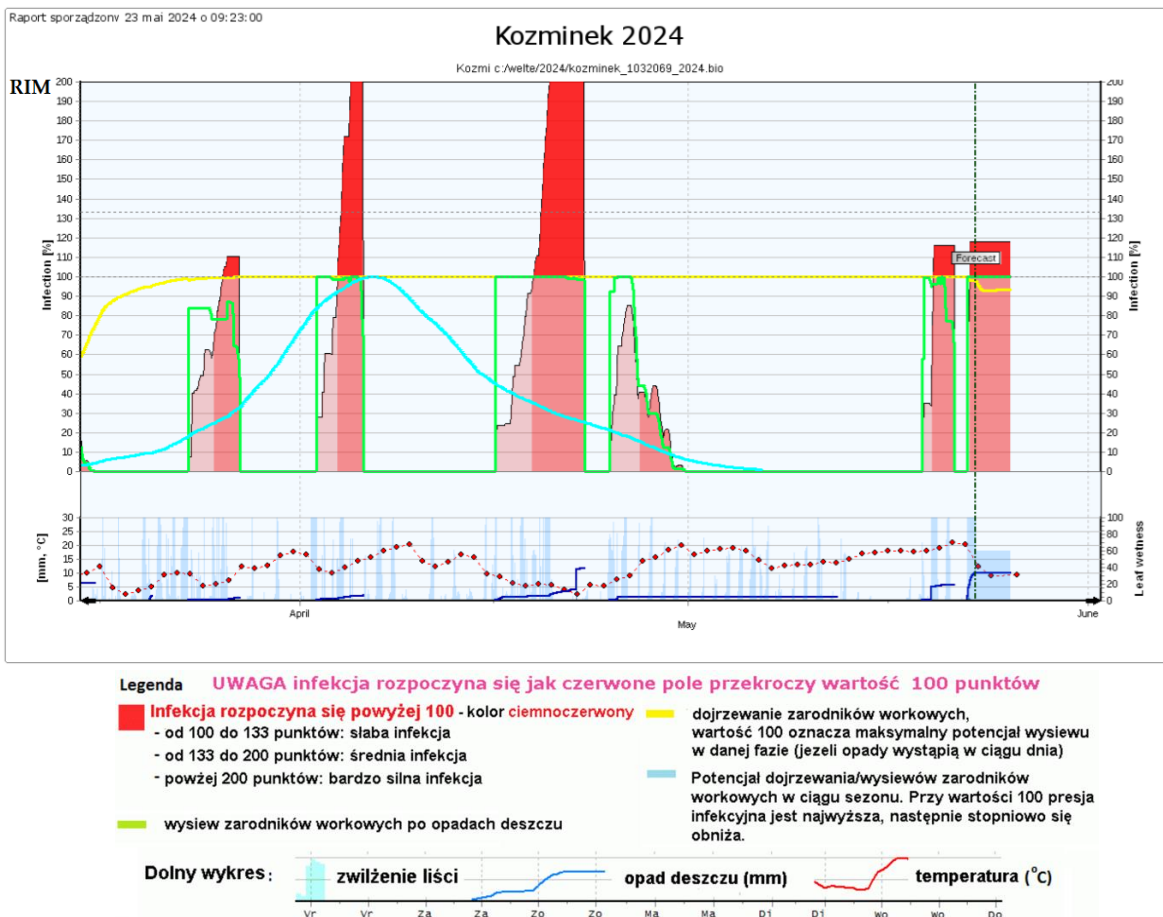
## 2.4 Rozpoznawanie chorób drzew i szkodników ogrodniczych

Skuteczna ochrona przed chorobami i szkodnikami sadowniczymi polega głównie na prewencji mającej na celu nie dopuścić do rozwoju patogenów grzybowych lub larw, powodujących degradację tkanki zielonej drzewa oraz robaczywienie owoców. W podrozdziale przedstawiono genezę występowania przykładowej choroby grzybowej drzew owocowych, tj. parcha jabłoni oraz genezę występowania przykładowego szkodnika owoców w postaci nasionnicy trześniówki wraz ze stosowaną w praktyce sadowniczej strategią ochronną.

Ochrona przed chorobami i szkodnikami sadów polega głównie na profilaktyce, aby nie dopuścić do rozwoju patogenów grzybów oraz larw powodujących degradację tkanek zielonych drzew lub robaczywienie owoców. W przyrodzie występować może nieregularna sezonowość inwazji niektórych rodzajów chorób lub szkodników oraz nieprawidłowości ich w nasileniu. Czynniki te sprawiają, że w pełni uzasadnione jest monitorowanie zagrożeń w czasie rzeczywistym oraz konieczność posiadania aktualnych informacji z inspekcji plantacji, w celu podejmowania decyzji o wykonaniu określonego zabiegu ochronnego lub interwencyjnego. Należy również podkreślić, że wykonywanie oprysku uzależnione jest od określonych warunków atmosferycznych, w których skuteczność wykonywanego zabiegu jest najwyższa.

### 2.4.1 Infekcje grzybowe


Parch jabłoni (łac. *Venturia inaequalis*) - rozwój i wysiew zarodników grzyba następuje w określonych warunkach pogodowych, dlatego szczególne znaczenie w skutecznej ochronie przed parchem jabłoni ma śledzenie czynników atmosferycznych. Skutki infekcji dla owoców jabłoni widoczne są na rysunku 2.13a. Specjalistyczne stacje pogodowe dostarczają aktualnych informacji o zmianach temperatury, opadów, wilgotności powietrza i ciśnienia powietrza. Informacje te, skorelowane z doświadczeniem, ustalonym modelem rozwoju i przebiegiem infekcji grzybowych (rys. 2.11) są źródłem wiedzy, na podstawie której podejmuje się decyzję o wykonaniu zabiegu ochronnego. W okresie wegetacyjnym może wystąpić od kilku do nawet kilkunastu infekcji, które wymagają zabiegów profilaktycznych lub interwencyjnych. Infekcja rozpoczyna się, gdy na ustalonej doświadczalnie skali modelu zostaje przekroczona wartość 100 parametru RIM (RIM, ang. relative infection measure) [50].




Rys. 2.11 Wykres przebiegu infekcji grzybowych i warunków meteorologicznych dla przykładowego obszaru Polski (rejon Koźminek, sezon wegetacyjny 2024) [51]

## 2.4.2 Szkodniki owoców

Nasionnica trześniówka (łac. *Rhagoletis cerasi*) od wielu lat jest groźnym szkodnikiem nie tylko w sadach czereśniowych, ale także w wiśniowych. Skuteczne zwalczanie utrudnia fakt, iż odróżnienie owoców nieuszkodzonych od zaatakowanych przez larwy jest prawie niemożliwe. W czasie infekcji uprawy zapłodniona samica szkodnika składa jaja wewnątrz rozwijającego się owocu, nacinając skórę. Z jaj wylęgają się larwy o długości około 4 mm, w kolorze białym. Powodują robaczywienie owoców nienadających się do spożycia i przetwórstwa przemysłowego (rys. 2.13b). W polskim położeniu geograficznym, przy określonych warunkach pogodowych pojawienie się tych owadów obserwuje się już w połowie maja. W okresie dojrzewania owoców czereśni występuje kilka pokoleń szkodników, które wymagają opryskiwania ciągnikiem z opryskiwaczem sadowniczym. W celu wykrycia szkodnika nasionnicy trześniówki na plantacjach owocowych, zawiesza się pułapki z atraktorem wabiącym owada (rys. 2.12). Zaobserwowanie odłowów owadów na pułapkę w ustalonej eksperymentalnie ilości (2 sztuki), jako progu ekonomicznej szkodliwości dla czereśni, jest sygnalizacją do podjęcia decyzji o zastosowaniu zabiegu ochronnego [52].



Rys. 2.12 Widok pułapki z odłowionymi owadami nasionnicy trześniówki (opracowanie własne)




Rys. 2.13 Porażone owoce: a) jabłoni – porażone parchem,  
b) czereśni – zainfekowane larwą nasionnicy trześniówki (opracowanie własne)

Przedstawiony rodzaj choroby i szkodnika plantacji sadowniczych stanowią jedynie przykład reprezentujący genezę zagrożenia i sposób ochrony przed nim. W praktyce sadowniczej wyróżnia się dla danych odmian specyficzne choroby i szkodniki, które wymagają dedykowanych strategii ochronnych. Objawy występujących infekcji często uwidaczniają się na liściach drzew, powodując np. zmianę ich koloru a z biegiem czasu zasychanie całych gałęzi. Taki uwidoczniiony efekt występowania ułatwia klasyfikacje zainfekowanych drzew lub obszarów plantacji.

## 2.5 System wizyjny w sadownictwie

W podrozdziale przedstawiono stan wiedzy z obszaru metod automatycznej analizy obrazu. W pierwszej części omówiono zadanie klasyfikacji oraz metody, które są w nim stosowane. Następnie poddane analizie zostały metody i rozwiązania przedstawione w literaturze, które mogą być wykorzystane również do automatycznego rozpoznawania szkodników oraz w rozpoznawaniu chorób sadowniczych na obrazach z kamery.

Proces automatycznej analizy obrazu w celu klasyfikacji obiektów, typowo obejmuje akwizycję obrazu, wstępne przetwarzanie oraz właściwą jego analizę (rys. 2.14).



Rys 2.14 Podstawowy schemat przetwarzania obrazu w zadaniu klasyfikacji obiektów

### 2.5.1 Akwizycja obrazu

Akwizycja obrazu ma za zadanie zarejestrowanie pojedynczych obrazów lub sekwencji wizyjnych z otoczenia za pomocą kamery. Na etapie akwizycji obrazu istotny jest odpowiedni dobór kamery. Do najczęściej wykorzystywanych rodzajów kamer zaliczamy kamery monochromatyczne, kolorowe, pracujące w zakresie fal niewidzialnych, np. podczerwieni, termowizyjne. Obrazy z kamery mogą być rejestrowane lub przesyłane do dalszej analizy. Współczesne kamery, już na etapie akwizycji, dokonują pewnych przekształceń danych z przetwornika obrazowego, aby uzyskać obraz jak najlepszej jakości i przekształcają je do odpowiedniego formatu. Na tym etapie również często dokonywana jest kompresja stratna obrazu.

Przy akwizycji obrazu nie mniej ważna jest kalibracja kamery, która uwzględnia i koryguje niedoskonałości parametrów wewnętrznych i zewnętrznych kamery. Parametry wewnętrzne, obejmują ogniskową układu optycznego kamery, punkt główny (punkt, w którym oś optyczna przecina płaszczyznę obrazu) i zniekształcenia obiektywu. Parametry zewnętrzne odnoszą się do pozycji i orientacji kamery w przestrzeni. Są one niezbędne do określenia, jak obraz z kamery odnosi się do rzeczywistego świata. To wiąże się z koniecznością zarejestrowania odpowiedniego obszaru obrazu obejmującego tzw. obszar zainteresowania (ROI, ang. region of interest), w którym znajdują się obiekty wymagane do dalszej analizy (np. drzewa owocowe).

### 2.5.2 Wstępne przetwarzanie

Na etapie wstępnego przetwarzania najczęściej obraz przekształcany jest do przestrzeni, w której możliwe jest odseparowanie danych istotnych od nieistotnych (lub mniej istotnych). Przykładowo, jeżeli do wykrycia obiektu wystarczy informacja o jego jasności, obraz może być przekształcony do formatu monochromatycznego. Jeżeli istotna jest informacja o kolorze, a nie o jasności, to obraz z matrycy RGB (RGB, ang. red, green, blue) przekształcany jest np. do formatu HSV (ang. hue, saturation, value, odcień, nasycenie, wartość), a do dalszej analizy brany jest tylko jeden wymiar, np. odcień [53].

Na etapie przetwarzania wstępnego często usuwany jest też szum oraz poprawiany jest kontrast, tak aby ułatwić dalszą analizę obrazu, poprzez uwypuklając wybrane cechy obrazu. Obraz może mieć zmniejszoną (poprzez decymację) lub zwiększoną rozdzielczość poprzez zastosowanie



interpolacji, np. dwusześciennej (ang. bicubic interpolation), która wyostrza obraz. Dodatkowe użycie filtrów, np. uśredniających wygładza i redukuje szумы w obrazie.

Wykonywane na tym etapie operacje i przekształcenia obrazów mają przygotować próbki możliwie najwyższej jakości do kolejnego etapu klasyfikacji obiektów.

### 2.5.3 Klasyfikacja obiektów

Proces klasyfikacji obiektów jest klasycznym zadaniem w przetwarzaniu obrazów oraz uczeniu maszynowym. Polega na automatycznej analizie obrazu i określeniu, do której klasy obiektów należy obiekt zarejestrowany na obrazie. Z etapu klasyfikacji obiektów można wyodrębnić dwa etapy: etap ekstrakcji cech oraz etap walidacji obrazu z wybranym klasyfikatorem.

Ekstrakcja cech służy do redukcji informacji (kompresji) opisującej obiekt i wyodrębnieniu tylko istotnych cech, na podstawie których będzie podejmowana ostateczna decyzja. W literaturze istnieje wiele propozycji skutecznych ekstraktorów cech używanych do wykrywania obiektów. Pierwszą grupę metod stanowią metody, które opierają się na ogólnie określonej architekturze cech, takich jak histogramy zorientowanych gradientów (HOG, ang. histogram of oriented gradients) [54], lokalne wzory binarne (LBP, ang. local binary pattern) [55], deskryptory 1D/2D Haara [56], oraz ich inne kombinacje [57], [58], [59], [60], [61]. Jednymi z bardziej wydajnych rozwiązań są także: metoda ICF (ICF, ang. integral channel features) [62], gdzie deskryptory HOG są używane razem ze składowymi luminancji i chrominancji, metoda ACF (ACF, ang. aggregated channel features) [63] łącząca cechy HOG wraz ze znormalizowaną wartością gradientu i kanałów kolorów LUV, oraz Checkerboards [64], które jest modyfikacją ICF, wykorzystującą filtrowanie kanałów HOG+LUV. Drugą grupę metod reprezentują splotowe sieci neuronowe CNN (CNN, ang. convolutional neural networks), które uczą się najkorzystniejszej reprezentacji cech w trakcie procesu trenowania. **Sieci neuronowe** stanowią jeden z najistotniejszych obszarów w dziedzinie uczenia maszynowego, który dominuje w wielu zastosowaniach przemysłowych. Zdolność sieci do modelowania złożonych wzorców i zdolność adaptacji do nowych danych przyczyniła się do znaczących postępów w dziedzinach takich jak: rozpoznawanie obrazów, prognozowanie szeregów czasowych i przetwarzanie języka naturalnego. W literaturze dostępny jest duży wybór architektur CNN, które na przestrzeni ostatnich kilku lat istotnie się rozwijały. Do najważniejszych architektur CNN należą: AlexNet/CaffeNet [65], [66] (jako historycznie pierwsza znacząca sieć CNN), VGG [67], ResNet [68], Xception [69], NasNet (w wersji Large oraz Mobile) [70], EfficientNet and EfficientNetV2 [71], [72], [73].

Na etapie walidacji wykorzystuje się różne kategorie klasyfikatorów: maszyny wektorów nośnych SVM, drzewa decyzyjne tj. AdaBoost (wykorzystywany np. w detektorze ACF), sieci neuronowe (w tym: macierze neuronów, samoorganizujące się mapy [74], [75] głębokie CNN) oraz różne ich kombinacje.

Sam proces klasyfikacji polega na kategoryzacji obiektów w obrazie w oparciu o podobieństwa i różnice. Klasyfikacja przebiegać może w sposób nadzorowany i nienadzorowany. W klasyfikacji nienadzorowanej grupowanie pikseli odbywa się za pomocą analizy obrazu bez dodatkowych danych trenujących. W klasyfikacji nadzorowanej użytkownik wybiera odpowiednie obszary na obrazie, które są wskazane do odpowiednich klas. Następnie algorytm wizyjny wykorzystuje wskazany zbiór danych jako odniesienie do procesu klasyfikacji obiektów na obrazie. Przykładem metody klasyfikacji nadzorowanej w identyfikacji typów szkodników jest zastosowanie SVM, która jest najbardziej efektywna pod warunkiem, że liczba wymiarów jest większa niż liczba próbek.

W pracy [76], do wstępnej selekcji wykorzystano klasyfikator AdaBoost, natomiast do ostatecznej weryfikacji klasyfikator SVM. W publikacji [77] zaproponowano połączenie AdaBoost

z siecią neuronową łączy funkcjonalnego wektora losowego. W pracy [78] zastosowano równoległe połączenie różnych klasyfikatorów, trenowanych w sposób komplementarny względem siebie. Rezultatem była wyższa dokładność, ale kosztem niższej wydajności.

Część walidacyjna w modelach głębokich sieci neuronowych może być zrealizowana za pomocą w pełni połączonych warstw sieci neuronowej (ang. fully connected layer). Stosowane są także inne rozwiązania. W pracy [79] wykorzystano głęboką sieć neuronową do celów klasyfikacji z wykorzystaniem informacji wielospektralnych, a w pracy [80] autorzy zastosowali CNN razem z klasyfikatorem AdaBoost.


Porównując modele sztucznych sieci neuronowych, wykorzystywane w badaniach nad klasyfikacją chorób liści w ogrodnictwie, zauważyć należy, że modele te mają wspólne cechy takie jak: operacje splotu, a różnią się głównie liczbą warstw określającą ich głębokość oraz rozmiarem analizowanych danych wejściowych. Warto przytoczyć tu kilka najpopularniejszych rozwiązań. GoogLeNet to rodzaj niewielkiej CNN, która wyodrębnia przestrzenną lokalizację pikseli obrazu na różnych poziomach ziarnistości. Architektura ShuffleNet pozwoliła na zminimalizowanie liczby wymaganych operacji, a poprzez wprowadzenie procesu losowego poprawiła wydajność modelu GoogLeNet. Modele takie jak Inception v3 należą do modeli głębokich, czyli posiadają większą liczbę warstw, co umożliwia efektywniej wyodrębnić cechy analizowanych obiektów. DenseNet-201 to model, który rozwiązuje problem zanikającego gradientu, poprzez zastosowanie wielowarstwowych połączeń typu feed-forward. Model Xception to multipołączenie oparte na CNN, gdzie w warstwach sieci występuje przetwarzanie równoległe. Transfer learning pozwala na dostosowanie wstępnie przeszkolonych modeli do innych zastosowań. Przy wymaganiu wysokich skutecznościach w rozpoznawaniu chorób, zasadne jest implementowanie modeli w aplikacjach wykorzystujących najnowsze rozwiązania w obszarze sztucznej inteligencji np. na smartfony, co ułatwić może ochronę sadów oraz być narzędziem dla sadowników z mniejszymi zasobami wiedzy specjalistycznej. Szczegółowy opis wybranych do badań eksperymentalnych modeli splotowych sieci neuronowych przedstawiony został w podrozdziale 3.4.

#### **2.5.4 Automatyczne rozpoznawanie szkodników w sadownictwie**

Szkodnikami powodującymi najbardziej znaczące straty w produkcji sadowniczej są owocówki i nasionnice (por. rozdział 2.4.2). Poza regularnie występującymi pokoleniami szkodnika, w sezonie produkcyjnym owoców pojawić się mogą dodatkowe pokolenia lub nieoczekiwane inwazje. W zintegrowanych uprawach sadowniczych dąży się do ograniczania stosowania środków owadobójczych. Dokonując właściwej lustracji feromonowych pułapek rozmieszczanych na terenie danego sadu, które odławiają pojawiające się szkodniki, można uzyskać precyzyjne informacje o konieczności wykonania zabiegu ochronnego. Lustracje klasyczne regularnie wykonywane przez plantatora lub doświadczonych ekspertów są czasochłonne i powodują generowanie kosztów.

Koncepcje automatycznego systemu monitorowania występowania szkodników powinny uwzględniać znajomości fenologii szkodników i wpływu na nią czynników klimatycznych. Rysunek 2.15 przedstawia przykładową strukturę automatycznego systemu monitorowania, w którym monitoring rozpoczyna się od śledzenia i analizy czynników klimatycznych [81]. Spośród analizowanych czynników klimatycznych system wyodrębnia te czynniki, które zwiększają ryzyko wystąpienia szkodników. Następnie monitorowany jest rozwój szkodników według ich fenologii i poprzez odławianie na pułapkach feromonowych. Obraz pułapek feromonowych ze szkodnikami odczytywany jest za pomocą kamer wizyjnych. Dane te służą do automatycznego rozpoznawania szkodników i podejmowania decyzji o podjęciu działań w celu ich zwalczania, po przekroczeniu liczebności owadów powodującej wejście w próg uznawany za szkodliwość ekonomiczną. Założeniem prezentowanego systemu monitoringu jest ekonomiczna produkcja sadownicza z minimalizacją stosowania środków chemicznych, poprzez ich precyzyjne dozowanie

w czasie, którym ich efektywność stosowania jest wskazana, dozwolona i najwyższa [81]. W oparciu o przedstawione założenia istnieje potrzeba udoskonalania technik monitorowania pułapek feromonowych w czasie rzeczywistym. Opracowywanie algorytmów przetwarzających dane z monitoringu plantacji powinno uwzględniać typ szkodników występujących w danej plantacji owoców.



Rys. 2.15 Koncepcja automatycznego systemu monitorowania szkodników sadowniczych [81]

#### a. Metody i algorytmy obliczeniowe







Elementarną częścią systemów automatycznego monitorowania plantacji są algorytmy przetwarzania danych. W literaturze, jednym z spotykanych podejść, jest przetwarzanie obrazów z wykorzystaniem algorytmów wizyjnych [82]. Algorytmy te muszą przede wszystkim dokonywać detekcji szkodników z zarejestrowanych obrazów i zliczać liczbę szkodników. Efektem przetwarzania pozyskanego obrazu wejściowego jest uzyskanie obrazu wyjściowego pozwalającego na jednoznaczną klasyfikację odłowionego szkodnika. Proces przetwarzania obrazu składa się z kilku etapów. Na początku, po pozyskaniu obrazów z uprawy ogrodniczej, następuje wykonywanie operacji wstępnego przetwarzania (por. rozdział 2.5.2). W kolejnym etapie, dokonywana jest ekstrakcja cech, w celu rozróżnienia obiektów na obrazie. Poszukiwanie podobnych obiektów może odbywać się przy udziale różnych typów cech takich jak: kształt, tekstura, kolor. Funkcja koloru wykorzystywana może być do trenowania maszyny wektorów nośnych (SVM) celem klasyfikacji obszarów ze szkodnikami i obszarów z liśćmi. Funkcja koloru służyć może również do klasyfikacji samych szkodników różniących się kolorem. Rozdzielenie koloru na składowe RGB powoduje redukcję ilości danych do przetworzenia. Identyfikacja szkodnika oparta jest wówczas na obliczeniu różnicy barwy pomiędzy pikselami.

Po identyfikacji szkodników często stosowane są operacje morfologiczne umożliwiające usunięcie niechcianych elementów ze sklasyfikowanego obrazu. W tym celu stosuje się operacje erozji i dylatacji. Dodatkowym problemem w identyfikacji szkodnika z wykorzystaniem kolorów pikseli na obrazie są zmieniające się warunki oświetlenia, co zmienia intensywność koloru, na obrazach dodatkowo mogą pojawiać się cienie. Światło słoneczne ma również tendencje do odbijania się od liści. Zdarza się również, że szkodniki mogą mieć taki sam kolor jak liść.



Tabela 2.1 przedstawia obrazy przykładowych szkodników plantacji uprawowych pozyskanych z monitoringu plantacji i obrazy szkodników po przetworzeniu opisaną powyżej metodą.

Tabela 2.1. Identyfikacja szkodnika z wykorzystaniem SVM [82]

Nazwa szkodnika	Obraz wejściowy	Obraz wyjściowy
Białe muszki		
Mszyce		
Ćma kapusty		

### b. Sprzęt i przykłady realizacji


Jednym z kluczowych etapów w procesie automatycznego monitoringu jest odpowiednie rozpoznawanie odłowionych na pułapkach feromonowych szkodników. W ostatnich latach zauważa się propozycje monitorowania występowania szkodników za pomocą pułapek elektronicznych. Pozwalają one, poza precyzyjną detekcją szkodników, na ograniczenie codziennych wyjazdów do sadów, często odległych, więc również potencjalnie przyczyniają się do oszczędności czasu i paliwa. Spotykane rodzaje pułapek to:

- Pułapki elektroniczne wyposażone w soczewkę Fresnela (rys. 2.16) – pułapka posiada czujnik optoelektroniczny i stereofoniczne urządzenie rejestrujące uderzenia skrzydeł owada szkodnika w locie. Wykrycie owada powoduje sygnalizację.



Rys. 2.16 Pułapka elektroniczna na owady szkodników [83]

- Pułapka zbudowana z użyciem smartfonu (rys. 2.17), która cyklicznie wykonuje zdjęcia i przesyła je w celu identyfikacji szkodników przez plantatora [84]. Pułapka posiada dodatkową baterię przedłużającą czas użytkowania bez ładowania i klasyczny wabik z feromonem. Przezroczysta i pokryta klejem ściana dolna zatrzymuje szkodnika w trwałej pozycji, co umożliwi analizę przyrostu szkodników w odstępach wykonania i przesłania kolejnych zdjęć.



Rys. 2.17 Schemat pułapki ze smartfonem [84]

Pułapki elektroniczne z monitoringiem wizyjnym wykorzystywane są najefektywniej, jeśli przesyłają obraz do dalszych analiz w czasie rzeczywistym. Rysunek 2.18 przedstawia jeden z systemów automatycznego monitorowania [85], gdzie obraz do dalszej analizy przesyłany jest za pośrednictwem sieci bezprzewodowej. System ten składa się z bezprzewodowych stanowisk monitorujących plantacje, które przesyłają informacje za pośrednictwem systemu GSM (GSM, ang. global system for mobile telecommunication). Stanowiska wysyłają na serwer obrazy z zarejestrowanymi szkodnikami trafiające do bazy danych, gdzie podlegają przetwarzaniu w celu identyfikacji szkodników. Z serwera do plantatora może zostać wysłany komunikat ostrzegawczy o zagrożeniu infekcji rozpoznanego szkodnika.



Rys. 2.18 System automatycznego monitorowania szkodników drzew owocowych [85]

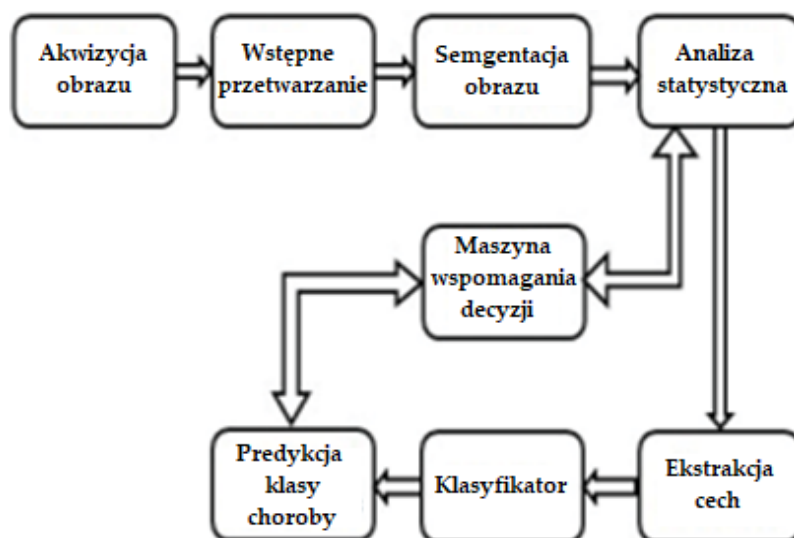
## 2.5.5 Automatyczne rozpoznawanie chorób w sadownictwie

Automatyczne rozpoznawanie chorób drzew i krzewów sadowniczych na podstawie przetwarzania obrazów osiągnęło wysoką skuteczność dzięki użyciu modeli głębokich, spłotowych sieci neuronowych. Algorytmy sztucznej inteligencji są wykorzystywane także przy analizie danych, na podstawie których określana jest sygnalizacja zagrożenia wystąpienia infekcji. Przedstawiony na rysunku 2.11 przebieg infekcji grzybowej parcha jabłoni, uzyskany został z matematycznego modelu chorobowego. Model ten, na podstawie analizy danych, wyodrębnia najbardziej kluczowy wynik, opisany parametrem RIM (patrz rozdział 2.4.1). Po przekroczeniu doświadczalnie ustalonej wartości progowej RIM sygnalizowany jest początek przebiegu infekcji, co oznacza konieczność wykonania zabiegu ochronnego plantacji. Całościowa analiza modelu chorobowego parcha jabłoni nie leży w zakresie tematyki niniejszej rozprawy doktorskiej.

W celu podniesienia precyzji sygnalizacji wyniku wskaźnika modelowego, pomocne jest dodatkowe zastosowanie na plantacji sadowniczej kamery z algorytmem obliczającym czas zwilżenia liści. Automatyczna lustracja plantacji w czasie rzeczywistym, odbywać się może z wykorzystaniem kamer stacjonarnych lub ruchomych (np. przymocowanych do karoserii ciągnika i zbierających informacje inspekcyjne w trakcie wykonywania oprysków ochronnych), a także aplikacji dla telefonów komórkowych.

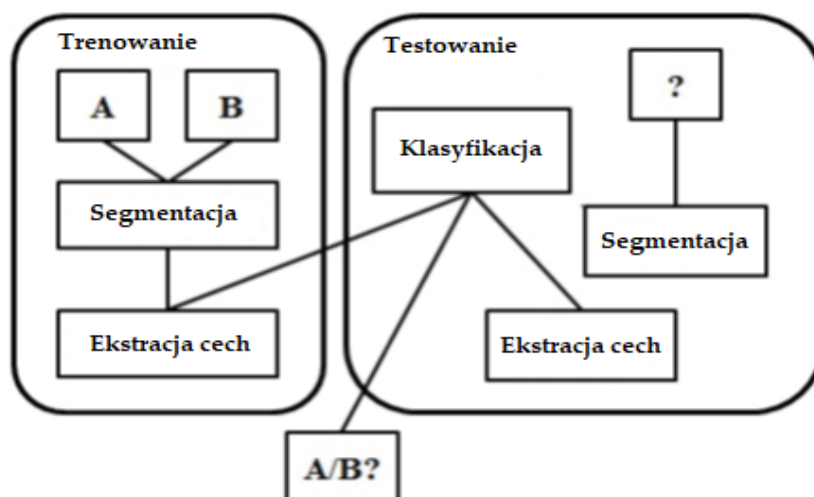
### a. Metody i algorytmy obliczeniowe

Aplikacje mobilne dla współczesnych telefonów komórkowych pozwalają na automatyczną klasyfikację chorób liści w czasie rzeczywistym z wykorzystaniem sztucznych sieci neuronowych. Wykonane zdjęcie liścia przesyłane jest na serwer w celu dokonania klasyfikacji, po której następuje informacja zwrotna o typie rozpoznanej infekcji. Jedną z takich aplikacji dedykowaną jest do rozpoznawania i klasyfikacji chorób krzewów winogron [86]. Algorytm analizy obrazu podzielony jest na cztery etapy. Pierwszy etap to akwizycja obrazu liścia winogrona za pomocą kamery w telefonie komórkowym. W drugim etapie stosowane jest wstępne przetwarzanie obrazu wejściowego, gdzie dokonywana jest segmentacja obszaru zainfekowania. Trzecim krokiem jest wyodrębnienie cech na podstawie właściwości, takich jak: kolor, korelacja, jednorodność, kontrast. W ostatnim kroku przeprowadzana jest analiza statystyczna cech i ostateczna klasyfikacja za pomocą maszyny wektorów nośnych SVM, która klasyfikuje liście krzewu winogrona do jednej z dwóch klas: jako zdrowe lub chore (rys. 2.19).



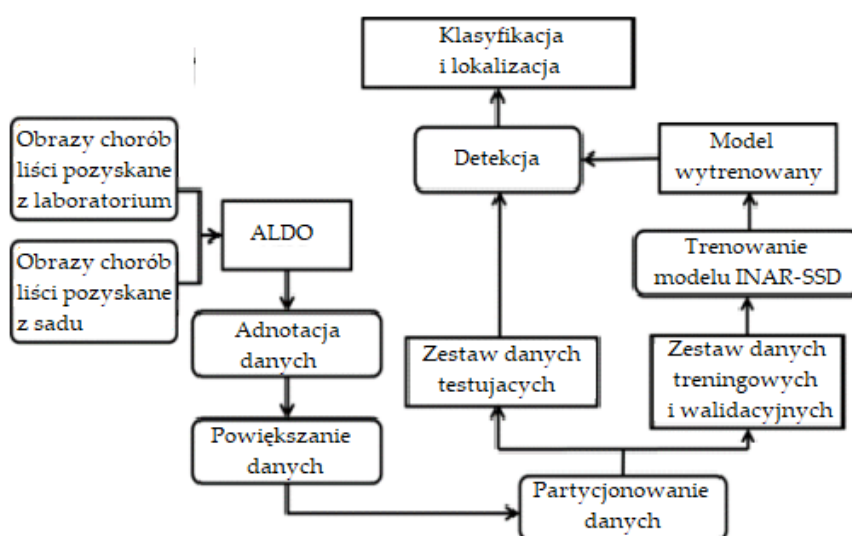
Rys. 2.19 Ogólny schemat blokowy systemu wykrywania chorób [86]

Klasyfikacja obejmuje proces uczenia i testowania, gdzie porównuje się cechy liści wyodrębnione ze zbioru treningowego z cechami liści ze zbioru testowego (rys. 2.20). Obrazy są klasyfikowane na podstawie dopasowanych cech. Przy klasyfikacji wykorzystuje się również zasadę minimalizacji ryzyka strukturalnego, która maksymalizuje margines separujący klasy dla dokładniejszej generalizacji SVM. W przedstawionej metodzie, opisanej w pracy [86], uzyskane dokładności klasyfikacji na zdrowe i chore liście osiągają 96.66 %.



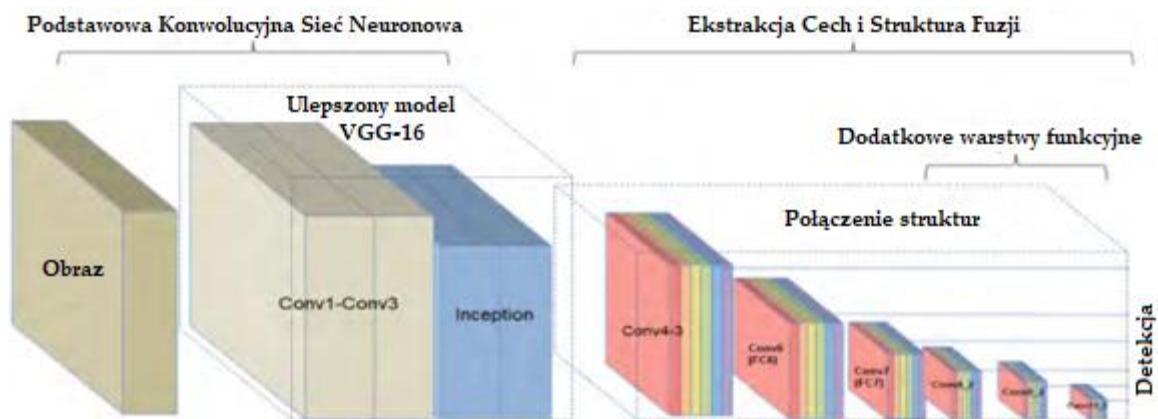
Rys. 2.20 Schemat procesu klasyfikacji [86]

W pracy [87] przedstawiono metody rozpoznawania głównych rodzajów chorób liści jabłoni z użyciem algorytmów przetwarzania obrazu i udoskonalonych spłotowych sieci neuronowych CNN (rys. 2.21). Zbiór danych dotyczących chorób liści jabłoni został utworzony przy użyciu technologii powiększania danych i adnotacji obrazów. Celem anotacji obrazu było oznaczenie pozycji i przyporządkowania do klas obiektów na obrazach z widocznymi chorobami. Po dodaniu anotacji do obrazów, program generuje pliki, które zawierają informacje, takie jak: wartości współrzędnych ramek ograniczających każdą zmianę na liściu oraz klasy chorób. Do opracowania modelu INAR-SSD [87] do wykrywania chorób liści jabłoni, wykorzystującego CNN, zastosowane zostały struktury modeli GoogLeNetInception i konkatenacja Rainbow. Model ten został wytrenowany do wykrywania głównych chorób liści jabłoni z dokładnością 78.80 %.



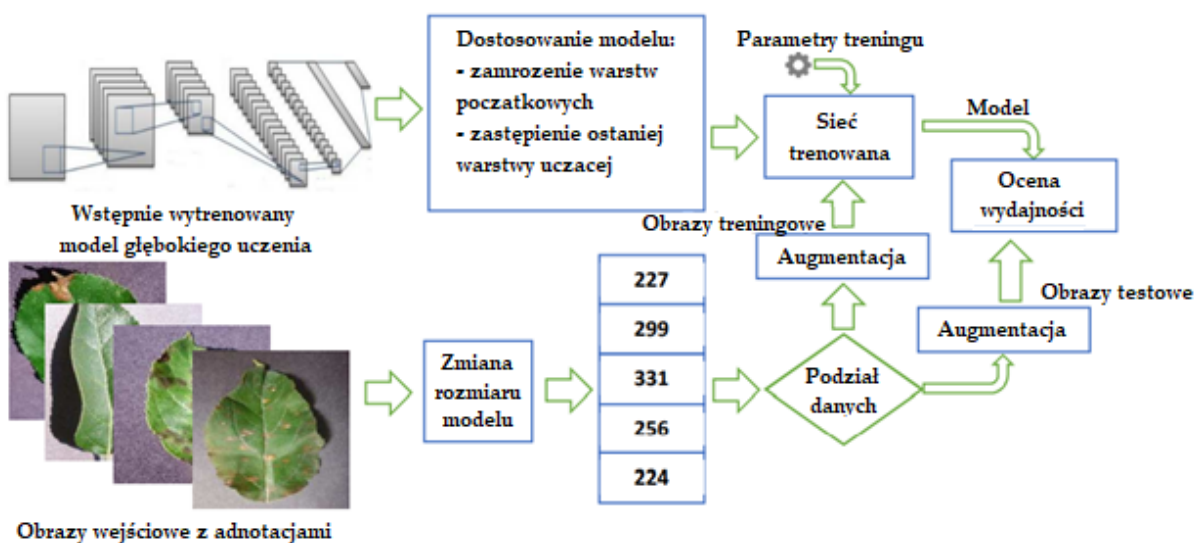
Rys 2.21 Schemat blokowy wykrywania chorób liści w czasie rzeczywistym [87]

Do modelu dostarczane są obrazy zdjęć liści z infekcjami chorobowymi zidentyfikowane w warunkach laboratoryjnych oraz obrazy dostarczone z plantacji sadowniczej. INAR-SSD dokonuje detekcji w czasie rzeczywistym. Zbudowany jest z podstawowej, wstępnej CNN oraz ekstraktora cech i struktury fuzji danych. Model pozwala na poprawę wieloskalowej ekstrakcji cech, poprzez dodanie do modelu VGG-16 dwóch modułów Inception (rys. 2.22). VGG-INCEP pozwala na rozwiązanie problemu detekcji plam chorobowych o różnych rozmiarach na tym samym liściu. Metoda Rainbow Concatenation została użyta w celu poprawy dokładności wykrywania małych obiektów, w tym przypadku, plam chorobowych na liściach. SSD jest jednoetapową metodą detekcji, która może przewidywać typy obiektów i współrzędne konturów. Szybkość detekcji SSD jest większa niż szybkiego R-CNN, przy porównywalnej dokładności obu metod [88].



Rys. 2.22 Ogólna struktura modelu INAR-SSD [87]

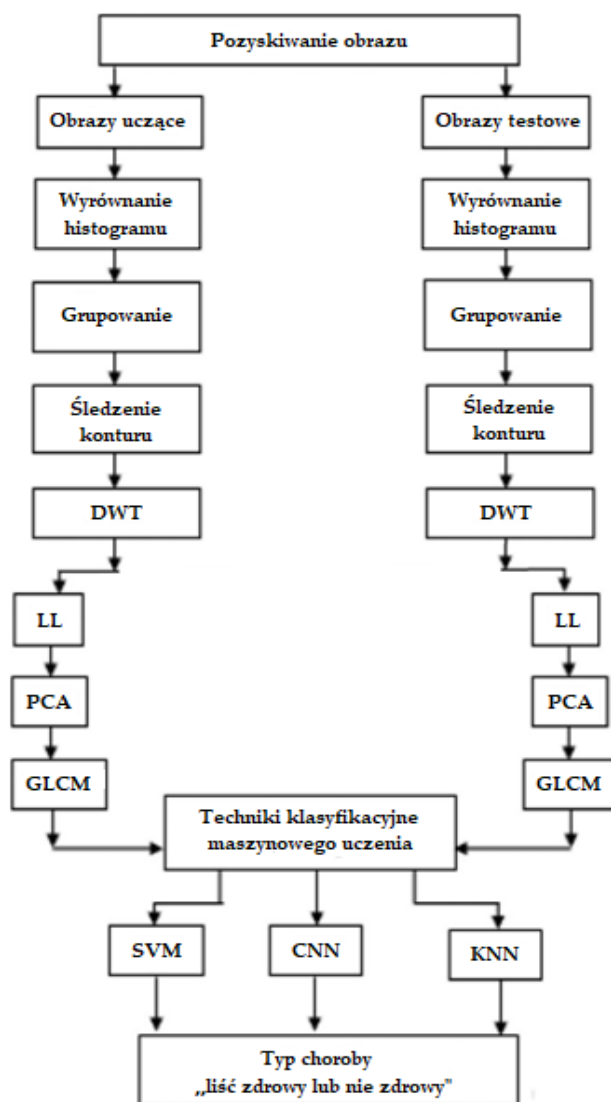
W pracy [89] identyfikacja diagnostyczna podstawowych chorób liści jabłoni, takich jak: rdza, parch i czarna zgnilizna przeprowadzona została z zastosowaniem wstępnie przeszkolonych modeli głębokiego uczenia takich jak InceptionV3, DenseNet-201, Mobile Netv-2, Resnet101, Resnet18, Xception, ShuffleNet, DarkNet -53, EfficientNet-b0. Uzyskano dokładność klasyfikacji na poziomie 99 %. Architekturę systemu przedstawiono na rysunku 2.23.



Rys. 2.23 Wizualizacja architektury systemu diagnostycznego chorób liści jabłoni [89]



Badania nad automatycznym wykrywaniem chorób liści prowadzone są także w uprawach pomidorów. W pracy [90] przedstawiono wykorzystanie algorytmów uczenia maszynowego do analizy obrazów w warunkach laboratoryjnych. Zaproponowany algorytm w pierwszym etapie wstępnego przetwarzania dostosowuje rozmiar i wyrównuje histogram w celu poprawy jakości próbek. Następnie stosowane jest grupowanie typu K-mean do znajdowania zainfekowanego obszaru liścia. W dalszej kolejności wykrywany jest zainfekowany kontur. Wyodrębnianie cech próbek odbywa się przy wykorzystywaniu: dyskretnej transformaty zafalowaniowej DWT (DWT, ang. discrete wavelet transform), która dzieli obraz na podpasma składowych częstotliwości najniższych LL (LL, ang. low low), analizy składowych głównych PCA (PCA, ang. principal component analysis), która dokonuje kompresji danych i macierzy współwystępowania poziomu szarości GLCM (GLCM, ang. grey-level co-occurrence matrix). Cechy uzyskane za pomocą DWT, PCA i GLCM są łączone w celu utworzenia wektora cech i dostarczane klasyfikatorowi. Do klasyfikacji i rozpoznawania wyodrębnionych cech użyte zostały metody uczenia maszynowego SVM, KNN (KNN, ang. k-nearest neighbours) i CNN. Architekturę modelu przedstawiono na rysunku 2.24. Zastosowanie opisanego modelu pozwoliło na uzyskanie dokładności klasyfikacji zdrowych i chorych liści pomidora, na poziomie 99.09 %.



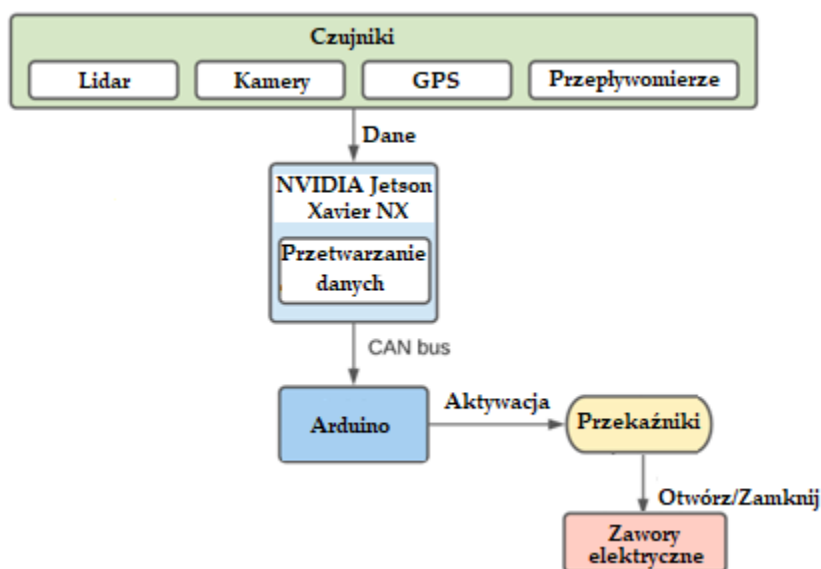
Rys 2.24 Model do rozpoznawania zdrowych i chorych liści pomidorów [90]

Przedstawione w podrozdziale metody automatycznej analizy obrazów z wykorzystaniem modeli przetwarzania danych, pomagają zredukować ryzyko wystąpienia chorób grzybowych w ogrodnictwie, ale nie mogą wyeliminować tego ryzyka całkowicie. Nawet najdokładniejsze rozpoznanie infekcji i odpowiednio wykonywane opryski nie zapewniają stuprocentowej gwarancji braku wystąpienia infekcji, dlatego dążyć należy do ciągłego monitorowania plantacji i czynników ryzyka.

## b. Sprzęt i przykłady realizacji

Realizacja automatycznego rozpoznawania chorób liści w środowisku rzeczywistym plantacji ogrodniczej wymaga architektury sprzętowej zintegrowanej z systemem sterowania opryskiwaczem. Architektura sprzętowa wraz z zaimplementowanymi algorytmami obliczeniowymi tworzy inteligentne opryskiwacze zdolne do szybkiego dostosowywania się do sygnalizacji i zmian zachodzących na plantacji [91].

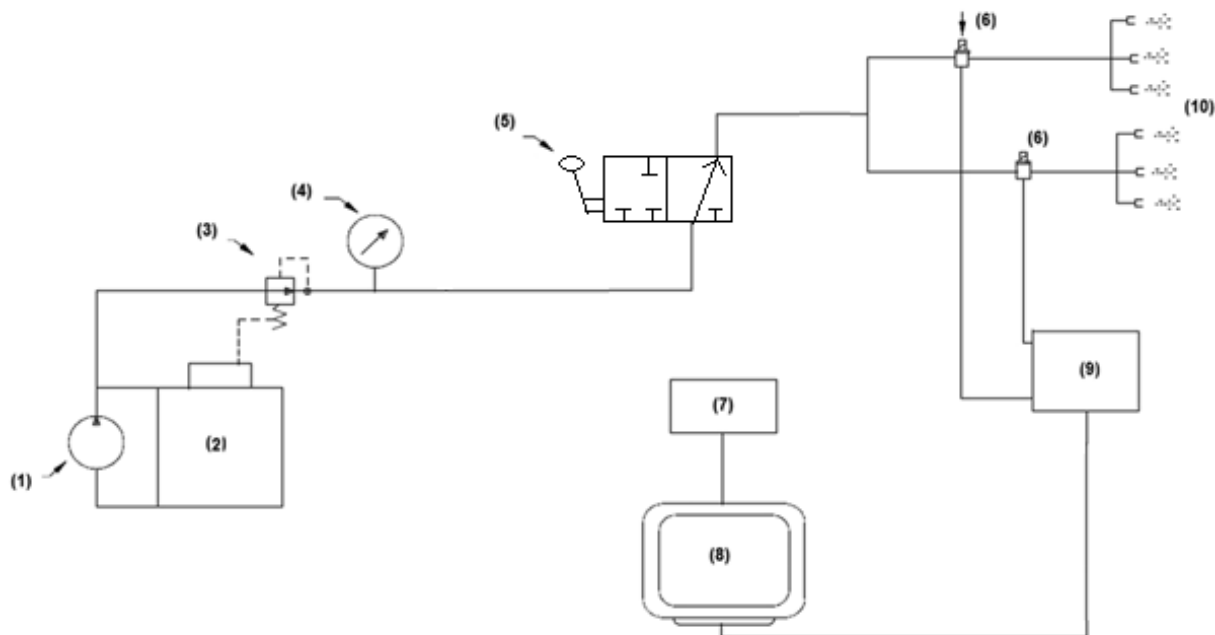
W skład budowy inteligentnego opryskiwacza przedstawionego w pracy [92] i realizującego automatyczną analizę obrazu wychodzi: lidar 2D, dwie kamery, moduł GPS oraz dwa przepływomierze. Moduł GPS służy do lokalizacji i kontroli prędkości. Przepływomierze sterują ilością wypryskiwanej cieczy. Pozyskane dane z połączonych czujników skanujących otoczenie i przetworzone przez algorytmy sztucznej inteligencji z wykorzystaniem procesora Nvidia Jetson Xavier NX, pozwalają uzyskać informacje takie jak: wysokość drzew, gęstość korony i ilość owoców. Dane następnie trafiają do mikrokontrolera na płycie typu Arduino, który steruje przekaźnikami aktywującymi elektrozawory odpowiedzialne za wypływ cieczy z opryskiem. Rozwiązanie to pozwala na minimalizację ilości stosowanych oprysków. Zaimplementowane algorytmy CNN pozwalają wykrywać dojrzałe i niedojrzałe owoce oraz drzewa z młodych i wieloletnich plantacji. System ten może wykrywać i klasyfikować obiekty np. ludzi i konstrukcje polowe. Rysunek 2.25 przedstawia architekturę sprzętową realizującą opisane funkcje.



Rys. 2.25 Budowa inteligentnego opryskiwacza do drzew [92]

W podobny sposób może odbywać się dostosowywanie klasycznego opryskiwacza do realizacji funkcji wynikających z automatycznej, wizyjnej analizy liści. Standardowy opryskiwacz zawiera układ hydrauliczny, w skład którego wchodzi pompa, zbiornik na ciecz, zawór zwrotny, manometr, rozdzielacz sterujący i dysze wylotowe. Modernizacja opryskiwacza w celu przystosowania go do sterowania z wykorzystaniem systemu wizyjnego polega na odpowiednim

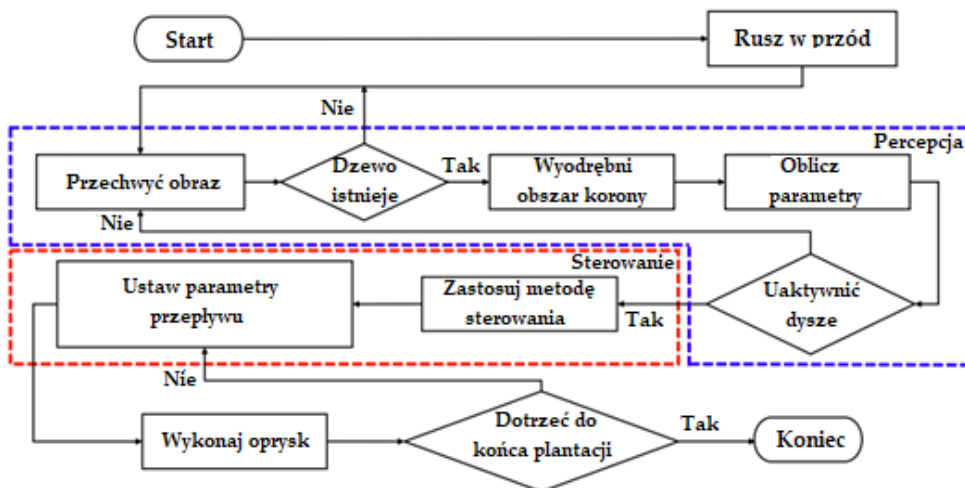
montażu kamer i komputera przetwarzającego dane wizyjne. W wyniku przetwarzania danych wizyjnych generowane są sygnały, które za pośrednictwem obwodu sterującego, kontrolują otwieranie i zamykanie zaworów elektromagnetycznych umiejscowionych w układzie hydraulicznym opryskiwacza oraz ciśnienie cieczy. Przedstawione na rys. 2.26 rozwiązanie podnosi precyzję wykonywanych oprysków uzyskaną w wyniku modernizacji tradycyjnego opryskiwacza sadowniczego.



Rys. 2.26 Schemat zmodyfikowanego opryskiwacza: 1 – pompa, 2 – zbiornik na ciecz, 3 – zawór zwrotny, 4 – manometr, 5 – rozdzielacz sterujący, 6 – zawory elektromagnetyczne, 7 – kamery, 8 – komputer, 9 – obwody sterujące, 10 – dysze wylotowe [93]


W pracy [94] przedstawiono algorytm (rys. 2.27) realizujący inteligentny oprysk, który uwzględnia zmienne w czasie warunki terenowe wykrywane na podstawie sygnału wizyjnego, z którego rozpoznawane są korony drzew i otoczenie sadu. Platforma mobilna wyposażona w system sztucznej inteligencji, po zainicjowaniu cyklu, rusza w głąb plantacji sadowniczej. System inteligentnego oprysku przechwytytuje obrazy z kamer do momentu wykrycia drzewa. Następnie wyodrębnia potencjalny obszar korony drzewa, który powinien być pokryty opryskiem i oblicza parametry oprysku. Z tych danych przekazywane są informacje uaktywniające odpowiednią liczbę dysz wylotowych. W przypadku, gdy algorytm wizyjny wykryje drzewo uschnięte lub złamane, wówczas dysze nie zostają aktywowane i cykl przechwytywania obrazu się powtarza. Gdy system rozpoznaje drzewo wymagające oprysku, w zależności od kształtu korony, uruchamia dedykowaną metodę oprysku i ustawia odpowiednie parametry przepływu cieczy do kolejnych aktywnych dysz wylotowych. Wówczas uruchamiany zostaje właściwy oprysk, którego parametry mogą być kalibrowane w trakcie wykonywania zabiegu.





Rys. 2.27 Algorytm inteligentnego systemu oprysku [94]

W skład wyposażenia sprzętowego opryskiwacza, poza standardowymi elementami hydraulicznymi, wchodzi dwie kamery (po jednej na każdej stronie), lidar, komputer z monitorem, elektrozawory z funkcją sterowania przepływem cieczy z wykorzystaniem modulacji wypełnienia impulsów (PWM, ang. pulse width modulation) i jednostka kontrolująca przepływ (rys. 2.28). Przedstawiona architektura sprzętowa zapewnia realizację zadań inicjowanych przez system wizyjny.

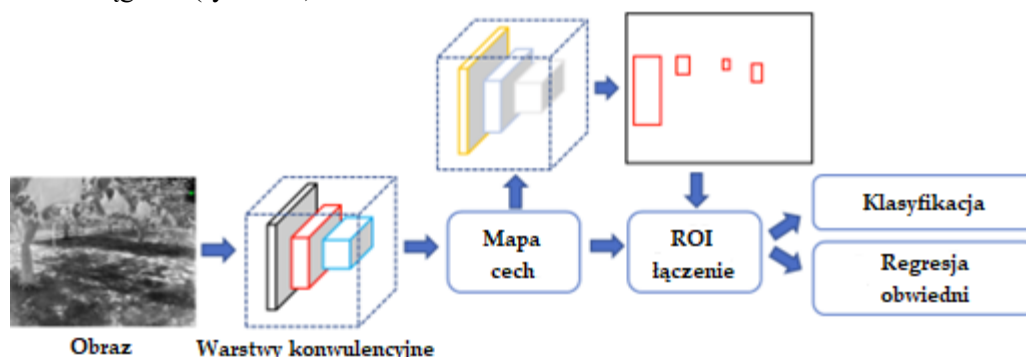


Rys. 2.28 Platforma mobilna z inteligentnym system oprysku [94]


## 2.5.6 Metody wizyjnej nawigacji pojazdu realizującego inteligentny oprysk

Najpowszechniej stosowaną metodą nawigacji autonomicznych ciągników są moduły wykorzystujące sygnał pochodzący z systemu GPS. Istnieją jednak przypadki, w których globalny system pozycjonowania nie sprawdza się. Zdarza się to często na obszarach z dominującymi koronami drzew. W takich sytuacjach dokładniejsze pozycjonowanie możliwe jest z wykorzystaniem kamery wizyjnej zamontowanej na przedniej części karoserii ciągnika lub kabinie kierowcy. Kamery wizyjne muszą mieć wówczas dostęp do lokalnej sieci, za pośrednictwem której przesyłają obraz wspomagający zdalne prowadzenie ciągnika przez operatora. Pozyskanie obrazu z kamer czołowych wykorzystać można również do algorytmów wizyjnych celem uzyskania funkcji prowadzenia wzdłuż wyznaczonej trajektorii lub detekcji nieoczekiwanych przeszkód. Podkreślić należy względy bezpieczeństwa i wymagania prawne, które stanowią w takim przypadku konieczność ustanowienia obszaru nawigacji niedostępnego dla ludzi.

W pracy [98] przedstawiono metodę nawigacji polegającą na rozpoznawaniu w sadzie, do celów nawigacji, punktów orientacyjnych takich jak pnie drzew. Zastosowano kamerę termowizyjną i algorytmy głębokich sieci neuronowych. Metoda ta może być stosowana w warunkach nie tylko zbyt słabego lub niedostępnego sygnału GPS, ale przede wszystkim przy braku dziennego oświetlenia. Badania przeprowadzone nad wykorzystaniem do nawigacji lidar wykazały, że uzyskać on może informacje o odległości i orientacji kątowej, ale nie może wprost podać informacji o obiekcie [95]. Jakość obrazu z kamer kolorowych (światła widzialnego) bardzo zależy od oświetlenia. Niewystarczające warunki oświetleniowe występować mogą często przy obszarach zacieniowanych lub w porze nocnej. Czujnik termiczny mierzy natomiast ilość ciepła emitowanego przez obiekt o danej temperaturze i na tej podstawie może określić jego temperaturę [96], [97]. Wykorzystanie modelu szybkiej R-CNN (rys. 2.29) pozwala na wykrycie pni drzew i wyznaczenie obiektów do nawigowania ciągnika (rys. 2.30).

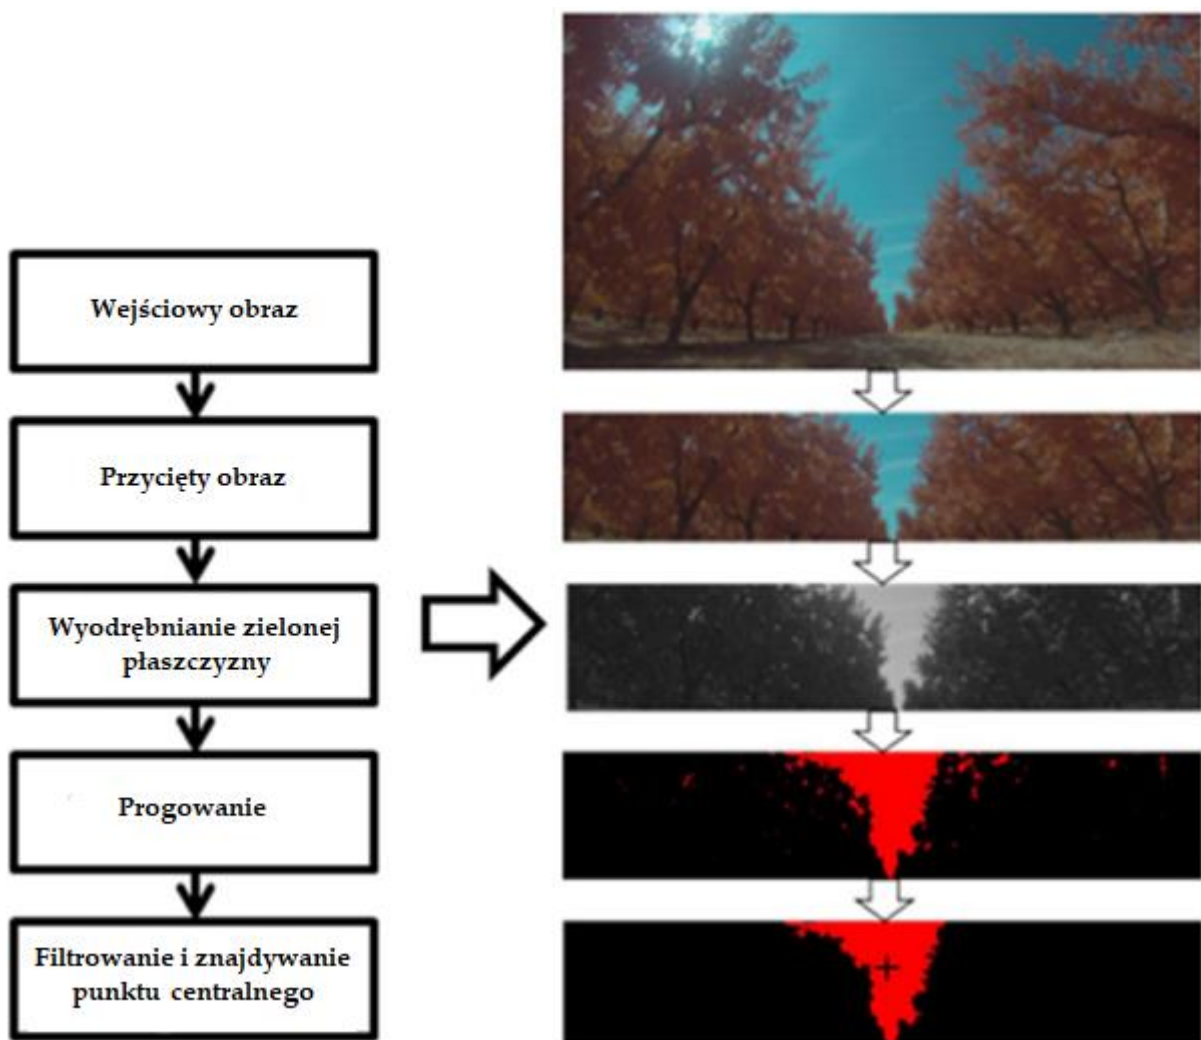


Rys. 2.29 Struktura szybkiej R-CNN do wykrywania pieńków drzew [98]



Rys. 2.30 Obrazy wyjściowe po detekcji pni drzew [98]

Kolejną metodą wykorzystującą wizję maszynową do nawigacji pojazdu w sadzie jest zastosowanie kamery multispektralnej. Kamery tego typu, poza rejestrowaniem obrazu w zakresie światła widzialnego, rejestrują informacje niewidzialne dla oka ludzkiego w zakresie podczerwieni i ultrafioletu. Kamera w trakcie przejazdów skierowana jest w górę, a algorytm wizyjny skupia się na przetwarzaniu obrazu przedstawiającego korony drzew i niebo. Następnie realizowane jest rozpoznawanie cech na podstawie kontrastu między koronami drzew i niebem. Po akwizycji obrazu zostaje on odpowiednio przycięty w celu usunięcia niepotrzebnej części nieba. Następnie, wyodrębniana jest zielona płaszczyzna koloru z obrazu, która zapewnia kontrast od niebieskiego nieba. Kolejny krok to progowanie, aby wyodrębnić płaszczyznę ścieżki pojazdu. Ostatnim etapem przetwarzania obrazu jest zastosowanie filtrowania i znajdowanie punktu centralnego służącego do nawigacji pojazdu (rys. 2.31). Wyniki testów systemu nawigacji przedstawione w pracy [99], które zostały przeprowadzone na bezzałogowej platformie napędzanej silnikami elektrycznymi, wykazały osiągnięcie pozycjonowania ze średniokwadratowym (RMS, ang. root mean square) błędem wynoszącym 2.35 cm. Ten sposób nawigacji wizyjnej, w porównaniu do nawigacji opartej o detekcje pni drzew, eliminuje możliwe błędy powstałe na skutek brakujących drzew w rzędzie.



Rys. 2.31 Schemat blokowy algorytmu przetwarzającego obraz dla celów autonomicznej nawigacji [99]


Metoda wyznaczania osi środkowej między rzędami uprawowymi z wykorzystaniem sygnału wizyjnego z kamery czołowej pojazdu, może opierać się na autonomicznym śledzeniu wyznaczonej ścieżki. W pracy [100] oś środkowa, według której porusza się pojazd będący obiektem nawigacji,

wyznaczana jest w wyniku kilkuetapowego przetwarzania obrazu. Wstępne przetwarzanie obrazu oparte jest na technice CIVE [101] i oraz filtrze medianowym [102]. W pierwszym etapie przeprowadza się usunięcie nieba z obrazu techniką progowania, co eliminuje zbędne obiekty. Następnie obraz kolorowy konwertowany jest na skalę szarości (rys. 32a,b,c).



Rys. 2.32 Wstępne przetwarzanie obrazu: a) obraz RGB zarejestrowany przez kamerę, b) obraz z usuniętym niebem, c) obraz w skali szarości CIVE [100]

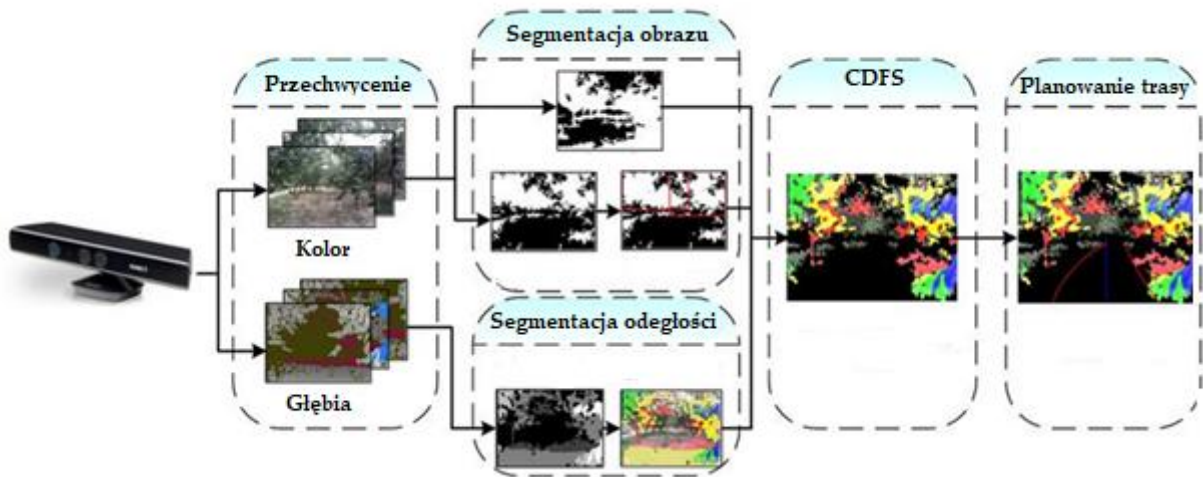
Kolejny etap przetwarzania to zastosowanie filtru medianowego. Następnie wykonywana jest segmentacja obrazu, polegająca na podziale obrazu na pierwszy plan i tło z wykorzystaniem filtru Gabora [103]. W celu zmniejszenia kosztów obliczeniowych stosowana jest analiza PCA [104], zmniejszającą wymiarowość zbioru danych. W kolejnym kroku przeprowadzana jest klasyfikacja uzyskanych danych przy wykorzystaniu algorytmu k-średnich. Z obrazu binarnego otrzymanego po grupowaniu k-średnich wyodrębnia się ścieżka nawigacji przy użyciu algorytmu osi środkowej (rys. 2.33a,b,c). Opisaną metodą system wizyjny wykrywa ścieżkę nawigacyjną na podstawie obrazów rzędów upraw i może podejmować decyzje sterujące robotem autonomicznym.



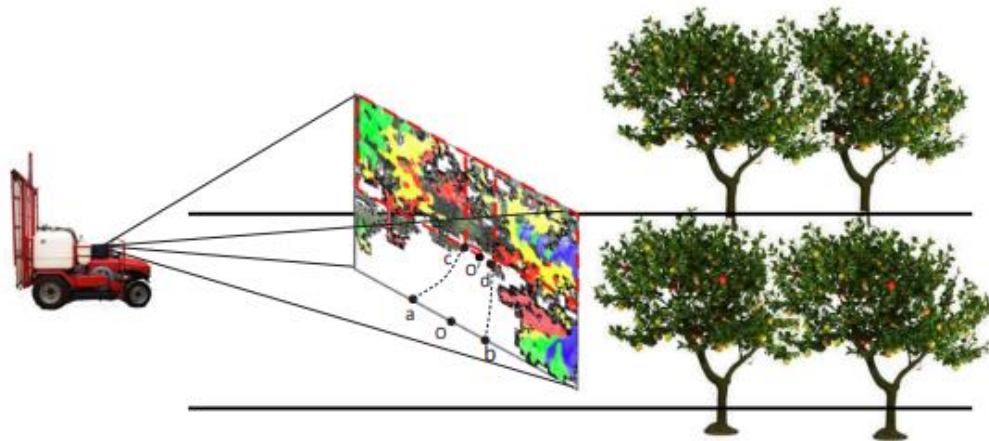
Rys. 2.33 Obraz po przetworzeniu: a) metodą filtru Gabora, b) algorytmem klastrowym k-średnich, c) z wyznaczoną ścieżką nawigacji [100]

Algorytm planowania ścieżki przejazdu w trakcie opryskiwania oparty może być również na wykorzystaniu obrazów RGB wraz z jednoczesnym wykorzystaniem map głębi (rys. 2.34) [105]. Mapa głębi obrazu daje informacje o odległościach między obiektami w otoczeniu. Łączenie tych informacji pozwala na wykrywanie obiektów w zasięgu do kilku metrów (rys. 2.35). Przechwycone obrazy z kamery są przetwarzane przy użyciu progowania adaptacyjnego, następnie stosowane jest przekształcenie do przestrzeni HSV. W kolejnym etapie stosowana jest metoda fuzji obrazów CDFS (CDFS, ang. colour-depth fusion segmentation) oparta na estymacji powierzchni korony drzewa. Ścieżka przejazdu w trakcie opryskiwania planowana jest po wyznaczeniu punktu środkowego  $O'$  (rys. 2.36).






Rys. 2.34 Schemat metody [105]



Rys. 2.35 Diagram perspektywicznej projekcji 3D-2D [105]



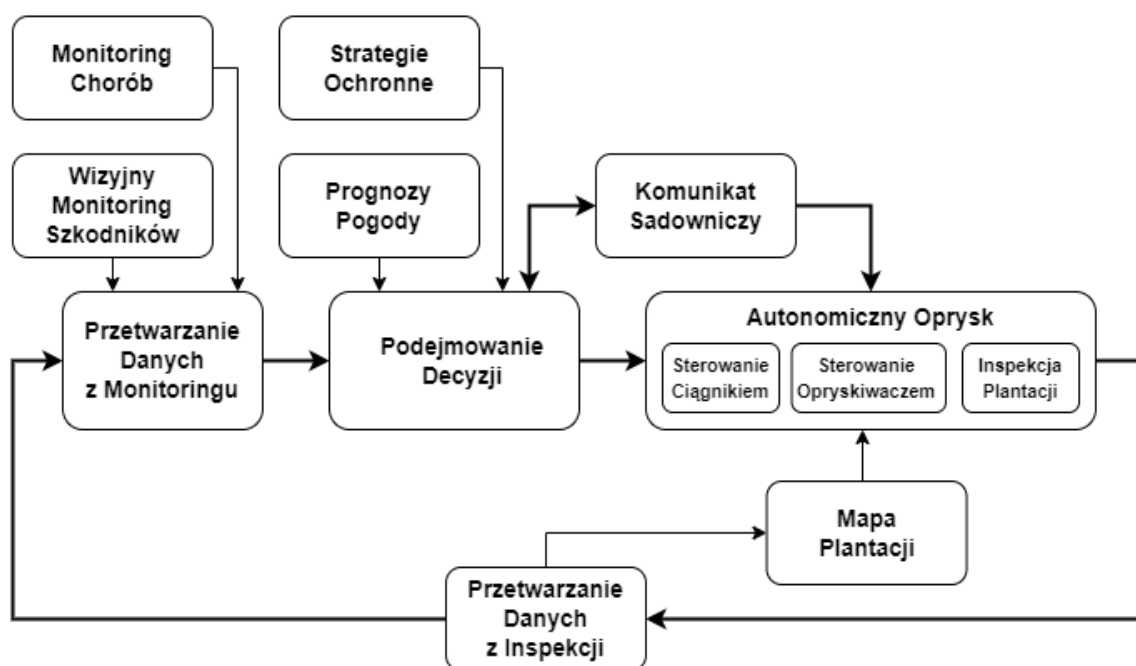
Rys. 2.36 Schemat wyznaczenia punktu środkowego [105]

### 3. Propozycja systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych

Wykorzystując analizę aktualnego stanu wiedzy związanej z systemami sztucznej inteligencji stosowanymi w ogrodnictwie oraz rozwiązania autorskie przygotowano propozycję systemu wspomagającego wykonywanie autonomicznych oprysków sadowniczych. Opracowany system wykorzystuje rozwiązania z obszaru przetwarzania obrazów i sztucznej inteligencji w celu realizacji poszczególnych zadań. Należą do nich analiza stanu plantacji (w tym wykrywanie chorób i szkodników), wspomaganie podejmowania decyzji wykonaniu oprysku, a także przeprowadzenie samego oprysku w sposób autonomiczny lub zdalnie sterowany. Zaprojektowany modułowy podsystem wizyjny umożliwia sterowanie ciągnikiem, opryskiwaczem, rozpoznawanie wysokości i stanu rozwojowego drzew. Pełni również rolę monitoringu inspekcyjnego plantacji. Przedstawiona propozycja systemu może również uwzględniać stosowanie oprysków biologicznych pochodzenia naturalnego, po przygotowaniu odpowiedniej bazy strategii ochronnej dla upraw ekologicznych [106].

#### 3.1 Główne elementy systemu

Schemat blokowy prezentowanego systemu przedstawia rysunek 3.1. Większość danych pozyskiwanych jest z modułowego systemu wizyjnego, który monitoruje występowanie chorób i szkodników sadowniczych oraz fluktuacji klimatycznych [107], pozwala na sterowanie autonomicznym ciągnikiem i opryskiwaczem oraz zbiera dane inspekcyjne podczas wykonywania zabiegów ochronnych, wykorzystując najnowsze metody przetwarzania danych [108], [109]. Opracowany system zawiera poziomy technologiczne 1, 2 i 3, przez co lokalizuje się w klasyfikacji Ogrodnictwa 4.0 [40] (por. rozdział 2.2).



Rys. 3.1 Schemat inteligentnego systemu oprysków ochronnych w sadownictwie (opracowanie własne)

System składa się z dziesięciu bloków, które realizują następujące zadania:

Blok 1 – Monitoring chorób

- Monitorowanie występowania chorób pochodzenia grzybowego odbywa się poprzez pomiar czasu zwilżania liści po opadach deszczu w określonej temperaturze. Czas zwilżania liści można określić za pomocą analizy wideo. Zmierzone wartości są następnie wprowadzane do modelu rozwoju choroby, na podstawie którego wyznaczany jest parametr RIM [51]. Przekroczenie wyznaczonego doświadczalnie progu RIM jest sygnałem ryzyka wystąpienia infekcji grzybowej.

#### Blok 2 – Wizyjny monitoring szkodników

- Monitorowanie występowania szkodników w uprawach sadowniczych za pomocą systemu wizyjnego dostarcza informacji o liczbie odłowionych szkodników w specjalne pułapki wabiące [110], [111]. Przekroczenie wyznaczonej doświadczalnie liczby szkodników na pułapkę jest sygnałem do wykonania oprysków w celu ich zwalczenia.

#### Blok 3 – Przetwarzanie danych o chorobach i szkodnikach

- Dane z bloków 1 i 2, pozyskane ze stacji meteorologicznych i/lub z kamer znajdujących się na plantacji, są przetwarzane w bloku 3. W przypadku wykrycia choroby lub szkodnika w uprawie sadowniczej generowane są informacje wyjściowe na potrzeby procesu decyzyjnego realizowanego przez blok 6.

#### Blok 4 – Strategie ochronne

- Blok ten zawiera bazę danych ze strategiami ochrony plantacji sadowniczych przed poszczególnymi zagrożeniami. Do typów zagrożeń przypisane są środki ochronne dozwolone przez odpowiednie zezwolenia na produkcję owoców. Każda sygnalizacja z bloku 3 wymaga znalezienia odpowiedniego środka ochronnego w bloku 4.

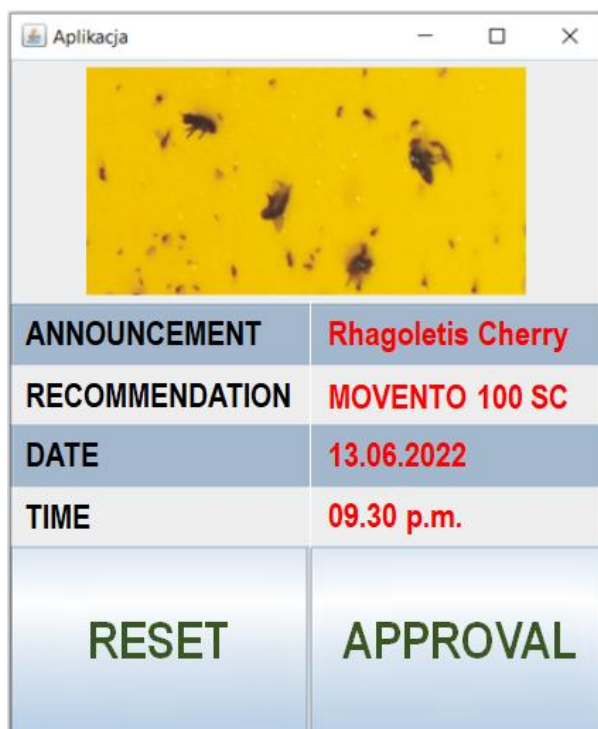
#### Blok 5 – Prognozy pogody

- W bloku tym zbiera i wstępnie przetwarza się dane uzyskane z prognozowanych warunków pogodowych. Do najważniejszych czynników pogodowych mających wpływ na decyzję o zabiegu należą temperatura powietrza, opady, wilgotność, siła wiatru. Dane przekazywane są do kolejnego bloku.

#### Blok 6 – Podejmowanie decyzji

- Po zebraniu i przetworzeniu danych o chorobach i szkodnikach (blok 3), dodatkowych danych określających środek ochronny (blok 4) oraz informacji związanych z prognozą pogody podejmowana jest decyzja o podjęciu oprysku plantacji. Jeżeli wskaźniki z monitoringu chorób sugerują przeprowadzenie zabiegu wyznaczany jest termin zabiegu. Wybierany jest dzień, w którym spełnione są wymagania dotyczące określonych czynników klimatycznych pogody, takich jak: temperatura, siła wiatru, brak opadów, pora dnia itp. Data i godzina zabiegu ma kluczowe znaczenie dla skuteczności oprysku. Na przykład zbyt silny wiatr utrudnia prawidłowe pokrycie całej zielonej tkanki drzewa i powoduje duże zużycie środków ochrony roślin, a także zanieczyszczenie środowiska. Zbyt niski poziom wilgotności powoduje odparowanie części środków ochronnych do atmosfery, a prognozowane po zabiegu opady mogą usunąć z tkanki liści środek ochronny. Przy zbyt niskiej lub zbyt wysokiej temperaturze skuteczność zabiegu jest znacznie niższa.
- Wygenerowana automatyczna decyzja wymaga przed kolejnym etapem (tj. przed wykonaniem zabiegu ochrony drzew) dodatkowo, jej zatwierdzenia przez doświadczanego sadownika

w celu weryfikacji działań i uniknięcia niepotrzebnych zabiegów w przypadku błędnych decyzji. Przykładowy obraz ekranu do akceptacji decyzji o oprysku prezentuje rys. 3.2. Decyzja plantatora o zatwierdzeniu lub anulowaniu automatycznej sugestii jest dodatkową informacją, która uczy system sztucznej inteligencji podejmowania decyzji. Po kilku sezonach testów i nauki systemu prawdopodobnie uda się pominąć etap ręcznej akceptacji.



Rys. 3.2 Przykładowa decyzja generowana przez blok podejmowania decyzji (opracowanie własne)

#### Blok 7 – Komunikat sadowniczy

- W tym bloku pozyskiwane są wiadomości z aktualnymi komunikatami generowanymi przez komercyjne firmy doradcze z branży sadowniczej dla obszaru, na którym znajduje się plantacja. Komunikaty te wskazują w pewnym stopniu na rodzaj i datę koniecznego oprysku sadu. Mogą wspierać proces decyzyjny w bloku 6, ale także lokalną decyzję o przeprowadzeniu procedury podjętej w bloku 6. Informacje o podjętych zabiegach wygenerowane przez algorytm decyzyjny mogą zostać także zwrotnie udostępniane firmom konsultingowym w celu dalszego przetwarzania lub do przygotowania precyzyjnych komunikatów.

#### Blok 8 – Mapa plantacji

- Aby móc wykonać autonomiczny zabieg ochronny, należy przygotować numeryczną mapę sadu. Mapa ta umożliwi poruszanie się autonomicznego ciągnika podłączonego do automatycznego opryskiwacza w danym obszarze plantacji sadowniczej. Mapa zawiera rozmieszczenie drzew na plantacji, a także możliwe trasy przejazdu.

#### Blok 9 – Autonomiczny oprysk

- Gdy plantator zaakceptuje decyzję podjętą przez system sztucznej inteligencji (blok 6), przeprowadzane jest autonomiczne opryskiwanie sadu. Zadanie to wykonywane jest przez



zautomatyzowany ciągnik sadowniczy z opryskiwaczem wyposażony w kamery. Strumień wideo z kamer przekazywane są do specjalnie zaprojektowanych modułów przetwarzania sygnału wizyjnego, które realizują trzy zadania: wspomagają system sterowania pojazdem, sterują automatycznym opryskiwaczem, a także zbierają dane o plantacji, np. wielkość drzew, stan liści, uszkodzenia, ewentualne choroby drzew (zwłaszcza nowe objawy, które nie zostały wykryte przed opryskiem), itp.

#### Blok 10 – Przetwarzanie danych z inspekcji

Dane uzyskane podczas opryskiwania (blok 9) są następnie przetwarzane i wykorzystywane do podejmowania dalszych analiz, np. w przypadku wykrycia objawów infekcji podjęcia decyzji o kolejnym oprysku. Blok ten dostarcza informacji zwrotnej w systemie, dzięki czemu decyzje są bardziej precyzyjne. Dodatkowo aktualizuje mapę plantacji (blok 8).

W kolejnych podrozdziałach przedstawiono szczegółowy opis zaprezentowanych bloków systemu.


## 3.2 Modułowy system wizyjny

Jak przedstawiono w poprzednim podrozdziale, na szczegółowej liście zadań opracowanego systemu inteligentnych oprysków jest systemem modułowym bazującym głównie na danych wizyjnych. Większość modułów przetwarza obrazy, które zawierają informacje wejściowe lub zwrotne do systemu.

Prezentowany w tym podrozdziale modułowy system wizyjny wspiera trzy główne zadania: monitoring szkodników, sterowanie ciągnikiem podczas autonomicznego oprysku oraz sterowanie opryskiwaczem. Do akwizycji obrazów w systemie wykorzystano kamery kolorowe IP Gemini 612-23W (Delta-Opti Poznań, Polska) o rozdzielczości 1,4 Mpix (1280 × 720 px) przy 25 kl./s z przetwornikiem CMOS OmniVision OV9712 1/4 cala, kodekiem wideo H.264 oraz interfejsem sieciowym Ethernet 10/100 Base-T.

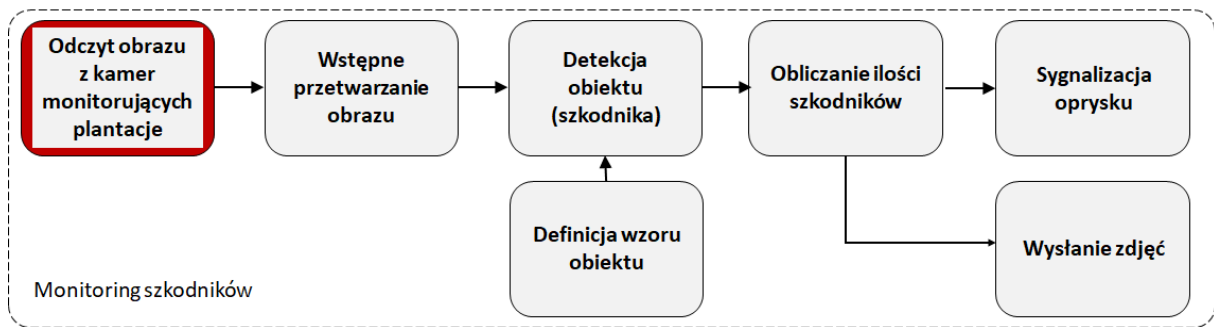
### 3.2.1 Wizyjny moduł monitorujący szkodniki

Automatyczne wykrywanie i zliczanie szkodników drzew owocowych zrealizowane zostało z wykorzystaniem biblioteki EMGU.CV [112]. Obrazy z kamer umieszczonych na plantacji sadowniczej, w których polu widzenia znajdują się pułapki wabikowe są odszumiane i poddawane binaryzacji poprzez progowanie jasności (rys. 3.3a). Wstępne przetwarzanie pozwala usunąć z obrazów szumy i niepożądane obiekty (np. kurz lub muchy, które w tym przypadku nie są szkodnikami). Następnie, szkodniki owadzie o określonej wielkości są wykrywane i liczone poprzez dopasowanie do znanych definicji wzorców obiektów (rys. 3.3b). Jeśli liczba szkodników w pułapce przekroczy podaną progową liczbę, system generuje sygnał do bloku decyzyjnego w celu wykonania oprysku zwalczającego szkodniki. Opcjonalnie system wysyła raport uzupełniony o wynikowy obraz w celu dodatkowej weryfikacji.




Rys. 3.3 Obraz pułapki ze szkodnikami: a) wejściowy, b) wyjściowy (opracowanie własne)

Schemat algorytmu wizyjnego do monitorowania szkodników przedstawiono na (rys. 3.4). Jak wspomniano w poprzednim rozdziale, algorytm ten monitoruje występowanie szkodników w uprawach sadowniczych i dostarcza informacji o liczbie szkodników złapanych w specjalne pułapki wabiące, sygnalizując konieczność wykonania oprysku. Pułapka feromonowa jest stale obserwowana przez kamerę inspekcyjną (rys. 3.5a), a uzyskany obraz poddawany jest przetwarzaniu w czasie rzeczywistym (rys. 3.5b).



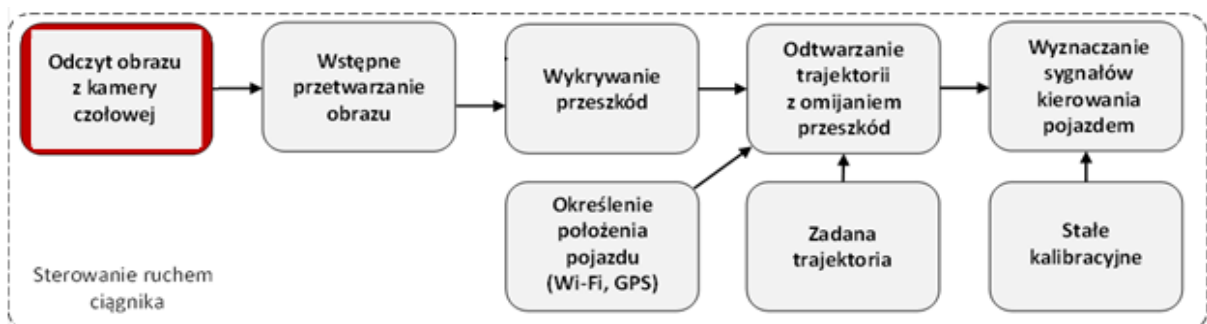
Rys. 3.4 Schemat algorytmu wizyjnej detekcji szkodników (opracowanie własne)



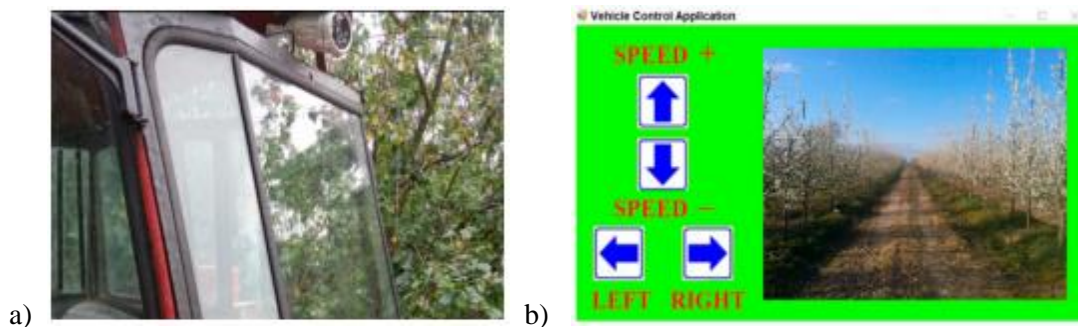
Rys. 3.5 Wizyjny moduł - pułapka na szkodniki śliwy: a) kamera monitorująca, b) obraz z kamery po przetworzeniu przez algorytm wizyjny (opracowanie własne)

### 3.2.2 Wizyjny moduł sterujący ciągnikiem

Podstawowe sterowanie poruszającym się pojazdem w zamkniętym terenie niedostępnym dla osób postronnych (jak w prezentowanym przypadku – w sadzie) może odbywać się za pomocą autonomicznego modułu jazdy. Schemat algorytmu sterowania przedstawiono na rysunku. 3.6. W celu umożliwienia jazdy zdalnie sterowanej lub autonomicznej ciągnik sadowniczy musiał zostać wyposażony w przednią kamerę umieszczoną na dachu ciągnika (rys. 3.7a). Obraz z kamery dostarcza informacji modułowi autonomicznej jazdy i może być również wykorzystany do zdalnego, ręcznego sterowania pojazdem za pośrednictwem sieci bezprzewodowej (rys. 3.7b) [113]. Autonomiczna jazda lub zdalne, ręczne sterowanie są znacznie korzystniejsze niż klasyczna jazda ciągnikiem podczas opryskiwania, gdyż operator nie jest narażony na szkodliwe warunki. Wymaga to jednak wprowadzenia dodatkowych procedur bezpieczeństwa.



Rys. 3.6. Schemat blokowy modułu autonomicznej jazdy (opracowanie własne)

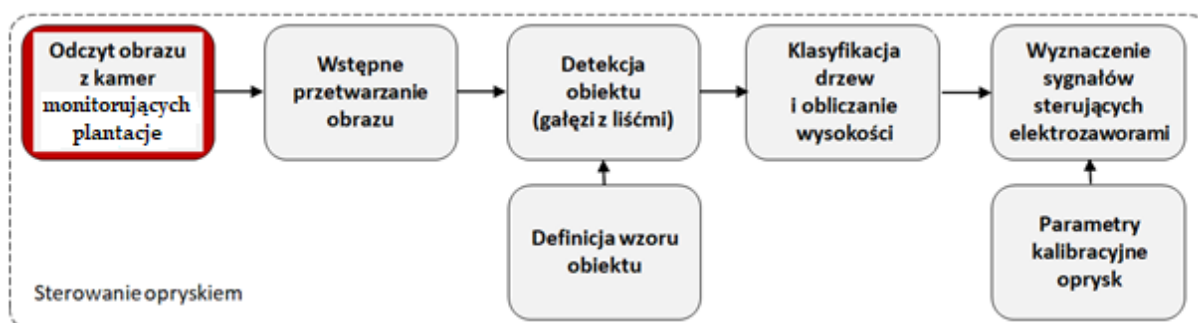


Rys. 3.7 Moduł wizyjny ciągnika autonomicznego: a) kamera czołowa do obsługi autonomicznej jazdy lub zdalnego sterowania ciągnikiem sadowniczym, b) aplikacja okienkowa zdalnie sterująca ciągnikiem (opracowanie własne)

Zdalne, ręczne sterowanie pojazdem może być konieczne w sytuacjach awaryjnych, np. gdy zachodzi potrzeba ręcznego naprowadzenia pojazdu na prawidłową trajektorię lub już zadana trajektoria wymaga modyfikacji. Autonomiczny system sterowania ciągnika pozwala na wykrywanie i rozpoznawanie obiektów pojawiających się w polu widzenia przedniej kamery. Wspomaga funkcję omijania przeszkód i awaryjnego zatrzymywania się, gdy ominięcie przeszkody jest niemożliwe. Ponieważ sad jest środowiskiem o niewielkiej zmienności w czasie, możliwe jest wcześniejsze zaprogramowanie trajektorii opryskiwania, która zostanie wykonana przez autonomicznego kierowcę, korzystającego z numerycznej mapy sadu. Informacje o lokalizacji ciągnika pozyskiwane są z systemu lokalizacji. System ten może korzystać z globalnego modułu GPS lub lokalnego modułu pozycjonowania pojazdu w oparciu o zmiany siły sygnału radiowego dostarczanego przez lokalne stacje sieci bezprzewodowej Wi-Fi. Szczegółowy opis autorskiego systemu lokalizacji do tego celu przedstawiono w pracy [113].


### 3.2.3 Wizyjny moduł sterujący automatycznym opryskiwaczem

Kluczową funkcją wizyjnego modułu sterującego zautomatyzowanym opryskiwaczem jest odpowiednie dozowanie środka ochronnego drzew. Opracowane algorytmy przetwarzania danych wizyjnych pozwalają na rozpoznanie stanu rozwojowego drzew, wykrycie ich wysokość oraz wykrycie zainfekowanych drzew do dalszej analizy. Schemat algorytmu sterującego opryskiwaczem pokazano na rysunku 3.8.



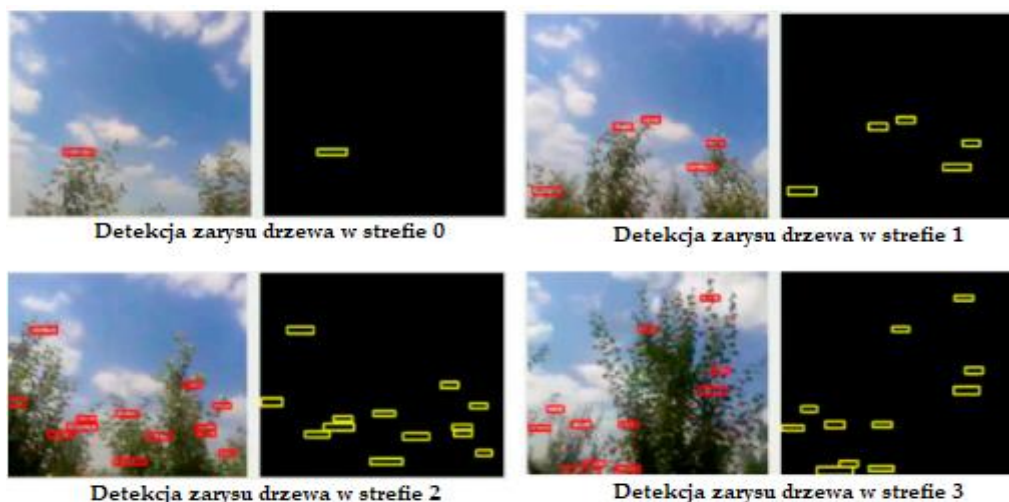
Rys. 3.8 Schemat blokowy algorytmu sterującego automatycznym opryskiwaczem (opracowanie własne)

Moduł wizyjny przetwarza sygnał odebrany z kamery umieszczonej na masce ciągnika, która jest skierowana na boki, w kierunku rzędu opryskiwanych drzew (rys. 3.9a,b). W przypadku znacznych wysokości drzew, których nie obejmuje pole widzenia typowej kamery istnieje możliwość rozbudowy wizyjnego modułu o dodatkowe kamery boczne [114].



Rys. 3.9 Moduł wizyjny automatycznego opryskiwacza: (a) kamera boczna umieszczona na masce do klasyfikacji drzew i sterowania opryskiwaczem, (b) przykładowy obraz zarejestrowany przez kamerę boczną, (c) opryskiwacz sadowniczy z przystawką wyposażoną w zawory elektromagnetyczne sterujące wlotem do dysz opryskiwacza (opracowanie własne)

Przechwycony obraz z kamery jest przetwarzany przez algorytm wizyjny [112], który wykrywa zarys drzewa, wykrywając liście i gałęzie w czterech strefach (rys. 3.10). Do tego zadania przygotowano specjalną funkcję. Najpierw wykrywanie krawędzi odbywa się za pomocą operatora Sobela, a następnie wykonywana jest jedna z operacji morfologicznych – dylatacja. Przetwarzanie obrazu odbywa się sekwencyjnie, aby znaleźć zarys gałęzi z liśćmi. Następnie tworzony jest element konstrukcyjny — prostokąt o określonym rozmiarze, który obejmuje wykryty kontur. Analizowane drzewa są następnie przypisywane do jednej z czterech stref – numerycznie wydzielonych kategorii wysokości drzew. W zależności od przypisanej kategorii wysokości drzewa, otwierana jest mniejsza lub większa liczba zaworów elektromagnetycznych sterujących dyszami opryskiwacza (rys. 39c). Algorytm wizyjny sterowania opryskiwaczem kalibruje parametry oprysku również w trakcie wykonywania zabiegów ochronnych. Pozwala to, poza opryskiwaniem tylko wymaganej powierzchni drzewa, na jednoczesną oszczędność wody i środków ochrony roślin.



Rys. 3.10. Wykrywanie wysokości drzew: przykłady z czterech stref: od 0 do 3. (opracowanie własne)

Oprócz wykrywania wysokości drzewa, moduł wizyjny wykrywa stan rozwojowy i infekcje drzew, które modyfikują lokalną decyzję o opryskiwaniu. Na przykład, drzewa bez liści nie będą opryskiwane. Ponieważ automatyczne wykrywanie stanu rozwojowego drzewa, a także chorób drzew, na podstawie wyłącznie analizy obrazu, jest trudnym zadaniem, problematykę tą rozwiązano za pomocą splotowych sieci neuronowych i dokładnie zbadano ich działanie (szczegółowy opis znajduje się w części eksperymentalnej, w rozdziale 4.3.3).



Zadania klasyfikacji stanów rozwojowych drzew i klasyfikacji na drzewa bez infekcji chorobowych i zainfekowane chorobami zrealizowane zostały poprzez wykorzystanie głębokich modeli splotowych sieci neuronowych. Algorytmy rozpoznawania stanów rozwojowych i infekcji drzew utworzone zostały z wykorzystaniem chmury obliczeniowej Google Colab. Środowisko to zapewnia przeprowadzenie obliczeń w tzw. chmurze. Obliczenia zostały wykonane z wykorzystaniem karty graficznej Nvidia Tesla T4. Dla każdej z utworzonych baz danych wyodrębniony został zbiór trenujący, walidacyjny i testowy. Obrazy drzew tworzące bazy danych poddane zostały augmentacji. Na ich podstawie tworzona i trenowana jest sieć wybranych modeli CNN. Po wytrenowaniu przeprowadzany został transfer learning, gdzie trenowane są tylko nowe warstwy modelu. Kolejno wykonywana była pięciokrotna walidacja krzyżowa w celu uzyskania najbardziej prawdopodobnej reprezentacji wyników.

Rozpoznawanie stanów rozwojowych drzew owocowych polega na zaklasyfikowaniu obrazów pozyskanych z plantacji sadowniczej do pięciu wyodrębnionych zestawów związanych z rozwojem drzew owocowych w sezonie wegetacyjnym. W celu optymalizacji zużycia wody z środkami ochronnymi do oprysku wyróżnić należy pięć etapów sezonu owocowego: okres bezlistny, okres przed kwitnieniem, okres kwitnienia, okres po kwitnieniu oraz okres wzrostu zawiązków. W tym czasie liście i pędy rozwijają się najintensywniej na drzewach. Zmiany te wymagają przede wszystkim konieczności regulacji ciśnienia oprysku w zależności od danego stanu rozwojowego, aby uzyskać pełne pokrycie przrastającej zielonej tkanki. Wytrenowanie modeli CNN klasyfikujących obrazy stanu rozwojowego drzew wymagało przygotowania bazy zdjęć (tab. 3.1) przedstawiających dany stan rozwojowy. Łącznie wykonano 7751 zdjęć o różnych porach dnia, które utworzyły bazę danych 1.

Tabela 3.1. Liczba zdjęć do badania stadiów rozwojowych drzew

Stan drzewa	Liczba próbek
okres bezlistny	1440
okres przed kwitnieniem	1634
okres kwitnienia	1408
okres po kwitnieniu	1766
okres wzrostu zawiązków	1503

Konstrukcja pojazdu z opryskiwaczem, w której kamera boczna, analizująca drzewa do oprysku jest na przodzie a obszar oprysku znajduje się w tylnej części pojazdu powoduje powstawianie opóźnienia w czasie:

$$T_d = \frac{x}{v} - \sum_i t_i; \quad T_d \geq 0 \quad (3.1)$$

gdzie:

$x$  – odległość między kamerą boczną sterującą a dyszami wylotowymi opryskiwacza [m]

$v$  – prędkość pojazdu (ciągnika z opryskiwaczem) dokonującego oprysk [m/s]

Opóźnienie  $T_d$  w powinno zostać uwzględnione przez system wykrywający drzewa i operujący dyszami opryskiwacza tak, aby wykryte drzewa były opryskane w właściwym czasie. W rozpatrywanym systemie uwzględniono poniżej przedstawione czasy składowe:

$t_k$  – czas kodowania obrazu,  $t_t$  – czas transmisji sygnału,  $t_a$  – czas przetwarzania sygnału przez algorytm,  $t_s$  – czas reakcji sterownika,  $t_e$  – czas reakcji elektrozaworu.

Czas  $T_d$  musi być nieujemny, zatem suma powyższych czasów nie może przekroczyć czasu przejazdu odległości  $x$ . Wpływa to przede wszystkim na maksymalny czas  $t_a$ , który przeważnie jest najdłuższy ze wszystkich składowych.

Baza danych nr 1 utworzona do trenowania splotowych sieci neuronowych:

- Przykład zdjęć ze zbioru drzewa sadownicze okres bezlistny:



- Przykłady zdjęć ze zbioru drzewa sadownicze okres przed kwitnieniem:



- Przykłady zdjęć ze zbioru drzewa sadownicze okres kwitnienia:




- Przykłady zdjęć ze zbioru drzewa sadownicze okres po kwitnieniu:



- Przykłady zdjęć ze zbioru drzewa sadownicze okres wzrostu zawiązek:



Tworząc bazę danych nr 1 przedstawiającą fazy rozwojowe drzewa uwzględniono skalę BBCH (BBCH, niem. Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie) [115] i przypisano do wyodrębnionych okresów, odpowiedni kod dziesiętny (rys. 3.11): okres bezlistny BBCH 10, okres przed kwitnieniem BBCH 30, okres kwitnienia BBCH 60, okres po kwitnieniu BBCH 70, wzrost zawiązków BBCH 80. Oznaczenie to zostało przyjęte do prezentacji i analizy wyników testów przedstawionych w podrozdziale 4.4.1.



Rys. 3.11 Fazy rozwojowe drzewa czereśni wg skali BBCH [115]

Rozpoznawanie infekcji drzew polega na klasyfikacji obrazów pozyskanych w trakcie wykonywania oprysków z kamery bocznej umieszczonej na karoserii ciągnika. Obrazy te poddawane są analizie w celu wykrycia objawów infekcji chorobowych. Zadanie wizyjnej inspekcji plantacji można traktować, jak wstępną kontrolę skuteczności wykonywanych oprysków. W praktyce sadowniczej dąży się do minimalizacji ryzyka wystąpienia objawów infekcji poprzez stosowanie wczesnego monitoringu źródeł infekcji. Nie można jednak wykluczyć, że mimo stosowanej strategii ochronnej drzewa zostaną zainfekowane, np. chorobami powstałymi w wyniku wadliwego materiału szkółkarskiego wykorzystanego do produkcji sadzonek lub chorobami rzadkimi występującymi nieregularnie. Z wymienionych powodów konieczna jest regularna inspekcja plantacji, która odbywa się w trakcie wykonywania zabiegów ochronnych. Algorytm inspekcyjny klasyfikuje wykryte drzewa, na drzewa bez infekcji chorobowych i drzewa z infekcjami chorobowymi. Na tej podstawie aktualizowana jest numeryczna mapa plantacji wskazująca położenie zainfekowanych drzew. Pozwala to na aktualizację danych do sygnalizacji koniecznych oprysków oraz uzyskanie informacji, pozwalających sadownikowi na właściwą reakcję zapobiegającą dalszej degradacji plantacji. Wytrenowanie modeli CNN klasyfikujących odpowiednio obraz niezainfekowanych i zainfekowanych drzew również wymagało przygotowania bazy zdjęć (tab. 3.2). Łącznie wykonano 3354 zdjęć o różnych porach dnia, które utworzyły bazę danych nr 2.

Tabela 3.2 Liczba zdjęć do badania zainfekowanych drzew

Stan drzewa	Liczba próbek
bez infekcji	1745
zainfekowane	1609




Baza danych nr 2 utworzona do trenowania splotowych sieci neuronowych:

- Przykłady zdjęć ze zbioru drzewa sadownicze z infekcjami:




- Przykłady zdjęć ze zbioru drzewa sadownicze bez widocznych infekcji



### 3.2.4 Wizyjna predykcja zapotrzebowania na środki ochrony drzew owocowych

Przedstawiony w podrozdziale 3.2.3 algorytm detekcji wysokości drzew spełniać może dodatkową funkcję. Poprzez numeryczną rejestrację liczby aktywnych dysz opryskiwacza w trakcie przejazdu w określonym czasie (rys. 3.12), można oszacować zapotrzebowanie na ilość wody i oprysku potrzebnego na dany obszar plantacji sadowniczej.



Rys. 3.12 Wykres aktywacji dysz przystawki opryskiwacza w czasie oprysku jednej alei drzew

Można dokonać predykcji ilości środków chemicznych potrzebnych do oprysku. Ilość  $V$  wykorzystanego środka do oprysku można wyznaczyć z poniższego wzoru:

$$V = W \cdot T \quad (3.2)$$

gdzie:

$T$  – czas oprysku [s],

$W$  – wydatek oprysku [l/s]

Czas oprysku uzależniony jest od drogi oprysku i prędkości przejazdu. Zakładając stałą prędkość przejazdu uzyskujemy:

$$T_o = \frac{s}{v} \quad (3.3)$$

gdzie:

$s$  – droga oprysku [m]

$v$  – prędkość pojazdu (ciągnika z opryskiwaczem) dokonującego oprysk [m/s]

Wydatek oprysku  $W$  uzależniony jest od liczby aktywnych dysz i wydatku oprysku pojedynczej dyszy

$$W = k_d \cdot W_d \quad (3.4)$$

gdzie:

$k_d$  – liczba dysz przystawki opryskiwacza

$W_d$  – wydatek oprysku pojedynczej dyszy [l/s]

Bez zastosowania inteligentnego sterowania dyszami opryskiwacza, przez cały czas trwania oprysku wszystkie dysze są aktywne. W związku z tym, ilość wypryskiwanego środka wynosi:

$$V_D = k_d \cdot W_d \cdot T_o \quad (3.5)$$

Ilość środka wypryskiwanego po zastosowaniu algorytmu detekcji wysokości drzew sterującego dyszami opryskiwacza zmniejsza się i wynosi:

$$V_A = \sum_{i=0}^{k_d} i \cdot W_D \cdot T_i \quad (3.6)$$

gdzie:

$T_i$  jest czasem równoczesnej aktywacji  $i$  dysz.

W rozpatrywanym przypadku opryskiwacz ma 5 dysz, zatem  $k_d = 5$ , czyli w konsekwencji:

$$V_A = 0 \cdot T_0 + W_D \cdot T_1 + 2W_D \cdot T_2 + 3W_D \cdot T_3 + 4W_D \cdot T_4 + 5W_D \cdot T_5 \quad (3.7)$$

Suma czasów  $T_i$  aktywacji dysz przystawki opryskiwacza równa się czasowi przejazdu. Dla rozpatrywanego przypadku będzie to:

$$T = T_0 + T_1 + T_2 + T_3 + T_4 + T_5 \quad (3.8)$$

Poniżej przedstawiono przykład numeryczny dla przejazdu zaprezentowanego na rys. 3.12. Ze zbioru danych decyzyjnych sterujących dyszami opryskiwacza odczytano następujące informacje o łącznych czasach aktywacji dysz i całkowitym czasie przejazdu:

$$T_0 = 0 \text{ s}$$

$$T_1 = 0 \text{ s}$$

$$T_2 = 19 \text{ s}$$

$$T_3 = 37 \text{ s}$$

$$T_4 = 62 \text{ s}$$

$$T_5 = 44 \text{ s}$$

$$T = 162 \text{ s}$$

Wydatek wykorzystywanych dysz wynosił  $W_D = 0,04$  l/s. Zatem, w przypadku klasycznego opryskiwacza, który pracowałby ze stałą (tj. maksymalną) liczbą dysz, zużyto by następującą ilość środków ochrony roślin (w mieszaninie z wodą):

$$V_D = 5 \cdot 0,04 \cdot 162 = 32,4 \text{ l}$$

Po zastosowaniu automatycznego sterowania dyszami, z użyciem algorytmu analizującego wysokość drzew, ilość użytego środka maleje:

$$V_A = 2 \cdot 0,04 \cdot 19 + 3 \cdot 0,04 \cdot 37 + 4 \cdot 0,04 \cdot 62 + 5 \cdot 0,04 \cdot 44$$

$$V_A = 1,52 \text{ l} + 4,44 \text{ l} + 9,92 \text{ l} + 8,81 \text{ l} = 24,68 \text{ l}$$

Wyliczona oszczędność oprysku pojedynczej alei drzew wyniosła:

$$\Delta V = V - V_A \quad (3.9)$$

$$\Delta V = 32.41 - 24.681 = 7.721$$

co dało względną oszczędność około 24 %. Na powyższym przykładzie widać, że zastosowana procedura daje wymierne efekty oszczędności środków ochrony roślin, wody i redukcji szkodliwego wpływu na środowisko naturalne.

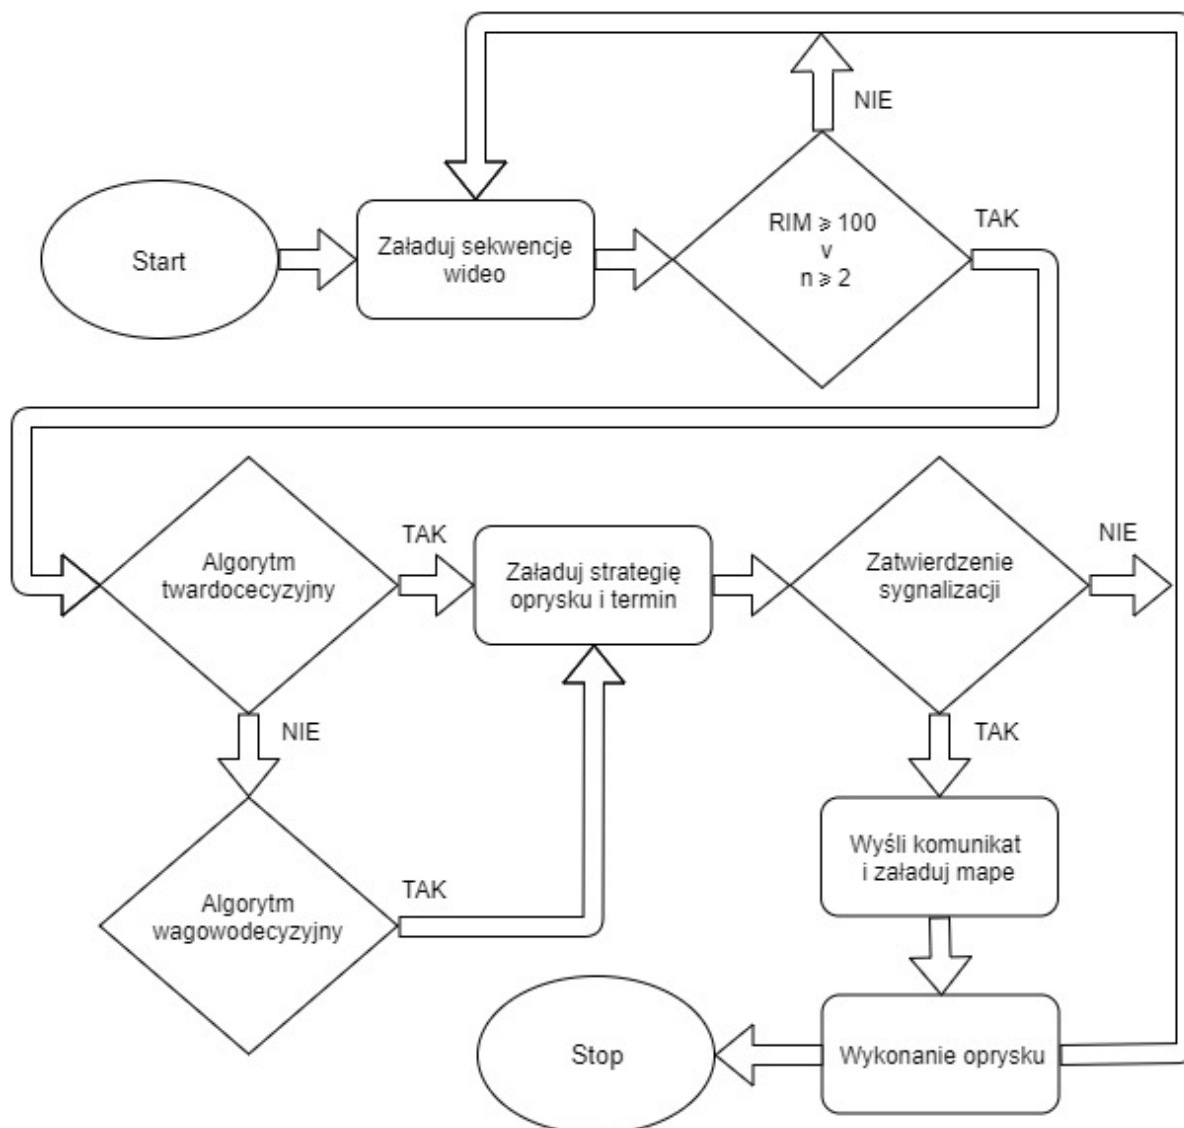
### 3.3 Główny algorytm decyzyjny

Schemat blokowy (rys. 3.1) przedstawia system, w którym dane pozyskiwane z modułowego systemu wizyjnego, monitoringu warunków pogodowych, komunikatów sadowniczych oraz z wizyjnej inspekcji plantacji, zostają przetwarzane i służą do generowania sygnalizacji wspomagającej decyzję o wykonaniu zabiegu ochronnego. Do generowania sygnalizacji wykorzystywana jest także baza danych strategii ochrony przed poszczególnymi zagrożeniami dla plantacji sadowniczych. Sygnalizacja może korzystać także z informacji o dostępnych zasobach środków ochronnych. Przygotowana kompletna sygnalizacja wspomaga sadownika w podejmowaniu decyzji o wykonaniu oprysku plantacji z uwzględnieniem terminu wykonania w prognozowanych warunkach pogodowych sprzyjających największej skuteczności zastosowanego środka ochronnego.

Pozyskane dane z prognoz meteorologicznych są kluczowe z punktu widzenia skuteczności wdrożenia odpowiedniego zabiegu ochronnego. Niezależnie od tego, czy oprysk wykonywany jest profilaktycznie lub interwencyjnie oraz czy jego działanie na szkodnika jest kontaktowe, żołądkowe lub transmilarne, ważne jest, aby wykonywany był w odpowiednich warunkach pogodowych. Zbyt silny wiatr utrudnia prawidłowe pokrycie całej tkanki zielonego drzewa, zbyt niska wilgotność powoduje parowanie części środka do atmosfery. Gdy temperatura jest niewystarczająca, skuteczność zabiegu jest niska. Dlatego decydując o terminie zabiegu, ważne jest posiadanie aktualnych danych pogodowych, a także prognozy pogody bezpośrednio po oprysku. Niepożądany jest opad atmosferyczny, zanim oprysk zostanie w pełni wchłonięty, ponieważ następuje splukiwanie środka z liści, co zmniejsza skuteczność zabiegu.

Główny algorytm decyzyjny (rys. 3.13) rozpoczyna swoje działanie od załadowania sekwencji wideo, którą analizuje. W przypadku, gdy z sekwencji wideo wyodrębniana jest informacja o stwierdzonej infekcji ( $RIM \geq 100$ ) lub szkodliwej ilości występującego szkodnika ( $n \geq 2$ ) działanie rozpoczyna algorytm twardego decyzyjny. Jeżeli w założonym oknie czasowym algorytm nie umieści decyzji o wykonaniu oprysku, działanie rozpoczyna algorytm wagowo decyzyjny, który do czynników wpływających na decyzję przypisuje wagi. Wypracowanie decyzji sygnalizacyjnej wskazującej na konieczność przeprowadzenia oprysku system realizuje w oparciu o dostępne dane wizyjne z monitoringu i z inspekcji plantacji, dane meteorologiczne i strategie ochronne. Sygnalizacja zawiera informacje o danym zagrożeniu, sposobie zwalczania i sugerowanym terminie wykonania zabiegu ochronnego. Gdy, w wyniku analizy algorytmicznej, przekroczone zostaną parametry sygnalizujące wystąpienie symptomów choroby (RIM) lub szkodnika ( $n$ ), załadowana zostaje strategia oprysku z utworzonej bazy strategii ochronnych wraz z wskazanym terminem wykonania zabiegu na podstawie analizy prognozowanych warunków pogodowych. Komunikat sygnalizacyjny wysyłany jest do sadownika celem akceptacji. Następnie, komunikat porównywany jest z wiadomościami sadowniczymi generowanymi na dany obszar kraju przez firmy konsultingowe celem porównania ustaleń ze systemu i załadowana zostaje mapa numeryczna plantacji, na której realizowany będzie oprysk. Etap wykonawczy realizowany jest przez zmodernizowany ciągnik z opryskiwaczem sadowniczym przystosowanym do pracy w trybie autonomicznym.

Kamery umieszczone na karoserii ciągnika odpowiadają za kalibrację parametrów oprysku w celu minimalizacji wydatku cieczy użytkowej oraz pełnią rolę wizyjnej inspekcji plantacji. W trakcie oprysków, wizyjny moduł zbiera dane kontrolne za pomocą kamer systemu wizyjnego, umieszczonych na karoserii ciągnika. Dane te są następnie przetwarzane i wykorzystywane do podejmowania decyzji o kolejnych niezbędnych procedurach ochronnych.



Rys. 3.13 Struktura głównego algorytmu wspomagającego podejmowanie decyzji (opracowanie własne)

Algorytm decyzyjny może pracować w jednym z dwóch trybów: twarodecyzyjnym lub uwzględniającym wagi poszczególnych sygnalizacji.

#### a. Algorytm twarodecyzyjny

Decyzja o podjęciu oprysku dana jest wzorem:

$$D(t) = \prod_{i=1}^N S_i(t) \quad (3.10)$$

gdzie:

$N$  – liczba czynników (sygnałów) wpływających na decyzję o wykonaniu oprysku.

Sygnalizacja  $S_i(t) = \{0,1\}$ , zezwalająca lub nie na oprysk ze względu na różne sygnały wejściowe.



W rozpatrywanym systemie uwzględniono poniżej przedstawione sygnały (wskaźniki pogodowe i związane z sygnalizacją chorobową):

- temperaturę

$$s_T(t) = \begin{cases} 0 & \text{dla } T(t) < T_p \\ 1 & \text{dla } T(t) \geq T_p \end{cases} \quad (3.11)$$

gdzie:

$T(t)$  – temperatura [°C],

$T_p$  – wartość progowa temperatury umożliwiająca skuteczne przeprowadzenie oprysku,

- wiatr

$$s_W(t) = \begin{cases} 0 & \text{dla } w(t) > w_p \\ 1 & \text{dla } w(t) \leq w_p \end{cases} \quad (3.12)$$

gdzie:

$w(t)$  – prędkość wiatru [m/s]

$w_p$  – wartość progowa wiatru, powyżej której przeprowadzenie oprysku jest niezalecane (oraz nieefektywne ze względu na duże rozpylenie środka poza korony drzew),

- porę dnia

$$s_D(t) = \begin{cases} 0 & \text{dla } g(t) \neq g_p \\ 1 & \text{dla } g(t) = g_p \end{cases} \quad (3.13)$$

gdzie:

$g(t)$  – godzina oprysku [h]

$g_p$  – przedział czasu, w którym wykonywanie oprysków jest dozwolone

- opady

$$s_o(t) = \begin{cases} 0 & \text{dla } O(t) > 0 \\ 1 & \text{dla } O(t) = 0 \end{cases} \quad (3.14)$$

gdzie:  $O(t)$  – ilość opadów [mm]

- sygnalizację RIM i ilości szkodników

$$s_z(t) = \begin{cases} 0 & \text{dla } RIM < 100 \wedge n < 2 \\ 1 & \text{dla } RIM \geq 100 \vee n \geq 2 \end{cases} \quad (3.15)$$

gdzie:

$RIM$  to parametr sygnalizujący wystąpienie infekcji chorobowej

$n$  – parametr sygnalizujący wystąpienie szkodnika (liczba zliczonych szkodników w pułapce feromonowej)


Uszczegóławiając system decyzyjny można, w dalszych etapach jego rozwoju, uwzględnić kolejne sygnały wejściowe (zwiększając wartość stałej  $N$ ).

Poniżej zaprezentowano przykład działania algorytmu twardego na rzeczywistych danych. Przyjęto następujące wartości progowe (tab. 3.3):

Tabela 3.3 Przyjęte wartości progowe czynników wpływających na decyzję

Czynnik	symbol	wartość	jednostka
wiatr	$w_p$	10	[m/s]
temperatura	$T_p$	12	[°C]
opad	$o_p$	0	[mm]
godzina	$g_p$	$g_p \in <19^{00}, 23^{59}> \cup <0^{00}, 6^{00}>$	[h]

Rysunek 3.14 przedstawia, przy założeniu istniejącej w czasie pięciu kolejnych dni sygnalizacji przekroczenia parametru  $RIM$  lub  $n$ , zmienność czynników w czasie i wartości funkcji sygnalizacji  $S_i(t)$  (oznaczone szarymi obszarami dla wartości aktywacji równej 1). Ostatecznie decyzja  $D(t)$  przyjęła wartość pozytywną w dwóch przedziałach czasu: od dnia 3, godz. 20:00 do dnia 4, godz. 6:00 oraz dnia 5, godz. 22:00 – 24:00.



Rys. 3.14 Wykres działania algorytmu twardodecyzyjnego

## b. Algorytm wagodecyzyjny

W praktyce algorytm twardeodecyzyjny może uniemożliwić przeprowadzenie oprysku przy niekorzystnym złożeniu czynników, np. pogodowych. Opóźnienie decyzji o oprysku o kilka, a nawet kilkanaście dni może pogorszyć warunki wzrostu owoców i mieć istotne znaczenie ekonomiczne. Dla takich przypadków zaproponowano modyfikację algorytmu twardeodecyzyjnego umożliwiającą dodanie wag do poszczególnych sygnalizacji (sygnałów zezwalających).

Algorytm decyzyjny uwzględniający ważność sygnałów zezwalających ma zatem postać:

$$D_w(t) = \begin{cases} 0 & \text{dla } d_w(t) < d_p \\ 1 & \text{dla } d_w(t) \geq d_p \end{cases} \quad (3.16)$$

gdzie  $d_p$  to doświadczalnie dobrany próg decyzyjny w zakresie  $d_p \in \langle 0,1 \rangle$

Ważona suma czynników decyzyjnych (sygnalizacji, sygnałów zezwalających) wynosi:

$$d_w(t) = \frac{1}{N} \sum_{i=1}^N a_i \cdot s_i(t), \quad d_w \in \langle 0,1 \rangle \quad (3.17)$$

gdzie

$a_i \in \langle 0,1 \rangle$  to indywidualne wagi przypisane do poszczególnych czynników określające ich ważność.

Zaprezentowane powyżej rozwiązanie pozwala na zwiększenie lub zmniejszenie wagi, a nawet eliminację wybranych sygnałów (po przypisaniu im wagi równej 0), branych pod uwagę przy podjęciu decyzji o oprysku. Wykorzystywane jest gdy algorytm twardeodecyzyjny nie zezwala na oprysk przez dłuższy czas.





Poniżej zaprezentowano przykład działania algorytmu wagodecyzyjnego na rzeczywistych danych. Przyjęto następujące wartości progowe (tab. 3.4):

Tabela 3.4 Przyjęte wartości wag czynników wpływających na decyzję

Czynnik	symbol	wartość	waga	Jednostka
wiatr	$w_p$	10	0.5	[m/s]
temperatura	$T_p$	12	0.75	[°C]
opad	$o_p$	0	1	[mm]
godzina	$g_p$	$g_p \in \langle 19^{00}, 23^{59} \rangle \cup \langle 0^{00}, 6^{00} \rangle$	1	[h]

oraz próg decyzyjny  $d_p = 0.7$ . Rysunek 3.15 przedstawia, przy założeniu występującej w czasie pięciu kolejnych dni sygnalizacji przekroczenia parametru  $RIM$  lub  $n$ , zmienność pozostałych czynników wpływających na decyzję w czasie oraz wartości funkcji sygnalizacji  $a_i S_i(t)$  (oznaczone szarymi obszarami dla wartości aktywacji równej 1). Ostatecznie, decyzja  $D_w(t)$  przyjęła wartość pozytywną wcześniej niż w przypadku algorytmu twardeodecyzyjnego, tj. dnia 3 od godz. 3:00 do 6:00. Przyjęte mniej korzystne warunki (np. w tym przypadku dopuszczona większa prędkość wiatru i niższa temperatura) pozwolą na wykonanie oprysku z użyciem przystosowanych opryskiwaczy wyposażonych w wentylatory odpowiednio wydajności powietrza wdmuchujący rozpyloną ciecz użytkową (oprysk). Faktycznie, rozwiązanie to jest często praktykowane z uwagi na dotrzymanie obowiązkowego terminu zabiegów dla środków ochronnych mogących mieć zastosowanie tylko przez określony czas po wystąpieniu infekcji.

Ze względu na fakt, że w obecnym stanie rozwoju i strojenia algorytmów decyzyjnych rozwiązania te mogą jeszcze popełniać błędy, w obu wersjach algorytmów decyzyjnych automatycznie wyznaczona decyzja jest przekazywana do eksperta. To ekspert, wykorzystując swoją wiedzę, ostatecznie weryfikuje decyzję i zezwala lub nie na wykonanie oprysku.



Rys. 3.15 Wykres działania algorytmu wagowodecyzyjnego

### 3.4 Splotowe sieci neuronowe

W czasie analizy literatury przedmiotu zauważono, że bardzo dużo projektów m.in. z obszaru Ogrodnictwa 4.0 wykorzystuje CNN, co skutkuje wysoką dokładnością w realizacji stawianych zadań. W pracy zdecydowano się więc na użycie modeli głębokich splotowych sieci neuronowych.

Głębokie sieci neuronowe DNN (DNN, ang. deep neural networks), zwane także sieciami neuronowymi z wyprzedzeniem lub perceptronami wielowarstwowymi, są kwintesencją modeli głębokiego uczenia się. Celem sieci wyprzedzających jest przybliżenie pewnej funkcji. Na przykład dla klasyfikatora

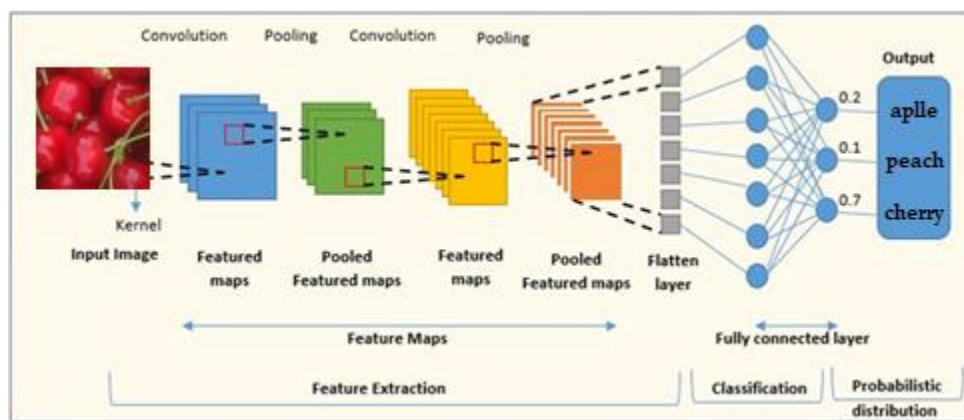
$$y = f^*(x) \quad (3.18)$$

mapuje się dane wejściowe  $x$  na kategorię  $y$ . Sieć ze sprzężeniem zwrotnym definiuje mapowanie

$$y = f(x; \theta) \quad (3.19)$$

i uczy się wartości parametrów  $\theta$ , które dają najlepsze przybliżenie funkcji. Dodatkowe warstwy sprawiają, że model uczy się bardziej złożonych reprezentacji danych, co wpływa się na zwiększenie dokładność w wielu zadaniach.

Splotowe sieci neuronowe (CNN) to specjalny typ głębokich sieci neuronowych, które są szczególnie skuteczne w przetwarzaniu obrazów (rys. 3.16). CNN wykorzystują operacje splotu do skanowania obrazu w poszukiwaniu lokalnych wzorców, takich jak krawędzie, kształty i tekstury. Dzięki temu są one w stanie efektywnie uczyć się hierarchicznych reprezentacji obrazów, co czyni je niezwykle skutecznymi w zadaniach takich jak klasyfikacja obrazów i detekcja obiektów. Każda architektura splotowej sieci neuronowej składa się z różnej liczby warstw i indywidualnych komponentów.



Rys. 3.16 Schemat typowej splotowej sieci neuronowej [116]

Jak podano powyżej, operacja splotu (ang. convolution) jest kluczowym elementem sieci splotowych. Jest to operacja matematyczna, która w przypadku użycia w przetwarzaniu obrazów przetwarza dwa zbiory: obraz wejściowy oraz maskę filtru (lub jądro) i wytwarza obraz wyjściowy, który jest wynikiem „przejścia” maski filtru przez obraz wejściowy. W przypadku sieci CNN, filtry są uczonymi parametrami sieci, które są dostosowywane podczas procesu uczenia się w celu ekstrakcji użytecznych cech z obrazów wejściowych.

- Operacja splotu ciągła:

$$(x*w)(t) = \int x(a)w(t - a)da \quad (3.20)$$



- o wynikiem jest funkcja, np. uśredniona wartość  $x(x)$  względem wszystkich pozycji  $w(a)$  jeśli  $w$  spełnia wymagania gęstości prawdopodobieństwa
- o w terminologii CNN:  
 $x$  – sygnał wejściowy,  $w$  – kernel (filtr), wagi połączeń neuronu  
wartości wyjściowe tworzą mapę cech

$$s(i) = \sum_m x(m)w(i - m) \quad (3.21)$$

Często używamy również operacji splotu na więcej niż jednej osi na raz. Na przykład, jeśli jako dane wejściowe użyjemy dwuwymiarowego obrazu  $I$ , prawdopodobnie będziemy używali również dwuwymiarowego jądra  $K$ .

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (3.22)$$

Splot jest przemienny, co oznacza, że można zapisać równoważnie

$$S(i, j) = (K * I)(i, j) = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (3.23)$$

Kolejnym istotnym elementem splotowych sieci neuronowych jest pooling. Jest to operacja, która ma na celu zmniejszenie wymiarowości danych przetwarzanych przez sieć. Operacja ta jest wykonywana po każdej warstwie splotu w celu zredukowania ilości parametrów i obliczeń w sieci, a także w celu zapewnienia niezmienniczości na przesunięcia [117].

Istnieją różne rodzaje operacji pooling, ale najpopularniejsze to max pooling i average pooling:

- max pooling: w tej operacji, dla każdego okna w wejściowej macierzy (o określonym rozmiarze, np. 2x2), wybierana jest największa wartość. Ta operacja efektywnie zwraca cechy, które są najbardziej wyraźne w danym oknie.
- average pooling: dla każdego okna w wejściowej macierzy, obliczana jest średnia wartość. Ta operacja zwraca średnią intensywność cech w danym oknie.

### 3.4.1 Trenowanie głębokich modeli CNN

Prawie wszystkie algorytmy głębokiego uczenia można opisać jako szczególne przypadki następującego zadania: połączyć specyfikację zbioru danych, funkcję kosztu, procedurę optymalizacji i model. Na przykład, algorytm regresji liniowej łączy zbiór danych składający się z  $X$  i  $y$ , czyli funkcji kosztu:

$$J(w, b) = -\mathbb{E}_{x, y \sim \hat{p}_{data}} \log p_{model}(y|x) \quad (3.24)$$

W kontekście uczenia maszynowego, funkcje straty są kluczowym elementem, który pomaga w optymalizacji modeli poprzez minimalizację błędów.

Większość nowoczesnych sieci neuronowych jest szkolona przy użyciu estymacji największej wiarygodności. Oznacza to, że funkcja kosztu jest ujemnym logarytmem wiarygodności, równoważnie opisanym jako entropia krzyżowa między danymi uczącymi a rozkładem modelu. Ta funkcja kosztu jest dana przez:

$$J(\theta) = -\mathbb{E}_{x, y \sim \hat{p}_{data}} \log p_{model}(y|x) \quad (3.25)$$

Ostateczna postać funkcji kosztu zmienia się w zależności od architektury modelu, w zależności od konkretnej postaci  $\log p_{model}$  [117].

Typowe funkcje straty używane w regresji to:

- **MAE** (MAE, ang. mean absolute error),
- **MSE** (MSE, ang. mean squared error)
- **MAPE** (MAPE, ang. mean absolute percentage error).

Metryki pomagają w kwantyfikacji różnicy między rzeczywistymi a przewidywanymi wartościami. W przypadku klasyfikacji, często stosuje się funkcje straty takie jak Categorical Cross Entropy, często stosowana w klasyfikacji wieloetykietowej, gdzie próbka wejściowa może należeć do jednej z wielu klas. W tym przypadku funkcja straty jest łączona z funkcją aktywacją softmax na wyjściu sieci. Funkcja softmax zwraca prawdopodobieństwo każdej klasy, gdzie suma prawdopodobieństw wszystkich klas wynosi 1. To oznacza, że model gwarantuje, że dana obserwacja należy do jednej z klas.

- Softmax w warstwie wyjściowej:

$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (3.26)$$

- wartości (0,1) unormowane

$$\sum_i \text{softmax}(z)_i = 1 \quad (3.27)$$

- zastosowanie: klasyfikacja  $n$  rozłącznych klas, wartości kodowane w postaci wektora binarnego

$$[0, \dots, 0, 1, 0, \dots, 0] \quad (3.28)$$

- wartości wyjściowe sieci reprezentują rozkład prawdopodobieństw zmiennej wyjściowej

$$\hat{y}_i = P(y = i|X), \quad i = 1, \dots, n \quad (3.29)$$

Innym typem funkcji straty jest Binary Cross Entropy, stosowana w zadaniach gdzie mamy do czynienia tylko z dwoma możliwymi klasami lub etykietami, np. pozytywną i negatywną lub prawdziwą i fałszywą. W tym przypadku na wyjściu sieci stosowana jest funkcja sigmoidalna. W przeciwieństwie do funkcji softmax, funkcja sigmoidalna, znaną również jako funkcja logistyczna, mapuje dowolną liczbę rzeczywistą na wartość między 0 a 1:

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (3.30)$$

Poniżej przedstawione są podstawowe kroki uczenia:

### 1. Propagacja wprzód

Na początku, dla danego wejścia, przeprowadza się propagację w przód przez sieć, aby obliczyć wyjście sieci. W trakcie tego procesu, zachowuje się wszystkie międzywarstwowe aktywacje i wyjścia, które będą potrzebne w kroku wstecznej propagacji.

## 2. Obliczanie błędu

Następnie oblicza się błąd sieci, który jest różnicą między wyjściem sieci a prawdziwym celem. Ten błąd jest następnie wykorzystywany do obliczenia gradientu funkcji strat na wyjściu.

## 3. Wsteczna propagacja błędu

Błąd jest następnie propagowany wstecz przez sieć. Zaczynając od ostatniej warstwy sieci, oblicza się gradient funkcji strat względem wag, a następnie wykorzystuje się ten gradient do obliczenia gradientu funkcji strat względem aktywacji poprzedniej warstwy. Proces ten jest powtarzany, przechodząc wstecz przez sieć, stąd nazwa „wsteczna propagacja”.

## 4. Aktualizacja wag

Na koniec, wykorzystuje się obliczone gradienty do aktualizacji wag sieci. Wagi są aktualizowane w kierunku, który najbardziej redukuje błąd, co jest określane przez gradient.

Algorytm wstecznej propagacji jest kluczowym elementem uczenia się sieci neuronowych. Jest to metoda, która pozwala na efektywne obliczenie gradientów, które są następnie używane do aktualizacji wag w sieci w procesie optymalizacji, zwykle za pomocą metody takiej jak stochastyczny spadek gradientu. Analogiczna sytuacja występuje w sieciach splotowych, te same kroki są stosowane, ale obliczenia są bardziej złożone ze względu na trójwymiarową naturę splotu i operację max-pooling.

Obliczenie wyrażenia analitycznego dla gradientu jest proste, ale numeryczna ocena takiego wyrażenia może być kosztowna obliczeniowo. Algorytm propagacji wstecznej dokonuje tego przy użyciu prostej i niedrogiej procedury.

Łańcuchowa reguła rachunku różniczkowego (nie mylić z łańcuchową regułą prawdopodobieństwa) służy do obliczania pochodnych funkcji utworzonych przez złożenie innych funkcji, których pochodne są znane. Propagacja wsteczna to algorytm obliczający regułę łańcuchową z określoną kolejnością operacji, która jest bardzo wydajna.

Niech  $x$  będzie liczbą rzeczywistą, a  $f$  i  $g$  będą funkcjami odwzorowującymi liczbę rzeczywistą na liczbę rzeczywistą.

Założmy, że  $y = g(x)$  i  $z = f(g(x)) = f(y)$

$$\frac{dz}{dx} = \frac{dz}{dy} \frac{dy}{dx} \quad (3.31)$$

Możemy to uogólnić na przypadek skalarny. Założmy, że  $x \in \mathbf{R}^m$ ,  $y \in \mathbf{R}^n$ ,  $g$  odwzorowują  $\mathbf{R}^m$  do  $\mathbf{R}^n$  i  $f$  odwzorowują  $\mathbf{R}^n$  do  $\mathbf{R}$ . Jeśli  $y = g(x)$  i  $z = f(y)$ , to

$$\frac{\partial z}{\partial x_i} = \sum_j \frac{\partial z}{\partial y_j} \frac{\partial y_j}{\partial x_i} \quad (3.32)$$

W notacji wektorowej można to równoważnie zapisać jako

$$\nabla_x z = \left(\frac{\partial y}{\partial x}\right)^T \nabla_y z \quad (3.33)$$

gdzie  $\frac{\partial y}{\partial x}$  jest macierzą Jacobiego  $n \times m$

Widzimy z tego, że gradient zmiennej  $x$  można otrzymać przez mnożenie macierzy Jacobiego  $\frac{\partial y}{\partial x}$  przez gradient  $\nabla_y z$ . Algorytm propagacji wstecznej pozwala na wykonanie takiego iloczynu gradientu jacobijskiego dla każdej operacji na wykresie [117].

- Optymalizacja spadkiem gradientu.

Głębokie sieci neuronowe są zwykle optymalizowane za pomocą **algorytmów opartych na spadku gradientu**. Te algorytmy iteracyjnie dostosowują parametry modelu, aby zminimalizować funkcję kosztu.

$$\nabla_{\theta} J(\theta) = -E_{x,y \sim \hat{p}_{data}} \nabla_{\theta} \log p_{model}(x, y; \theta) \quad (3.34)$$

Dokładne obliczenie jest bardzo kosztowne, ponieważ wymaga oceny modelu na każdym przykładzie w całym zbiorze danych. W praktyce, w celu przyspieszenia procesu uczenia można uczyć iteracyjnie, losowo wybierając niewielką liczbę przykładów ze zbioru danych, a następnie uśredniając gradient [117].

Przykłady:

1. **Gradient Descent (Spadek Gradientu)**: Jest to najprostsza metoda, która polega na aktualizacji każdego parametru w kierunku, który najbardziej zmniejsza funkcję kosztu.
2. **Stochastic Gradient Descent (Stochastyczny Spadek Gradientu)**: Jest to wariant metody spadku gradientu, który aktualizuje parametry modelu na podstawie pojedynczego przykładu szkoleniowego, a nie całego zestawu danych.
3. **Mini-Batch Gradient Descent**: Jest to kompromis między spadkiem gradientu a stochastycznym spadkiem gradientu. W tej metodzie parametry są aktualizowane dla małych grup przykładów szkoleniowych, zamiast pojedynczego przykładu lub całego zestawu danych.
4. **Momentum**: Jest to technika, która pomaga przyspieszyć SGD w odpowiednim kierunku i tłumić oscylacje. To robi poprzez dodanie “momentu” do kierunku zmiany parametrów.
5. **Adaptive Gradient (AdaGrad)**: Jest to metoda, która dostosowuje szybkość uczenia się dla każdego parametru, co pozwala na szybsze uczenie się dla rzadziej aktualizowanych parametrów.
6. **RMSProp**: Jest to ulepszenie AdaGrad, które rozwiązuje problem szybkiego zmniejszania się szybkości uczenia się.
7. **Adam (Adaptive Moment Estimation)**: Jest to metoda, która łączy zalety RMSProp i Momentum. Dostosowuje szybkość uczenia się dla każdego parametru i używa momentu, co sprawia, że jest bardzo skuteczny w praktyce.

Wszystkie te metody mają swoje zalety i wady, a wybór między nimi zależy od konkretnego zadania. W praktyce metoda Adam jest często preferowana ze względu na jej dobre wyniki w rozwiązywaniu różnych problemów.

Obecnie stosowane architektury głębokich sieci neuronowych posiadają bardzo złożone struktury i dużą liczbę parametrów (sięgającą nawet setek milionów), które muszą zostać wyliczone w trakcie uczenia. Zazwyczaj im bardziej złożona struktura modelu, tym większa baza, potrzebna aby uniknąć zjawiska przeuczenia się modelu (ang. overfitting).

- Transfer learning

W przypadku niewystarczającego zbioru uczącego możliwe jest zastosowanie pomocniczej metody trenowania – przenoszenia wiedzy (ang. transfer learning) [118], [119]. W metodzie tej wykorzystuje się dwa etapy trenowania. W pierwszym etapie model trenowany jest na bardzo dużej bazie (w praktyce w zadaniu klasyfikacji obiektów na bazie imagenet [120]).

W kolejnym kroku model jest dotrenowywany na docelowej bazie uczącej. Do tego celu wykorzystywany jest wcześniej wytrenowany model z zamrożonymi wagami. Trenowaniu poddane są tylko ostatnie warstwy, (zwykle 3 warstwy połączonych neuronów - fully connected) które pełnią rolę klasyfikatora w sieci. W tym podejściu trening przebiega szybciej i nie wymaga tak dużej liczby przykładów uczących.

- Fine-tuning

W celu uzyskania jeszcze lepszego dopasowania do danych oraz wyższej dokładności (ang. accuracy), po etapie transferowanego uczenia (ang. transfer learning) stosuje się w zależności o potrzeb dodatkowy etap strojenia modelu (ang. fine-tuning) [121], [122], [123]. W tym przypadku wagi całego modelu podlegają trenowaniu (są odmrożone). Jednakże podczas tego treningu wartość współczynnika uczenia (ang. learning rate) powinna mieć relatywnie niską wartość, wraz z niewielką liczbą epok, tak aby tylko nieznacznie dostroić wagi modelu.

- Overfitting

Zjawisko przeuczenia modelu jest istotnym ryzykiem podczas trenowania sieci neuronowej. Objawia się ono głównie poprzez wysoką wartość uzyskiwanej dokładności na etapie trenowania modelu, która jednakże nie przekłada się na wysoką skuteczność na zbiorze testowym i może być nawet bardzo niska. W celu zapewnienia stabilności i niezawodności procesu trenowania sieci stosuje się szereg metod zapobiegania temu zjawisku.

Podstawowym warunkiem skutecznego treningu jest stosowanie rozbudowanej i zróżnicowanej bazy trenującej. W praktyce zauważyć można, że im większy model, tym potrzebna jest też większa baza, aby prawidłowo wyuczyć model. Oprócz zróżnicowanej bazy, proces trenowania zwykle kontroluje się, wykorzystując jednocześnie szereg technik stosowanych na różnych etapach uczenia [124], [125]:

- Augmentacja danych – przed każdą iteracją do paczki danych dodawane są różnego typu manipulacje o losowych współczynnikach.
- Podział bazy na zbiory: uczący, walidacyjny oraz testowy – baza danych jest dzielona na odpowiednie części w celu weryfikacji czy zjawisko przeuczenia ma miejsce.
- Wielokrotna walidacja modelu (ang. K-fold cross-validation) - za każdym razem inna część zbioru jest zbiorem testującym
- Dropout – metoda polega na losowym usuwaniu z sieci z warstw wewnętrznych pojedynczych neuronów w trakcie uczenia, losowe zapominanie niektórych neuronów i nieprzekazywanie informacji.
- Zapisywanie najlepszych wag modelu (ang. early stopping procedure) – proces zapamiętywania w trakcie treningu wag modelu dla którego uzyskano najlepszą dokładność na zbiorze walidacyjnym, bądź testowym.

### 3.4.2 Zastosowane modele CNN

W podrozdziale przedstawione zostały metody algorytmów programowych realizowanych za pomocą spłotowych sieci neuronowych [126]. Dokonano dogłębnej analizy programowo realizowanych zadań, wykonując analizę eksperymentalną. Wybrano architektury odpowiedniej wielkości dostosowane do danego typu zadania i rozmiaru bazy treningowej. Do realizacji zadań rozpoznawania stanów rozwojowych drzew i identyfikacji drzew porażonych przez choroby sadownicze przyjęte zostały dwa modele spłotowych sieci neuronowych, a mianowicie: Xception [69] oraz NasNetLarge [70], których adaptacja do opisywanego projektu została przedstawiona w rozdziałach 3.4.3 i 3.4.4.

Przygotowane i przedstawione wcześniej bazy danych mimo łącznej liczby zdjęć przekraczającej 10 000 obrazów są niewielkimi zbiorami w kontekście zasobów (liczonych w milionach) zwykle wykorzystywanych do treningu spłotowych sieci neuronowych. W przypadku gdy zestaw treningowy może być niewystarczający do treningu sieci stosuje się pomocniczą metodę uczenia transferowego (ang. transfer learning). Metoda ta wykorzystuje dwa etapy treningu. W pierwszym etapie model jest trenowany na bardzo dużej bazie danych (zazwyczaj jest to siatka obrazów dla zadania klasyfikacji obiektów). W następnym kroku modelu jest trenowany na docelowej bazie danych uczących. W tym celu wykorzystywany jest wcześniej wytrenowany model z zamrożonymi wagami. Treningowi podlegają tylko ostatnie warstwy (zwykle trzy warstwy w pełni połączonych neuronów), które następnie działają jako klasyfikator w sieci. W przedstawionej metodzie trening jest szybki i nie wymaga aż tak dużej liczby danych szkoleniowych.

W celu zwiększenia odporności trenowanych modeli na zjawisko nadmiernego dopasowania, zastosowano szereg technik augmentacji. Zakres stosowanych każdej z technik dla danego obrazu jest losowy, ale ograniczony we wskazanym zakresie:

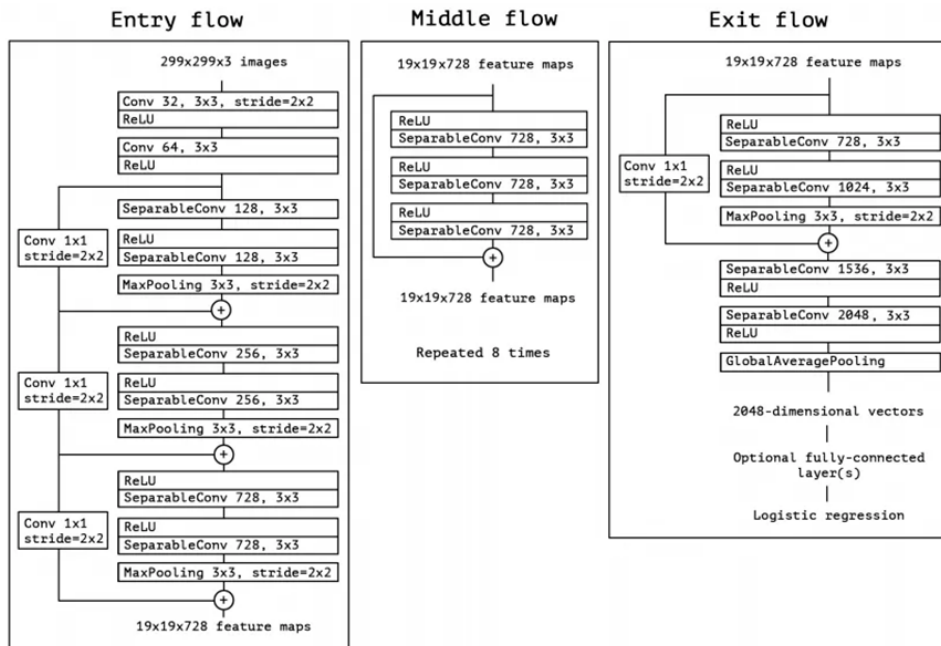
- obrót w osi pionowej (brak, obrót)
- rotacja obrazu (od  $-10^\circ$  do  $10^\circ$ )
- powiększenie (do 40%)
- translacja (do 10%)
- adaptacja kontrastu (factor = 0.3)
- adaptacja poziomu jasności (factor = 0.1).

### 3.4.3 Model Xception

Model Xception jest rozszerzoną wersją modelu Inception V3 [127], w którym bloki Inception, zastąpione zostały warstwami spłotowymi, używanymi osobno dla poszczególnych kanałów przetwarzania. Xception (rys. 3.17) jest podzielony na trzy główne bloki z których środkowy blok podczas trenowania modelu powtarzany jest osiem razy:

- blok wejściowy (ang. entry flow)
- blok środkowy (ang. middle flow)
- blok wyjściowy (ang. exit flow).

W rezultacie jest to liniowy stos warstw spłotowych z dodatkowymi połączeniami (ang. residual connections). W porównaniu z modelem Inception V3 wykazuje niewielki wzrost dokładności klasyfikacji w zbiorze danych ImageNet i znacznie większy wzrost dokładności w zbiorze danych JFT.



Rys. 3.17 Podsumowanie architektury sieci Xception, od lewej: blok wejściowy (entry flow), blok środkowy (middle flow), blok wyjściowy (exit flow) [93]

W przeprowadzonych eksperymentach wykorzystano sieć Xception z wagami wytrenowanymi na bazie ImageNet. Następnie dostosowano architekturę sieci do trenowania z metodą transfer learning dodając warstwę jednokierunkowych perceptronów. Podsumowanie zmodyfikowanej architektury modelu Xception służącej do klasyfikacji stanu rozwojowego drzew przedstawiono w (tab. 3.5). Przy klasyfikacji infekcji drzew zmieniona została tylko liczba perceptronów w ostatej warstwie. Trenowanie sieci odbyło się tylko dla nowej warstwy sieci (trenowaniu podlegało 10245 parametrów), pozostałe wagi zostały zamrożone (tj. około 21 milionów parametrów architektury Xception). Wyniki parametrów modelu przedstawia (tab. 3.6).

Tabela 3.5 Podsumowanie zmodyfikowanej architektury sieci Xception

Layer (type)	Output Shape	Param
input_4 (InputLayer)	[(None, 331, 331, 3)]	0
input_4 (InputLayer)	[(None, 299, 299, 3)]	0
sequential_1 (Sequential)	(None, None, None, 3)	0
rescaling_1 (Rescaling)	(None, 299, 299, 3)	0
NASNet (functional)	(None, 10, 10, 2048)	20 861 480
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 2048)	0
dropout_1 (Dropout)	(None, 2048)	0
dense_1	(None, 5)	10245

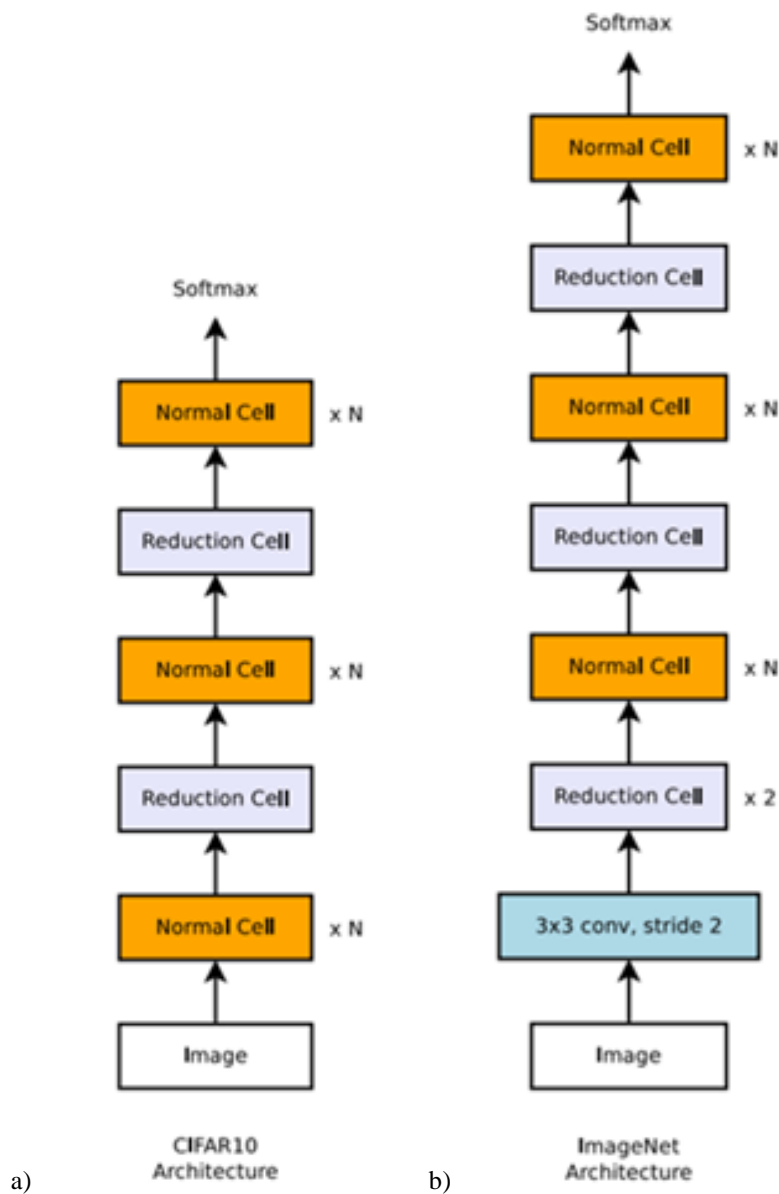
Tabela 3.6 Zestawienie parametrów modelu Xception

Total params: 20 871 725
Trainable params: 10 245
Non-trainable params: 20 861 480



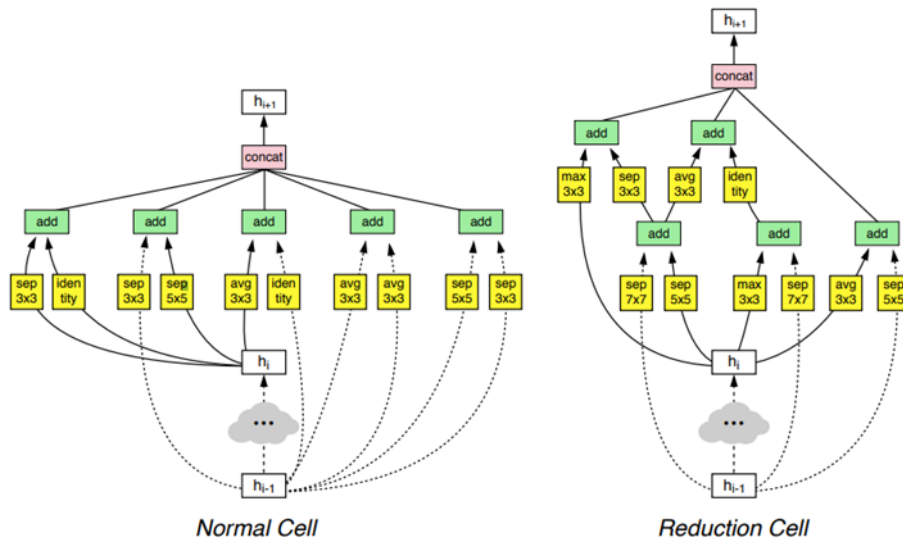
### 3.4.4 Model NasNetLarge

Drugą architekturą CNN wykorzystaną do badań eksperymentalnych był model NasNet (ang. neural architecture search network). Architektura modelu pierwotnie została opracowana w sposób półautomatyczny przy użyciu metod uczenia się przez wzmacnianie. Ze względu na czasochłonny proces poszukiwania optymalnej architektury, analizę przeprowadzono na małym zbiorze danych, a następnie przeniesiono wyszukaną konfigurację bloków do weryfikacji na większym zestawie danych. Na (rys. 3.18a) przedstawiono ogólny schemat sieci zaprojektowany przez autorów [94] dla mniejszej bazy CIFAR10 a na (rys. 3.18b) dla większej bazy ImageNet. W trakcie eksperymentów poszukiwano optymalnej architektury bloku spłotowego (ang. normal cell) oraz redukcyjnego (ang. reduction cell). Przedstawiona sieć powiela komórki spłotowe oraz redukcyjne  $N$  razy.



Rys. 3.18 Diagram przedstawiający ogólną architekturę modelu: a) dla CIFAR-10, b) dla ImageNet [94]

Schemat wyszukanych bloków jest przedstawiony na rysunku 3.19. Pomimo, że przeszukiwanie zostało wykonane na bazie CIFAR-10 to zastosowanie tej samej architektury komórek na bazie ImageNet pozwoliło osiągnąć bardzo wysoką dokładność na poziomie 82.7% (top-1) i 96.2% (top-5).



Rys. 3.19 Ostateczne architektury wyszukanych bloków, od lewej: komórka splotowa, komórka redukcyjna [94]

W przeprowadzonych eksperymentach wykorzystano sieć NasNet w wersji NasNetLarge, z wagami wytrenowanymi na bazie ImageNet. Następnie dostosowano architekturę sieci do trenowania z metodą Transfer Learning dodając warstwę jednokierunkowych perceptronów (tab. 3.7). Trenowanie sieci odbyło się tylko dla nowej warstwy sieci (trenowaniu podlega 20165 parametrów), pozostałe wagi są zamrożone (tj. około 85 milionów parametrów architektury NasNet). Wyniki parametrów modelu przedstawia (tab. 3.8).

Tabela 3.7 Podsumowanie zmodyfikowanej architektury sieci NasNetLarge

Layer (type)	Output Shape	Param
input_4 (InputLayer)	[(None, 331, 331, 3)]	0
sequential_1 (Sequential)	(None, 331, 331, 3)	0
rescaling_1 (Rescaling)	(None, 331, 331, 3)	0
NASNet (functional)	(None, 11, 11, 4032)	84 916 818
global_average_pooling2d_1 (GlobalAveragePooling2D)	(None, 4032)	0
dropout_1 (Dropout)	(None, 4032)	0
dense_1	(None, 5)	20165

Tabela 3.8 Zestawienie parametrów modelu NasNetLarge

Total params: 84 936 983
Trainable params: 20 165
Non-trainable params: 84 916 818

### 3.4.5 Metodyka oceny

Metryka dokładność (ang. accuracy) daje wynik opisujący działanie modelu we wszystkich klasach. Parametr ten jest najbardziej przydatny jeżeli wszystkie klasy są równo ważne. Obliczany zostaje na podstawie stosunku sumy próbek prawdziwie dodatnich TP (TP, ang. true positive) i prawdziwie ujemnych TN (TN, ang. true negative) do sumy wszystkich wartości w macierzy pomyłek [128]:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (3.35)$$

gdzie: suma próbek prawdziwie dodatnich TP (TP, ang. true positives) , suma próbek prawdziwie ujemnych TN (TN, ang. true negatives), suma próbek fałszywie dodatnich FP (FP, nag. False Positives), suma próbek fałszywie ujemnych FN (FN, ang. false negatives).

Właśnie dokładność została przyjęta jako kryterium oceny ze względu zbliżone ilości próbek w klasach wykorzystanych do trenowania rozpatrywanych sieci. Poza przyjętą metryką oceny istnieją również inne np. F1-score, która określa w jakim stopniu wyuczony model sztucznej sieci neuronowej wykonuje przewidywanie przynależności danych pikseli do odpowiednich klas obiektów lub oraz IoU (ang. intersection over union), recall czy precision.

## 4. Część eksperymentalna

### 4.1 Plan eksperymentów

Część eksperymentalną niniejszej pracy przeprowadzono z użyciem specjalnie przygotowanego stanowiska badawczego. Na doświadczalnej plantacji sadowniczej o wymiarach 500 m × 30 m, z rzędami drzew owocowych dokonywano zabiegów za pomocą wyposażonego w system bezprzewodowej automatyki sterującej ciągnika z opryskiwaczem sadowniczym. Założono, że kluczowe dane do sterowania opryskiwacza pochodzić będą z systemu wizyjnego zainstalowanego na ciągniku. Obrazy pozyskane z kamer poddane zostały przetworzeniu w celu pozyskania informacji służących kalibracji i ustalenia parametrów oprysku. Ponadto, włączono zmodernizowany ciągnik i opryskiwacz sadowniczy w system sztucznej inteligencji wspomagający wykonywanie oprysków sadowniczych na podstawie analizy danych pochodzących z modułowego systemu wizyjnego. Automatycznej analizie poddano obrazy pozyskane ze stałego monitoringu szkodników oraz obrazy z wizyjnej inspekcji plantacji wykonywanej w czasie autonomicznych oprysków.

Do wykonania planu badawczego opracowane zostały algorytmy przetwarzania danych wizyjnych, które realizują:

- detekcje szkodników na pułapkach feromonowych rozmieszczonych na plantacji sadowniczej
- rozpoznawanie stanu rozwojowego drzewa i kalibracje ciśnienia oprysku
- rozpoznawanie w czasie przejazdów wysokości drzew i sterowanie ilością aktywnych dysz wylotowych opryskiwacza
- detekcję drzew porażonych chorobami.

Ponadto, opracowana aplikacja umożliwia zdalne sterowanie ciągnikiem i opryskiwaczem sadowniczym oraz wykonuje algorytmy detekcji przeszkód.

Ekspertyzy badawcze wymagały przygotowania bazy zdjęć do automatycznej analizy. Podjęto się utworzenia autorskich baz danych i zrealizowano:

- wykonanie zdjęć pułapek feromonowych ze szkodnikami w środowisku rzeczywistym
- wykonanie zdjęć i nagrań wideo zamieszczonych na karoserii ciągnika.

Przygotowano algorytmy wizyjne poprzez:

- opracowanie programu wykonującego detekcję szkodników i zliczanie ich ilości
- opracowanie programu wykonującego detekcję wysokości drzew na obrazie
- opracowanie programu rozpoznającego stan rozwojowy drzew na obrazie
- opracowanie programu identyfikującego choroby drzew sadowniczych.

Przeprowadzone eksperymenty pozwoliły na ocenę działania zaprojektowanego systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych.

## 4.2 Stanowisko badawcze

Polskie gospodarstwa sadownicze są bardzo zróżnicowane pod względem sprzętu służącego do produkcji owoców. W zależności od posiadanego areалу uprawy, techniki uprawy i rodzaju produkcji, sadownicy posiadają w swoim parku maszynowym najnowocześniejsze modele ciągników i opryskiwaczy sadowniczych oraz maszyny dedykowane do prac sadowniczych. Z przeprowadzonych ankiet wśród sadowników wyodrębnić można pewną grupę ciągników, które mimo upływu lat i zmieniającej się technologii, w dalszym ciągu cieszą się ogromną popularnością ze względu na prostotę budowy, tanią eksploatację, a także możliwości modernizacji przy relatywnie niskich kosztach, w porównaniu do zakupu nowych ciągników. Do tej grupy zaliczyć można przede wszystkim modele takich marek jak: Ursus C-330 i Ursus C-360 wraz z modelami wcześniejszymi Ursus C-325, Ursus C-328, Ursus C-4011 i Ursus C-355 oraz Massey Ferguson MF-235 i MF-255. Wymieniona wyżej grupa rozszerzona o model Władimiriec T-25 stanowi ponad połowę obecnie zarejestrowanych ciągników w naszym kraju. W Polsce jest około 70 tys. gospodarstw sadowniczych, z czego ponad 50 tys. to gospodarstwa o areale do 15 hektarów, w których przeważają wyżej wymienione modele ciągników.

Z punktu widzenia wydajności uprawy oraz jakości produkowanych owoców najistotniejszymi zabiegami sadowniczymi są opryski ochronne. Klasycznie wykonuje je przeszkolony operator, prowadząc ciągnik sprzęgnięty z opryskiwaczem sadowniczym. Wyróżnić można opryskiwacze zawieszane, posiadające zbiornik na ciecz roboczą, o pojemności 200 – 600 litrów oraz opryskiwacze doczepiane, których konstrukcja oparta jest na własnym podwoziu posiadające zbiornik na ciecz roboczą o pojemności 1000 litrów i większej. Analizując komercyjne oferty, wyróżnić należy także opryskiwacze sadownicze które posiadają własny napęd. Wszystkie opryskiwacze sadownicze niezależnie od ich typu posiadają dedykowane przystawki z wentylatorem umożliwiające rozpylanie cieczy roboczej. Należy także wyróżnić opryskiwacze sterowane manualnie i opryskiwacze sterowane komputerem dozującym ciecz roboczą.

Podjętą się realizacji badań naukowych powiązanych z branżą sadowniczą przyjęte zostały kryteria, które swoją uniwersalnością pozwalają na adaptacje opracowanych rozwiązań na użytkowanych w gospodarstwach sadowniczych ciągnikach i opryskiwaczach bez konieczności kupna nowych. Takie podejście nie zamyka możliwości inwestycyjnych w innowacyjne technologie wspomagające produkcje owoców małym i średnim gospodarstwom. Analiza publikacji naukowych z obszaru precyzyjnego rolnictwa i sadownictwa wykazała, że brakuje obecnie propozycji systemów sterowania opryskiwaczami sadowniczymi w oparciu o system wizyjny z algorytmem rozpoznającym wysokość drzew, selekcyjnym gałęzie do oprysku, szacującym powierzchnie liści, opartym na sztucznych sieciach neuronowych.

### 4.2.1 Modernizacja ciągnika i opryskiwacza sadowniczego do pracy w trybie autonomicznym

Z szerokiej gamy istniejących marek i modeli ciągników użytkowanych w gospodarstwach sadowniczych trudno wybrać jeden model do modernizacji na pojazd autonomiczny. Istniejące typy ciągników, które posiadają automatyczne skrzynie biegów, wspomaganie układu kierowniczego oraz podzespoły elektroniczne, ułatwiłyby istotnie modernizacji. Wybrano jednak model ciągnika, który charakteryzuje się, poza mechaniczną prostotą budowy, dodatkowymi wyzwaniami modernizacyjnymi, ze względu na luzy mechanizmów sterowania jazdą spowodowane zużyciem eksploatacyjnym.

Z wyżej wymienionych powodów zdecydowano się na modernizację modelu Władimiriec T-25 (rys. 4.1) produkowanego od 1966 do 1995 roku w ZSRR i później w Rosji. Model ten posiada silnik dwucylindrowy o pojemności skokowej 2077 cm<sup>3</sup> na olej napędowy i skrzynię biegów

o następującej liczbie przełożeń: 8 biegów do przodu i 6 biegów do tyłu, dodatkowo z dwoma biegami pełzającymi do przodu. Zakres prędkości jazdy wynosi od 0,67 do 26,9 km/h, udźwig podnośnika 600 kg, klasa pociągowa 6 kN oraz liczbę obrotów WOM (wałka odbioru mocy) 540 obr/min. Jego wymiary to: szerokość 1370 cm, wysokość z kabiną 2470 cm i długość w granicach 3072-3282 cm przy masie 2020 kg. W ciągniku zainstalowana jest instalacja elektryczna o nominalnym napięciu 12 V.



Rys. 4.1 Ciągnik Władimiriec T-25 po modernizacji z opryskiwaczem sadowniczym (opracowanie własne)

Przygotowanie stanowiska badawczego rozpoczęto od takich modernizacji mechanizmów ciągnika, aby funkcje sterownia jazdą ciągnika mógł kontrolować układ automatyki, komunikujący się z autonomicznym systemem sterowania. Ponadto zmodernizowano instalację elektryczną ciągnika umożliwiającą docelowo automatyczne uruchamianie silnika. Adaptacja wybranego modelu do celów badawczych wymagała modernizacji układu kierowniczego o podzespół wspomagający manewrowanie skrętem kół. Modernizacja ta umożliwiła sterowanie układem kierowniczym przez silnik prądu stałego zasilany napięciem 12 V o mocy 60 W. Sterowanie dźwigniami sprzęgła, hamulca i regulacji obrotów zostało zapewnione poprzez siłowniki liniowe, przemieszczające się w wyznaczonych zakresach. Pominięta została automatyzacja skrzyni biegów, bowiem do wykonywania oprysków sadowniczych z przyjętą prędkością jazdy nie jest ona konieczna (cały przejazd można zrealizować z wykorzystaniem jednego biegu). Zastosowane silniki i siłowniki przekładają na ruch obrotowy lub prostoliniowy sygnały pochodzące z aplikacji sterującej. W celu kontroli bieżącego stanu elementów wykonawczych wykorzystywane są czujniki: kontroli obrotów silnika, kąta skrętu kół, położenia dźwigni sprzęgła i hamulca. Układ automatyki sterowny jest za pośrednictwem sterownika PLC (PLC, ang. programmable logic controller) komunikującego się z aplikacją sterującą.

Z uwagi na fakt, iż celem prezentowanych badań jest obniżenie do minimum konieczności prac związanych z wykonywaniem oprysków sadowniczych przez operatora oraz ograniczenie zużycia chemicznych środków ochrony roślin poprzez ich precyzyjne dozowanie z wykorzystaniem algorytmów wizyjnych, zdecydowano się na wykonanie prototypowej przystawki do wybranego modelu opryskiwacza sadowniczego marki PILMET (rys. 4.2). Rozwiązanie to pozwala na przedstawienie istoty funkcji, którą pełni system wizyjny sterujący dyszami wylotowymi opryskiwacza, odseparowanymi od siebie elektrozaworami załączanymi w zależności od wykrywanej wysokości drzew. Pompa opryskiwacza zapewnia wydajność 60 l/min przy obrotach wałka




napędowego 540 obr/min oraz maksymalne ciśnienie cieczy roboczej do 2 MPa. Zbiornik opryskiwacza może pomieścić 300 litrów cieczy roboczej.



Rys. 4.2 Opryskiwacz PILMET wyposażony w prototypową przystawkę (opracowanie własne)

Poza konstrukcją prototypowej przystawki sadowniczej wykonano standardową modernizację wybranego opryskiwacza marki Pilmet, tak aby funkcje sterownia opryskiem mógł kontrolować układ automatyki. Zastosowano silnik z przekładnią ślimakową do regulacji ciśnienia cieczy roboczej (rys. 4.3) oraz czujnik ciśnienia cieczy roboczej. Dodatkowo zamontowano elektrozawór, którego otwarcie powoduje przekierowanie cieczy roboczej z powrotem do zbiornika. Jest to wykorzystywane w przypadku braku drzew w opryskiwanym rzędzie lub na jałowych przejazdach. Układ automatyki opryskiwacza podobnie jak układ automatyki ciągnika sterowany jest za pośrednictwem sterownika PLC z modułami rozszerzającymi dla którego informacjami wejściowymi są sygnały będące wynikiem przetwarzania algorytmu wizyjnego.



Rys. 4.3 Zmodernizowany układ automatycznej regulacji ciśnienia opryskiwacza (opracowanie własne)

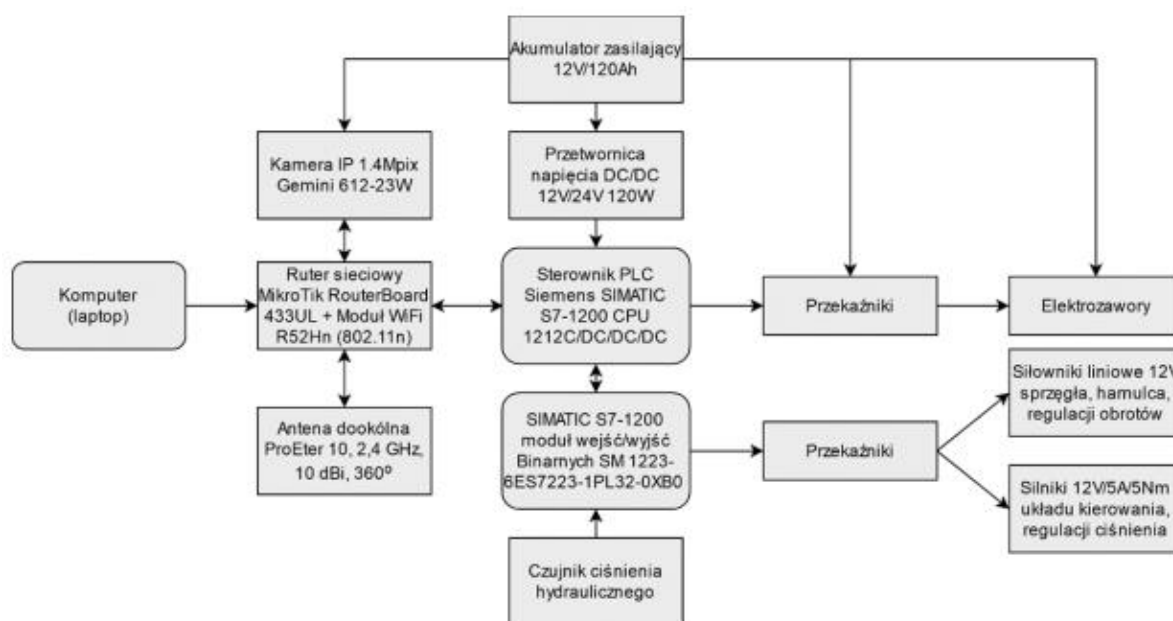
Koncepcja systemu sterownia ciągnikiem wraz z opryskiwaczem sadowniczym - przygotowane rozwiązania w pierwszej kolejności chronią człowieka – operatora standardowo wykonującego zabiegi ochronne, bezpośrednio kierującego ciągnikiem z opryskiwaczem w siedlisku kierowcy. Podkreślić należy, że nie wszystkie ciągniki sadownicze wyposażone są w odpowiedniej klasy kabiny

zapewniające szczelność uniemożliwiającą przedostawanie się do środka pyłu unoszącego się podczas wykonywania oprysków. Uciążliwe jest także wielogodzinne oddychanie przez maski specjalistyczne chroniące drogi oddechowe w przypadku ich stosowania, a także niekorzystny wpływ drgań na operatora ciągnika.

Stosowanie zabiegów ochronnych jest koniecznością, w celu zapewnienia jakości i wydajności plantacji. Niezależnie od rodzaju stosowanych środków do ich wykonywania niezbędna jest woda, której oszczędność możliwa jest dzięki optymalizacji i precyzji wykonywanych zabiegów. Dodatkowo, w przypadku stosowania chemicznych środków ochronnych, relatywnemu zmniejszeniu ulega ich ilość wykorzystywana do zabezpieczenia plantacji przed chorobami grzybowymi i szkodnikami. Wykonana modernizacja daje zatem współmierne korzyści dla ochrony środowiska.

#### 4.2.2 Architektura systemu sterowania

Architektura rozwiązań technicznych systemu sterowania ciągnika i opryskiwacza (rys. 4.4) pozwala na jej adaptację do dowolnego modelu ciągnika i opryskiwacza. Instalacja elektryczna ciągnika zazwyczaj zapewnia napięcie zasilania 12 V, co umożliwia zasilanie dodatkowych urządzeń elektronicznych (w tym routera Firmy MikroTik 433UL z modułem Wi-Fi R52Hn, rys. 4.5). W celu podłączenia sterownika PLC firmy Siemens SIMATIC S7-1200 wymagane jest zastosowanie przetwornicy napięcia DC/DC (rys. 4.6), która na wyjściu zapewnia napięcie 24 V. Informacje z przetwarzania danych przez algorytmy wizyjne przetwarzane są na sygnały, które w odpowiednio załączają przekaźniki (rys. 4.7) uruchamiające elementy wykonawcze układu automatyki. Siłowniki liniowe przesuwają dźwignie sprzęgła, hamulca i regulacji obrotów ciągnika. Silniki elektryczne przekazują natomiast moment obrotowy na układ kierowniczy ciągnika i regulacyjny ciśnienia oprysków. Zastosowane elektrozawory wymagają także włączenia w ich obwody sterujące przekaźników wzmacniających prąd cewki. W zależności od liczby sygnałów pochodzących z układu wejściowego i wyjściowego automatyki wymagane jest dołączenie do jednostki CPU (CPU, ang. central processing unit) sterownika PLC odpowiednich modułów wejściowych i wyjściowych. Antena dookólna podłączona do modułu Wi-Fi służy do komunikacji z aplikacją sterującą zapewniając dwukierunkową łączność. Czujnik ciśnienia zapewnia utrzymanie odpowiedniego ciśnienia w układzie hydraulicznym opryskiwacza.



Rys 4.4 Architektura rozwiązań technicznych systemu sterowania (opracowanie własne)



Rys. 4.5 Router Firmy MikroTik 433UL z modulem Wi-Fi R52Hn (opracowanie własne)




Rys. 4.6 Sterownik PLC firmy Siemens SIMATIC S7-1200 z przetwornicą napięcia WOLT DC-120 (opracowanie własne)



Rys. 4.7 Przekładniki elektromagnetyczne sterujące elementami wykonawczymi układu automatyki (opracowanie własne)

Lokalizacja ciągnika wraz z opryskiwaczem może być zrealizowana za pomocą infrastruktury sieci bezprzewodowej, składającej się z czterech przekaźnikowych stacji transmisyjnych, zapewniających komunikację dwukierunkową. Ustawienie stacji w odpowiedni tryb pracy nie wymaga dodawania dodatkowego okablowania szkieletowego między stacjami. Testy przyjętej architektury bezprzewodowej automatyki przeprowadzono na doświadczalnej plantacji sadowniczej o wymiarach 500 m × 30 m, z rzędami drzew owocowych, wzniesieniem terenu na środku i różnicą wzniesień terenu około 5 m [118]. Architektura ta umożliwia transmisję szerokopasmową, przesyłanie obrazu z kamery, sprawną komunikację ze sterownikiem, w czasie rzeczywistym bez istotnych opóźnień w standardzie IEEE 802.11n. Pierwsza stacja jest połączona przewodowo z komputerem z zainstalowaną aplikacją sterującą. Druga i trzecia stanowią przedłużenie sieci bezprzewodowej. Czwarta stacja, umieszczona na ciągniku, komunikuje się dwukierunkowo z pozostałymi stacjami, a w pojeździe została dołączona przewodowo do sterownika i kamer Gemini 612-23W o rozdzielczości 1.4 Mpix.



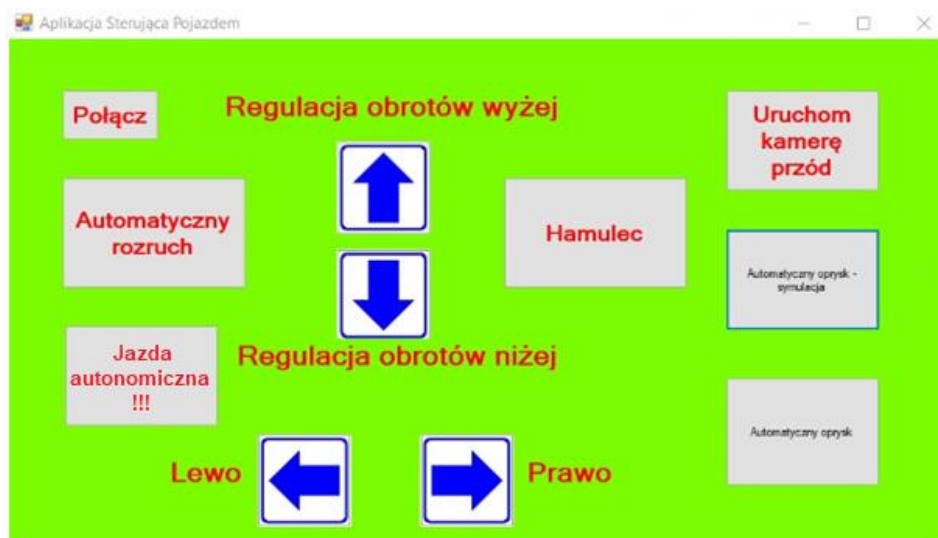
Rys. 4.8 Szkic poglądowy doświadczalnej działki sadowniczej (opracowanie własne)

Algorytm lokalizacyjny wykorzystywać może metodę stosowaną w radiolokalizacji opartą na triangulacji kołowej (rys. 4.8). Lokalizacja pojazdu odbywa się za pomocą analizy sygnałów pochodzących z co najmniej trzech stacji bazowych, komunikujących się z stacją mobilną, umiejscowioną na poruszającym się pojeździe. Funkcja algorytmu lokalizującego w trakcie przejazdów roboczych odczytuje w programowo ustawionych odstępach czasu dane o położeniu pojazdu. Dane te następnie wykorzystywane są do nawigowania pojazdu według zaprogramowanej trajektorii jazdy. Rozwiązanie to jest alternatywą do powszechnie stosowanego systemu pozycjonowania GPS. Utworzenie lokalnej sieci teleinformatycznej zapewnia, poza pozycjonowaniem pojazdu, możliwość komunikacji z nim i zdalnego sterowania z wykorzystaniem systemu wizyjnego pracującego w jednej sieci lokalnej.



### 4.2.3 Aplikacja sterująca

Aplikacja sterująca ciągnikiem i opryskiwaczem przygotowana w programie Visual Studio (rys. 4.9) może być dowolnie modyfikowana w zależności od zastosowanej technologii modułowego sterowania. To co łączy wszystkie możliwe koncepcje to implementacja funkcji bezpieczeństwa, która pozwala na awaryjne, niezwłoczne zatrzymanie w przypadku utraty łączności z pojazdem. Uniwersalne są również funkcje uruchomienia pojazdu i regulacji obrotów silnika oraz manewrowania jego układem kierowniczym. W zależności od typu modernizowanego pojazdu, wymagane mogą być dedykowane funkcje sterowania skrzynią biegów lub specjalistyczne. W przypadku zastosowań sadowniczych funkcja specjalistyczna kontroluje sterownie opryskiwaczem.



Rys. 4.9 Interfejs główny aplikacji sterującej ciągnikiem autonomicznym z opryskiwaczem

(opracowanie własne)

Po zainicjowaniu połączenia z pojazdem wyświetlony zostaje stosowny komunikat informujący o nawiązaniu komunikacji. Wówczas możliwe jest uruchomienie kamery czołowej, umiejscowionej na przodzie ciągnika i podgląd w czasie rzeczywistym obrazu, który rejestruje kamera na monitorze komputera. Ciągnik uruchamiany jest automatycznie i wprowadzany w ruch na zadanym biegu. Istnieje możliwość regulacji jego prędkości jazdy, poprzez regulację w dopuszczalnym zakresie obrotów silnika. Aplikacja umożliwia także, poza zdalną możliwością manewrowania kierunkiem jazdy i zatrzymania ciągnika, włączenie i wyłączenie automatycznego sterowania elektrozaworami hydraulicznymi dysz wylotowych opryskiwacza, wykorzystującego system wizyjny do rozpoznawania stanu rozwojowego i wysokości drzew oraz inspekcji upraw. Funkcja jazdy autonomicznej przekazuje sterowanie ciągnikiem wraz z opryskiwaczem sadowniczym algorytmowi lokalizującemu, co rozpoczyna odtwarzanie zadanej trajektorii jazdy.

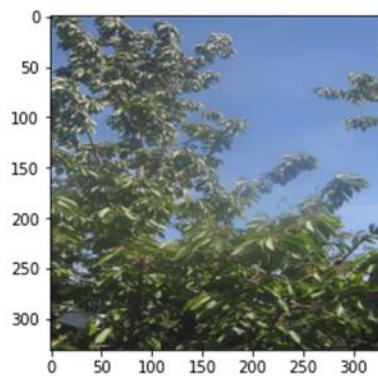
Odpowiednio zmodernizowany ciągnik sadowniczy i opryskiwacz odpowiadają za zabieg w rzeczywistym środowisku, których podzespoły automatyki są częścią autonomicznego systemu sterowania. Ciągnik sprzęgnięty z opryskiwaczem rozpoczyna i kończy pracę na przygotowanym stanowisku zrobotyzowanym, gdzie opryskiwacz jest automatycznie napełniany wodą i podejmowane są odpowiednie środki ochrony roślin z pojemników magazynowych. Stanowisko zapewnia może również możliwość tankowania paliwa. Następnie pojazd porusza się autonomicznie po plantacji.

### 4.3 Szczegółowe wyniki badań i eksperymentów

W podrozdziale przedstawiono wyniki cząstkowych badań eksperymentalnych, tj. zaprezentowano efekty działania poszczególnych bloków systemu wizyjnego. Wyniki działania systemu jako całości zaprezentowano w rozdziale 4.4.

#### 4.3.1 Wyniki przetwarzania obrazów z funkcją augmentacji danych

Wszystkie wartości parametrów funkcji augmentacji zostały dobrane w sposób doświadczalny, obserwując rezultaty obrazów po augmentacji. Przykłady obrazu drzew bez infekcji przed zastosowaniem funkcji augmentacji przedstawiono na rysunku 4.10. Przykłady obrazów drzew bez infekcji po zastosowaniu funkcji augmentacji przedstawiono na rysunku 4.11.



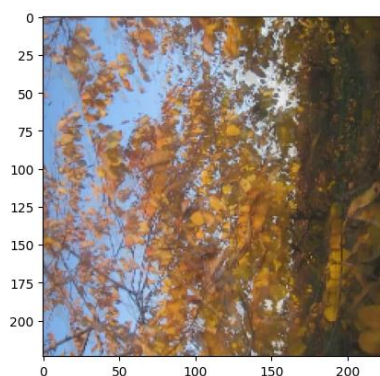
Rys. 4.10 Oryginalny obraz przez dokonaniem przekształceń




Rys. 4.11 Obrazy zmodyfikowane z funkcją augmentacji (opracowanie własne)



Przykłady obrazu drzew z infekcjami przed zastosowaniem funkcji augmentacji przedstawiono na rysunku 4.12. Przykłady obrazów drzew z infekcjami po zastosowaniu funkcji augmentacji przedstawiono na (rys. 4.13).



Rys. 4.12 Oryginalny obraz przez dokonaniem przekształceń




Rys. 4.13 Obrazy zmodyfikowane z funkcją augmentacji (opracowanie własne)


Augmentacja danych jest wykonywana w locie (ang. on the fly). Każdy obraz przed podaniem do sieci neuronowej jest transformowany przez funkcje augmentacji. Oznacza to, że nie jest zapisywany finalnie jak dodatkowy obraz w zbiorze danych treningowych.

### 4.3.2 Wyniki detekcji szkodników sadowniczych

Algorytm rozpoznawania szkodników na pułapkach fermionowych przetestowany został na reprezentatywnej plantacji czereśni, gdzie wywieszone zostały pułapki feromonowe na głównego szkodnika czereśni nasionnicę trześniówkę (por rozdział 2.4.2) powodującego pojawianie się robaków w dojrzałych owocach. Na przygotowanym stanowisku badawczym zainstalowane zostały kamery rejestrujące obrazy żółtej pułapki na szkodniki. Algorytm detekcji początkowo rozpoznawał tylko i wyłącznie pojawiające się owady (rys. 4.14a,b), które rozmiarem znacznie różniły się od nasionnicy trześniówki i wysyłał cyklicznie zdjęcia bez sygnalizacji uruchamiającej generowanie przez system wspomagający wykonywanie oprysków komunikat dla sadownika. W kolejnych dniach, gdy na pułapce zaczął być odławiany właściwy szkodnik (rys. 4.15a,b) algorytm wizyjny po wykryciu dwóch osobników szkodnika wygenerował komunikat sygnalizujący konieczność wykonania oprysku.



Rys. 4.14 a) pułapka bez nasionnicy trześniówki, b) obraz pułapki przetworzony przez algorytm wizyjny (opracowanie własne)




Rys. 4.15 a) pułapka z nasionnicą trześniówką, b) obraz pułapki przetworzony przez algorytm wizyjny (opracowanie własne)


W testowym sezonie sadowniczym, opracowany algorytm wizyjny będący jednym z elementów modułowego systemu wizyjnego włączonego do systemu sztucznej inteligencji wspomagającego wykonywanie oprysków sadowniczych wykrył cztery pokolenia szkodników pojawiających się na plantacji w okresie dwóch miesięcy. Każda z sygnalizacji została zweryfikowana przez doświadczonego eksperta i potwierdziła każdorazową skuteczność detekcji. Wykonane w następstwie sygnalizacji zabiegi ochronne przyjętymi strategiami zapobiegły przedostaniu się larw szkodnika do owoców.

### 4.3.3 Wyniki detekcji wysokości drzew

Algorytm rozpoznawania wysokości drzew został przetestowany na przygotowanym stanowisku badawczym w warunkach oprysku sadu (środowisko rzeczywiste). Wyniki wykrywania gałęzi z liśćmi w odpowiednich strefach skutkują aktywacją odpowiedniej liczby elektrozaworów rozdzielających dysze prototypowej przystawki opryskiwacza. Przystawka posiada cztery dysze. Pierwsza z nich zostaje aktywowana jeśli zarys drzewa zostaje wykryty w zerowej programowo wydzielonej strefie obrazu (Rys 4.16a,b). Dysza ta zostaje dezaktywowana w czasie wykonywania oprysku tylko wtedy, gdy w rzędzie sadowniczym brakuje drzewa. Wówczas ciecz przekierowywana jest z powrotem do zbiornika. Poprawna detekcja zostaje uwidoczniana przez swobodny wylot cieczy z opryskiem poprzez pierwszą dyszę. Analogicznie aktywowane zostają pozostałe dysze wylotowe po wykryciu zarysu drzewa w kolejnych zaprogramowanych strefach, tj, 1, 2 i 3 obrazu (rys. 4.17 – rys. 4.19).



Rys. 4.16 a) wykrycie zarysu drzewa w strefie 0, b) przystawka z aktywną dyszą nr. 1 (opracowanie własne)




Rys. 4.17 a) wykrycie zarysu w strefie 1, b) przystawka z aktywną dyszą nr. 1 i 2 (opracowanie własne)






Rys. 4.18 a) wykrycie zarysu w strefie 2, b) przystawka z aktywną dyszą nr. 1,2 i 3 (opracowanie własne)



Rys. 4.19 a) wykrycie zarysu w strefie 3, b) przystawka z aktywnymi wszystkimi dyszami (opracowanie własne)

Kontrola skuteczności systemu sterowania opryskiwaczem z zainstalowanym modułem wizyjnymi, algorytmem detekcji wysokości drzew zrealizowana została poprzez rozmieszczenie na odpowiednich wysokościach drzew 50 sztuk papieru hydro-wrażliwego (tj. wrażliwego na wodę). Papier tego typu zmienia kolor z żółtego na niebieski pod wpływem wody. Kontrola po wykonaniu oprysku wykazała, że wszystkie rozmieszczone sztuki papieru zmieniły kolor na niebieski, co oznacza właściwe pokrycie drzew opryskiem (rys. 4.20a,b).



Rys. 4.20 Papier hydro-wrażliwy: a) niepokryty wodą, b) pokryty wodą (opracowanie własne)


#### 4.3.4 Wyniki rozpoznawania stanów rozwojowych drzew

Wyniki eksperymentów klasyfikacji stanów rozwoju drzewa według K-krotnej walidacji krzyżowej przedstawiono w tabeli 4.1 (dla modelu Xception) i tabeli 4.2 (dla modelu NasNetLarge). Wykresy dokładności treningu obu modeli dla zbioru uczącego i walidacyjnego przedstawiono na rysunku 4.21 i rysunku 4.23. Suma błędów przedstawiają wykresy (rys. 4.22) i (rys. 4.24).


- Model Xception

Tabela 4.1 Wynik rozpoznania dla modelu Xception

K-fold	Accuracy [%]		
	Train	Validation	Tests
1	97.95	99.87	99.16
2	97.98	99.14	97.44
3	96.55	99.42	97.24
4	97.43	97.89	98.57
5	97.21	98.14	98.17
<b>Average</b>	<b>97.42</b>	<b>98.89</b>	<b>98.12</b>



Rys. 4.21 Wykres dokładności rozpoznawania dla zbioru uczącego i walidacyjnego (opracowanie własne)




Rys. 4.22 Suma błędów dla zbioru uczącego i walidacyjnego (opracowanie własne)

- Model NasNetLarge

Tabela 4.2 Wynik rozpoznania dla modelu NasNetLarge

K-fold	Accuracy [%]		
	Train	Validation	Tests
1	98.40	100	99.12
2	97.86	98.45	97.23
3	98.23	99.13	96.88
4	98.07	97.45	97.13
5	97.67	98.51	98.21
Average	98.05	98.71	97.21



Rys 4.23 Wykres dokładności rozpoznawania dla zbioru uczącego i walidacyjnego (opracowanie własne)



Rys. 4.24 Suma błędów dla zbioru uczącego i walidacyjnego (opracowanie własne)




### 4.3.5 Wyniki rozpoznawania infekcji drzew sadowniczych

Wyniki eksperymentów klasyfikacji drzew bez infekcji i zainfekowanych według K-krotnej walidacji krzyżowej przedstawiono w tabeli 4.3 (dla modelu Xception) i w tabeli 4.4 (dla modelu NasNetLarge). Wykresy dokładności treningu obu modeli dla zbioru uczącego i walidacyjnego przedstawiono na rysunku 4.25 i rysunku 4.27. Suma błędów przedstawiają wykresy (rys. 4.26) i (rys. 4.28).


- Model Xception

Tabela 4.3 Wynik rozpoznania dla modelu Xception

K-fold	Accuracy [%]		
	Train	Validation	Tests
1	97.06	100	100
2	100	100	97.06
3	100	100	97.06
4	97.06	100	97.06
5	97.06	100	97.06
<b>Average</b>	98.24	100	97.65



Rys. 4.25 Wykres dokładności rozpoznawania dla zbioru uczącego i walidacyjnego (opracowanie własne)




Rys. 4.26 Suma błędów dla zbioru uczącego i walidacyjnego (opracowanie własne)


- Model NasNetLarge

Tabela 4.4 Wynik rozpoznania dla modelu NasNetLarge

K-fold	Accuracy [%]		
	Train	Validation	Tests
1	100	100	100
2	97.06	100	97.06
3	100	100	100
4	97.06	100	97.06
5	97.06	100	100
Average	98.24	100.00	98.82



Rys 4.27 Wykres dokładności rozpoznawania dla zbioru uczącego i walidacyjnego (opracowanie własne)



Rys. 4.28 Suma błędów dla zbioru uczącego i walidacyjnego (opracowanie własne)

## 4.4 Końcowe wyniki badań i eksperymentów

W rozdziale tym zaprezentowano wyniki badań eksperymentalnych zaprojektowanego systemu jako całości.

### 4.4.1 Oszczędności wody i środków chemicznych

W podrozdziale przedstawiono wyniki analizy porównawczej ilości wypryskiwanej cieczy opryskiwaczem tradycyjnym oraz zmodernizowanym którym steruje system sztucznej inteligencji. Badania eksperymentalne przeprowadzono dla reprezentatywnej powierzchni 1 ha sadu.

Uzyskane wyniki rozpoznawania stanu rozwojowego drzew, przez opracowany wizyjny algorytm klasyfikacji, na poziomie dokładności ponad 97 [%] przedstawione w podrozdziale 4.3.4, zapewniają wysoką wiarygodność uzyskania prawidłowej kalibracji parametrów oprysku. Tabela 4.5 przedstawia szacowane zużycie wody na 1 ha z zastosowaniem i bez zastosowania algorytmu klasyfikacji stanu rozwojowego drzew.

Tabela 4.5 Wyniki zużycia wody do oprysku z algorytmem klasyfikacji stanu rozwojowego drzew

<b>Faza rozwojowa</b>	<b>Wykorzystana ilość wody (w litrach) z wizyjnym algorytmem klasyfikacji</b>	<b>Wykorzystana ilość wody (w litrach) bez wizyjnego algorytmu klasyfikacji</b>
<b>BBCH 10</b>	460	500
<b>BBCH 30</b>	500	550
<b>BBCH 60</b>	600	660
<b>BBCH 70</b>	700	780
<b>BBCH 80</b>	800	850
<b>Łącznie</b>	3060	3340

Wyniki pomiarów zużycia wody z zastosowaniem algorytmu wizyjnego przedstawionego w podrozdziale 4.3.3, wykrywającego wysokość drzew do oprysku w kolejnych fazach rozwojowych drzew przedstawia tabela 4.6.

Tabela 4.6 Wyniki zużycia wody do oprysku z algorytmem wykrywania wysokości drzew

<b>Faza rozwojowa</b>	<b>Wykorzystana ilość wody (w litrach) z wizyjnym algorytmem wykrywania wysokości</b>	<b>Wykorzystana ilość wody (w litrach) bez wizyjnego algorytmu wykrywania wysokości</b>
<b>BBCH 10</b>	430	500
<b>BBCH 30</b>	450	550
<b>BBCH 60</b>	550	660
<b>BBCH 70</b>	590	780
<b>BBCH 80</b>	680	850
<b>Łącznie</b>	<b>2700</b>	<b>3340</b>

Tabela 4.7 przedstawia podsumowanie łączne oszczędności wody wykorzystywanej do oprysku wynikające z zastosowania opracowanych algorytmów wizyjnych sterujących opryskiwaczem.

Tabela 4.7 Oszczędności wody wynikające z opracowanych algorytmów

	<b>BBCH 10</b>	<b>BBCH 30</b>	<b>BBCH 60</b>	<b>BBCH 70</b>	<b>BBCH 80</b>
<b>Algorytm wizyjny 1 - klasyfikacji stanów rozwojowych drzew</b>					
<b>Oszczędność wody w litrach</b>	40	50	60	80	50
<b>Liczba oprysków</b>	2	3	3	4	5
<b>Łącznie</b>	<b>80</b>	<b>150</b>	<b>180</b>	<b>320</b>	<b>250</b>
<b>Algorytm wizyjny 2 - wykrywania wysokości drzew</b>					
<b>Oszczędność wody w litrach</b>	70	100	110	190	170
<b>Liczba oprysków</b>	2	3	3	4	5
<b>Łącznie</b>	<b>140</b>	<b>300</b>	<b>330</b>	<b>760</b>	<b>850</b>
<b>Algorytm wizyjny 1 + Algorytm wizyjny 2</b>					
<b>Łącznie</b>	<b>220</b>	<b>450</b>	<b>170</b>	<b>1080</b>	<b>1100</b>
<b>Suma</b>	<b>3360</b>				
<b>Oprysk tradycyjny bez zastosowania algorytmów wizyjnych</b>					
<b>Łącznie</b>	500	550	660	780	850
<b>Liczba zabiegów</b>	2	3	3	4	5
<b>Łącznie</b>	<b>1000</b>	<b>1650</b>	<b>1980</b>	<b>3120</b>	<b>4250</b>
<b>Suma</b>	<b>12 000</b>				

Tabela 4.8 przedstawia podsumowanie oszczędności środków ochrony roślin i wody wykorzystywanej do oprysku w przeliczeniu na 1 hektar powierzchni sadu czereśniowego.

Tabela 4.8 Oszczędności środków chemicznych i wody wynikające z opracowanych algorytmów

Faza rozwojowa	Liczba oprysków	Nazwa środka	Zalecana Ilość środka na 1 ha	Zalecana ilość wody na 1 ha	Oszczędność środka na 1 ha	Oszczędność wody na 1 ha
BBCH 10	2	Miedzian Extra 350 SC	3 [l]	600 [l]	0.55 [l]	110 [l]
		Miedzian 50 WP	3 [kg]	600 [l]	0.55 [kg]	110 [l]
BBCH 30	3	Decis Mega 50 EW	0.25 [l]	600 [l]	0.06 [l]	150 [l]
		Zato 50 WG	0.15 [kg]	600 [l]	0.04 [kg]	150 [l]
		BioBit	1 [kg]	600 [l]	0.25 [kg]	150 [l]
BBCH 60	1	Serenade ASO	8 [l]	600 [l]	2.27 [l]	170 [l]
BBCH 70	4	Signum 33 WG	0.75 [kg]	600 [l]	0.34 [kg]	270 [l]
		Matrix 2,5 EC	0.3 [l]	600 [l]	0.135 [l]	270 [l]
		Luna Experience 400	0.6 [l]	600 [l]	0.27 [l]	270 [l]
		Naturalis	2 [l]	600 [l]	0.9 [l]	270 [l]
BBCH 80	5	Movento 100 SC	2.25 [l]	600 [l]	0.83 [l]	220 [l]
		Exirel 100 SE	0.6 [l]	600 [l]	0.22 [l]	220 [l]
		Movento 100 SC	2.25 [l]	600 [l]	0.83 [l]	220 [l]
		Switch 62,5 WG	1 [kg]	600 [l]	0.37 [l]	220 [l]
		Mospilan 20 SP	0.125 [kg]	600 [l]	0.05 [kg]	220 [l]

#### 4.4.2 Zmniejszenie emisji środowiska i ochrona operatora

Jak wynika z powyższych wyników przedstawionych w tabelach 4.5 – 4.8, nastąpiło znaczące zredukowanie ilości wody potrzebnej do oprysków. Oznacza to istotne zmniejszenie oddziaływania środków stosowanych do oprysku na środowisko. Efekt ten był możliwy do uzyskania poprzez opracowaną propozycję precyzyjnych oprysków wykorzystującą algorytmy wizyjne. Jednocześnie zapewniona została ochrona operatora, poprzez to że system działa w znacznym stopniu autonomicznie i nie wymaga operatora prowadzącego ciągnik z opryskiwaczem.



## 5. Wnioski końcowe i podsumowanie przeprowadzonych badań

Rezultat przeprowadzonych badań naukowych wskazuje, że opracowany system sztucznej inteligencji wspomagający wykonywanie oprysków sadowniczych pozwala na wykonywanie precyzyjnych oprysków. Przeprowadzone zostały eksperymenty na przygotowanym stanowisku badawczym, którym był zmodernizowany ciągniki i opryskiwacz sadowniczy w warunkach plantacji sadowniczej. Wyniki eksperymentów wskazują, że zastosowanie algorytmów wizyjnych do sterowania zautomatyzowanym ciągnikiem i opryskiwaczem przynosi oszczędności wynikające ze stosownej do oprysków wody i środków ochrony roślin na poziomie niemal 30 %.

Na ograniczeniu kosztów produkcji sadowniczej pozwala opracowany i przetestowany algorytm wizyjny do detekcji szkodników na pułapkach feromonowych w warunkach plantacji sadowniczej. Rozmieszczone na plantacji kamery wizyjne dostarczają regularnych informacji o pojawiających się szkodnikach na wczesnym etapie ich rozwoju. Informacje te poza generowaną sygnalizacją eliminują konieczność codziennej lustracji pułapek feromonowych rozmieszczonych w sadzie. Przy plantacjach rozproszonych pozwalają zaoszczędzić czas sadownika i paliwo zużywane na codzienne dojazdy.

Opracowany automatyczny algorytm rozpoznawania stanu rozwojowego drzew jest konieczny, żeby oprysk wykonywany przez autonomiczny ciągnik z opryskiwaczem mógł mieć w czasie rzeczywistym kalibrowane parametry. Funkcja automatycznego rozpoznawania infekcji drzew wraz z określeniem współrzędnych lokalizacji wykrytej infekcji, dostarcza informacji które pozwala na eliminację zainfekowanego drzewa oraz zaoszczędza czas potrzeby na inspekcyjną lustrację plantacji. Dla obu zadań tj.: klasyfikacji stanów rozwojowych drzew i klasyfikacji drzew bez infekcji i zainfekowanych osiągnięto wysokie wartości dokładności klasyfikacji (ponad 97 % na testowych zbiorach danych). Niezależnie od zastosowanego modelu sieci, otrzymane wyniki były podobne. Potwierdza to również metoda K-krotnej walidacji krzyżowej (tabele 4.1 – 4.4).

Zauważyć można większe wahania dokładności podczas procesu uczenia (rys. 4.25) dla zbioru walidacyjnego (w stosunku do wyników uzyskanych dla zbioru uczącego). Wynik jest powiązany z mniejszym rozmiarem zbioru walidacyjnego. Podczas procesu testowania nie wykryto znaczącego nadmiernego dopasowania modelu. Ponadto zastosowano silne metody augmentacji danych.

W przypadku klasyfikacji drzew zdrowych i zainfekowanych uzyskane wyniki są jeszcze wyższe i mają średnią dokładność 98.82 % na zbiorze danych testowych (dla modelu NasNetLarge) dzięki temu, że obrazy w klasach drzew bez infekcji i zainfekowanych są bardziej wizualnie różne. W przyszłości baza ta może być powiększana, co jest zadaniem wieloletnim i trudnym ze względu na okresowość obserwowanych chorób.

Proponowane algorytmy wizyjne realizują w systemie funkcje, których uzasadnienie wynika z zebranego doświadczenia praktycznego przy realizacji oprysków sadowniczych oraz zasad sygnalizacji zagrożenia występowania infekcji upraw. Wyodrębniono rodzaje infekcji określane jako: choroby grzybowe oraz szkodniki. Do zwalczania danych infekcji przygotowane zostały strategie ochronne z przypisaniem dedykowanych środków ochrony roślin dopuszczonych do produkcji sadowniczej odpowiednimi zezwoleniami. Poprzez modernizację opryskiwaczy w system wizyjny i zastosowanie systemu wspomagającego wykonywanie oprysków sadowniczych można ograniczyć stosowanie między innymi pestycydów i zmniejszyć ich ilość przedostającą się do środowiska. Ponieważ dokładne testowanie systemu wymaga kilku rocznych cykli, obecnie proponowany system jest w fazie rozwoju, będzie wymagał rozbudowy i kolejnych faz testów.

W rozprawie doktorskiej przedstawione zostały założenia systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych. Głównymi elementami systemu są kamery, których sygnał wideo jest przetwarzany przez opracowane algorytmy wizyjne. Przygotowane rozwiązania mogą być szeroko stosowane w nowych i używanych ciągnikach oraz opryskiwaczach sadowniczych po ich wcześniejszej modernizacji. Podczas opryskiwania moduł wizyjny, który steruje opryskiwaczem sadowniczym, oprócz określenia wysokości opryskiwanego drzewa, rozpoznaje również stan rozwojowy drzew i dokonuje inspekcji plantacji poprzez klasyfikację porażonych drzew

Analizując przykładowe zezwolenie Ministra Rolnictwa i Rozwoju Wsi (nr R – 3/2017/d) dotyczące zezwolenia na dopuszczenie do produkcji owoców środka ochronnego o nazwie MIEDZIAN EXTRA 350 SC i zezwolenia dla innych środków można wywnioskować, że podawane zalecenia odnoszą się z reguły do powierzchni 1 hektara sadu i dotyczą zarówno zalecanej dawki środka oraz zalecanej ilości wody.

W sezonie sadowniczym 2024 roku na reprezentatywnej plantacji 1 hektara sadu wykonano łącznie 15 oprysków ochronnych różnymi dopuszczonymi do produkcji środkami ochrony roślin. W ciągu sezonu sadowniczego oszczędności wody dla reprezentatywnej powierzchni sadu 1 hektara czereśni wyniosły 28 % (tabele 4.5 – 4.8) Analogicznie oszczędności uzyskano w łącznej ilości zastosowanych środków ochrony roślin. Analizując wyniki przedstawione w tabeli 4.8 zauważyć należy, że zaproponowane algorytmy wizyjne sterujące opryskiwaczem zapewniają największą redukcję stosowanych środków chemicznych i wody do oprysku w fazach BBCH 70 i BBCH 80. W fazach tych drzewa rozwijają się najbardziej intensywnie co uwidocznione zostaje przyrostem młodych pędów drzewa i zawiązek owoców, które są najbardziej narażone na infekcje. Na okres ten przypada również największa liczba zabiegów wykonywanych głównie środkami chemicznymi. W pozostałych fazach również odnotowane zostały oszczędności, których niższy poziom wynika z mniej intensywnego rozwoju drzew.

Przedstawiona architektura systemu sztucznej inteligencji i przeprowadzone badania eksperymentalne wpisuje się w obszar ogrodnictwa precyzyjnego, który optymalizuje obszar produkcji owoców poprzez minimalizowanie kosztów i podnoszenie wydajności produkcji. Wykorzystane modele do przeprowadzenia eksperymentów, których wyniki zostały przedstawione są częścią przygotowanego systemu sztucznej inteligencji wspomagającego wykonywanie autonomicznych oprysków sadowniczych.

Podsumowując, cel badawczy rozprawy doktorskiej, którym było zastosowanie metod sztucznej inteligencji do wspomagania podejmowania decyzji o zabiegach sadowniczych, minimalizujących liczbę oprysków i ilość wykorzystywanych w tym celu środków ochrony roślin, a także do eliminacji bezpośredniego udziału operatora, czyli do zapewnienia pełnej ochrony człowieka od ekspozycji na stosowane środki chemiczne został zrealizowany.

Ostatecznie, przyjęta teza naukowa zakładająca, że dzięki zastosowaniu zaproponowanego inteligentnego systemu wizyjnego do rozpoznawania chorób i szkodników drzew owocowych oraz detekcji drzew, a także opracowanego zrobotyzowanego bezzałogowego sprzętu do oprysków sadowniczych, zapewnia się poprawę precyzji oprysków, ograniczenie ilości stosowanych środków chemicznych i wody, poprawę jakości owoców a ponadto ochronę sadownika przed ekspozycją na szkodliwe środki chemiczne została dowiedziona.

## Bibliografia

- [1] M. H. Saleem, J. Potgieter, i K. M. Arif, „Correction to: Automation in Agriculture by Machine and Deep Learning Techniques: A Review of Recent Developments”, *Precis. Agric.*, t. 22, nr 6, s. 2092–2094, grudz. 2021, doi: 10.1007/s11119-021-09824-9.
- [2] Skrzypczyński, P., Ćwian, K. (2023). Lokalizacja robotów rolniczych: wyzwania, rozwiązania i nowe podejście. W: Szewczyk, R., Zieliński, C., Kaliczyńska, M., Bućinskas, V. (red.) *Automatyzacja 2023: kluczowe wyzwania w automatyce, robotyce i technikach pomiarowych. AUTOMATYZACJA 2023. Lecture Notes in Networks and Systems*, tom 630. Springer., [https://doi.org/10.1007/978-3-031-25844-2\\_11](https://doi.org/10.1007/978-3-031-25844-2_11)
- [3] Guerrero-Ibañez, A.; Reyes-Muñoz, A. Monitoring Tomato Leaf Disease through Convolutional Neural Networks. *Electronics* 2023, 12, 229. <https://doi.org/10.3390/electronics12010229>.
- [4] Szymczyk S., Legutko S., Zawada M., Nijak M., Wojciechowski J. „Zwalczanie chwastów z wykorzystaniem systemów wizyjnych i sztucznej inteligencji jako nowy kierunek rozwoju opryskiwaczy rolniczych”, *PROGRESS IN PLANT PROTECTION* 63 (4): 205–212, 2023 eISSN 2084-4883, DOI: 10.14199/ppp-2023-021
- [5] Vinay Vijayakumar, Yiannis Ampatzidis, Lucas Costa, Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning, *Smart Agricultural Technology*, Volume 3, 2023, 100077, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2022.100077>.
- [6] Bykov, S. World trends in the creation of robots for spraying crops. *E3S Web Conf.* 2023, 380, 01011 . <https://doi.org/10.1051/e3sconf/202338001011>.
- [7] Jiang, A.; Ahamed, T. Navigation of an Autonomous Spraying Robot for Orchard Operations Using LiDAR for Tree Trunk Detection. *Sensors* 2023, 23, 4808. <https://doi.org/10.3390/s23104808>.
- [8] T. Mizik, „How can precision farming work on a small scale? A systematic literature review”, *Precis. Agric.*, t. 24, nr 1, s. 384–406, luty 2023, doi: 10.1007/s11119-022-09934-y.
- [9] „Artificial Intelligence In Agriculture Market Report, 2019-2025”. <https://www.grandviewresearch.com/industry-analysis/artificial-intelligence-in-agriculture-market> (dostęp 24 sierpień 2023)
- [10] R. Sharma, „Artificial Intelligence in Agriculture: A Review”, *5th Int. Conf. Intell. Comput. Control Syst. ICICCS*, 2021, s. 937–942, maj 2021, doi: 10.1109/ICICCS51141.2021.9432187.
- [11] M. N. Blanco, R. A. Fenske, E. J. Kasner, M. G. Yost, E. Seto, i E. Austin, „Real-Time Monitoring of Spray Drift from Three Different Orchard Sprayers”, *Chemosphere*, t. 222, s. 46–55, maj 2019, doi: 10.1016/j.chemosphere.2019.01.092.
- [12] H. A. M. Williams *i in.*, „Robotic kiwifruit harvesting using machine vision, convolutional neural networks, and robotic arms”, *Biosyst. Eng.*, t. 181, s. 140–156, maj 2019, doi: 10.1016/j.biosystemseng.2019.03.007.
- [13] J. P. Underwood, C. Hung, B. Whelan, i S. Sukkarieh, „Mapping almond orchard canopy volume, flowers, fruit and yield using lidar and vision sensors”, *Comput. Electron. Agric.*, t. 130, s. 83–96, lis. 2016, doi: 10.1016/j.compag.2016.09.014.

- [14] M. A. Ebrahimi, M. H. Khoshtaghaza, S. Minaei, i B. Jamshidi, „Vision-based pest detection based on SVM classification method”, *Comput. Electron. Agric.*, t. 137, s. 52–58, maj 2017, doi: 10.1016/j.compag.2017.03.016.
- [15] E. Böckmann, A. Pfaff, M. Schirrmann, i M. Pflanz, „Rapid and low-cost insect detection for analysing species trapped on yellow sticky traps”, *Sci. Rep.*, t. 11, nr 1, Art. nr 1, maj 2021, doi: 10.1038/s41598-021-89930-w.
- [16] M. Sharif, M. A. Khan, Z. Iqbal, M. F. Azam, M. I. U. Lali, i M. Y. Javed, „Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection”, *Comput. Electron. Agric.*, t. 150, s. 220–234, lip. 2018, doi: 10.1016/j.compag.2018.04.023.
- [17] X. E. Pantazi, D. Moshou, i A. A. Tamouridou, „Automated leaf disease detection in different crop species through image features analysis and One Class Classifiers”, *Comput. Electron. Agric.*, t. 156, s. 96–104, sty. 2019, doi: 10.1016/j.compag.2018.11.005.
- [18] A. T. Meshram, A. V. Vanalkar, K. B. Kalambe, i A. M. Badar, „Pesticide spraying robot for precision agriculture: A categorical literature review and future trends”, *J. Field Robot.*, t. 39, nr 2, s. 153–171, 2022, doi: 10.1002/rob.22043.
- [19] R. Cmielewski, „Autonomiczny robot polowy do siewu i pielęgnacji upraw szerokokorzędowych nagrodzony na XII Międzynarodowej Warszawskiej Wystawie Wynalazków IWIS 2018”, *Tech. Rol. Ograd. Śna*, nr 5, 2018, <http://agro.icm.edu.pl/agro/element/bwmeta1.element.agro-e6c5c3fd-1172-4bf3-8bb0-9e41fb61806e>, (dostęp 24 sierpień 2023)
- [20] T. Botterill *i in.*, „A Robot System for Pruning Grape Vines”, *J. Field Robot.*, t. 34, nr 6, s. 1100–1122, 2017, doi: 10.1002/rob.21680.
- [21] T. Fujinaga, S. Yasukawa, i K. Ishii, „Development and Evaluation of a Tomato Fruit Suction Cutting Device”, w *2021 IEEE/SICE International Symposium on System Integration (SII)*, sty. 2021, s. 628–633. doi: 10.1109/IEEECONF49454.2021.9382670.
- [22] I. Abbas *i in.*, „Different sensor based intelligent spraying systems in Agriculture”, *Sens. Actuators Phys.*, t. 316, s. 112265, grudz. 2020, doi: 10.1016/j.sna.2020.112265.
- [23] M. Graf Plessen, „Coupling of crop assignment and vehicle routing for harvest planning in agriculture”, *Artif. Intell. Agric.*, t. 2, s. 99–109, cze. 2019, doi: 10.1016/j.aiaa.2019.07.001.
- [24] G. Farjon, O. Krikeb, A. B. Hillel, i V. Alchanatis, „Detection and counting of flowers on apple trees for better chemical thinning decisions”, *Precis. Agric.*, t. 21, nr 3, s. 503–521, cze. 2020, doi: 10.1007/s11119-019-09679-1.
- [25] S. Ren, K. He, R. Girshick, i J. Sun, „Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 39, nr 6, s. 1137–1149, cze. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [26] K. Simonyan i A. Zisserman, „Very Deep Convolutional Networks for Large-Scale Image Recognition”. arXiv, 10 kwiecień 2015. doi: 10.48550/arXiv.1409.1556.

- [27] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, i L. Fei-Fei, „ImageNet: A large-scale hierarchical image database”, w *2009 IEEE Conference on Computer Vision and Pattern Recognition*, cze. 2009, s. 248–255. doi: 10.1109/CVPR.2009.5206848.
- [28] G. Lin, Y. Tang, X. Zou, J. Xiong, i Y. Fang, „Color-, depth-, and shape-based 3D fruit detection”, *Precis. Agric.*, t. 21, nr 1, s. 1–17, luty 2020, doi: 10.1007/s11119-019-09654-w.
- [29] G. Lin, Y. Tang, X. Zou, J. Cheng, i J. Xiong, „Fruit detection in natural environment using partial shape matching and probabilistic Hough transform”, *Precis. Agric.*, t. 21, nr 1, s. 160–177, luty 2020, doi: 10.1007/s11119-019-09662-w.
- [30] P. Roy, A. Kislai, P. A. Plonski, J. Luby, i V. Isler, „Vision-based preharvest yield mapping for apple orchards”, *Comput. Electron. Agric.*, t. 164, s. 104897, wrz. 2019, doi: 10.1016/j.compag.2019.104897.
- [31] M. Jiang, L. Song, Y. Wang, Z. Li, i H. Song, „Fusion of the YOLOv4 network model and visual attention mechanism to detect low-quality young apples in a complex environment”, *Precis. Agric.*, t. 23, nr 2, s. 559–577, kwi. 2022, doi: 10.1007/s11119-021-09849-0.
- [32] Figiel S. DEVELOPMENT OF ARTIFICIAL INTELLIGENCE AND POTENTIAL IMPACT OF ITS APPLICATIONS IN AGRICULTURE ON LABOR USE AND PRODUCTIVITY. *Problems of Agricultural Economics*. 2022;373(4):5-21. doi:10.30858/zer/153583.
- [33] Mahomet, M.; Hamdoun, H.; Sagheer, A. W kierunku zrównoważonego rolnictwa: Wdrożenie sztucznej inteligencji do przewidywania optymalnego zapotrzebowania na wodę i energię dla mikrosystemów nawadniających opartych na czujnikach zasilanych energią słoneczną fotowoltaiczną. *Agronomia* 2023, 13, 1081. <https://doi.org/10.3390/agronomy13041081>
- [34] Sampurno, R.M.; Liu, Z.; Abeyrathna, R.M.R.D.; Ahamed, T. Wykrywanie nieskoszonych chwastów w rzędzie za pomocą segmentacji instancji typu "tylko jeden raz" dla plantacji sadowniczych. *Czujniki* 2024, 24, 893. <https://doi.org/10.3390/s24030893>
- [35] G. Beier, A. Ullrich, S. Niehoff, M. Reißig, i M. Habich, „Industry 4.0: How it is defined from a sociotechnical perspective and how much sustainability it includes – A literature review”, *J. Clean. Prod.*, t. 259, s. 120856, cze. 2020, doi: 10.1016/j.jclepro.2020.120856.
- [36] R. Brozzi, D. Forti, E. Rauch, i D. T. Matt, „The Advantages of Industry 4.0 Applications for Sustainability: Results from a Sample of Manufacturing Companies”, *Sustainability*, t. 12, nr 9, Art. nr 9, sty. 2020, doi: 10.3390/su12093647.
- [37] „Umsetzungsempfehlungen für das Zukunftsprojekt Industrie 4.0. Abschlussbericht des Arbeitskreises Industrie 4.0”, *acatech*. <https://www.acatech.de/publikation/umsetzungsempfehlungen-fuer-das-zukunftsprojekt-industrie-4-0-abschlussbericht-des-arbeitskreises-industrie-4-0/> (dostęp 24 sierpień 2023).
- [38] H. Lasi, P. Fettke, H.-G. Kemper, T. Feld, i M. Hoffmann, „Industry 4.0”, *Bus. Inf. Syst. Eng.*, t. 6, nr 4, s. 239–242, sie. 2014, doi: 10.1007/s12599-014-0334-4.
- [39] D. G. Harkut, K. Kasat, i S. Shah, *Cloud Computing: Technology and Practices*. BoD – Books on Demand, 2019.

- [40] S. Ludwig-Ohm, P. Hildner, M. Isaak, W. Dirksmeyer, i J. Schattenberg, „The contribution of Horticulture 4.0 innovations to more sustainable horticulture”, *Procedia Comput. Sci.*, t. 217, s. 465–477, sty. 2023, doi: 10.1016/j.procs.2022.12.242.
- [41] F. L. Willrodt, „Steering attachment for tractors”, US1506706A, <https://patents.google.com/patent/US1506706A/en> (dostęp 24 sierpień 2023)
- [42] A. Lüdeke, *Panzer der Wehrmacht: 1933-1945*. Stuttgart, 2015.
- [43] V. Rondelli, B. Franceschetti, i D. Mengoli, „A Review of Current and Historical Research Contributions to the Development of Ground Autonomous Vehicles for Agriculture”, *Sustainability*, t. 14, nr 15, Art. nr 15, sty. 2022, doi: 10.3390/su14159221.
- [44] „THE FLORIDA ROBOTIC GROVE-LAB”. <https://doi.org/10.13031/2013.31342> (dostęp 24 sierpień 2023).
- [45] A. Niewola, „Mobile Robot 6-D Localization Using 3-D Gaussian Mixture Maps in GPS-Denied Environments”, *IEEE Intell. Syst.*, t. 37, nr 1, s. 79–88, sty. 2022, doi: 10.1109/MIS.2020.3046138.
- [46] J. Kim, J. Seol, S. Lee, S. -W. Hong and H. I. Son, "An Intelligent Spraying System with Deep Learning-based Semantic Segmentation of Fruit Trees in Orchards," 2020 IEEE International Conference on Robotics and Automation (ICRA), Paris, France, 2020, pp. 3923-3929, doi: 10.1109/ICRA40945.2020.9197556.
- [48] L. Cantelli, F. Bonaccorso, D. Longo, C. D. Melita, G. Schillaci, i G. Muscato, „A Small Versatile Electrical Robot for Autonomous Spraying in Agriculture”, *AgriEngineering*, t. 1, nr 3, Art. nr 3, wrz. 2019, doi: 10.3390/agriengineering1030029.
- [48] S. Wang *i in.*, „Design and development of orchard autonomous navigation spray system”, *Front. Plant Sci.*, t. 13, 2022, <https://www.frontiersin.org/articles/10.3389/fpls.2022.960686> (dostęp 24 sierpień 2023)
- [49] „Auto DRIVE – system jazdy autonomicznej”, *GOtrack*. <https://gotrack.pl/auto-drive/> (dostęp 24 sierpień 2023).
- [50] Aćimović, S.; Wallis, A.; Basedow, M. Two Years of Experience with RIMpro Apple Scab Prediction Model on Commercial Apple Farms in Eastern New York. *Fruit Q.* 2018, 26, 21–27.
- [51] Soska Konsulting - Niezależne doradztwo sadownicze, [www.soskakonsulting.pl](http://www.soskakonsulting.pl), dostęp 23 maj 2024.
- [52] „Program Ochrony Roślin Sadowniczych na rok 2024”, PlantPress Sp. z o.o. Kraków 2024
- [53] Pawłowski, P.; Piniarski, K.; Dąbrowski, A. Highly Efficient Lossless Coding for High Dynamic Range Red, Clear, Clear, Clear Image Sensors. *Sensors* 2021, 21, 653. <https://doi.org/10.3390/s21020653>
- [54] N. Dalal i B. Triggs, „Histograms of oriented gradients for human detection”, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, cze. 2005, s. 886–893 t. 1. doi: 10.1109/CVPR.2005.177.



- [55] Y. Cao, S. Pranata, i H. Nishimura, „Local Binary Pattern features for pedestrian detection at night/dark environment”, *18th IEEE International Conference on Image Processing*, wrz. 2011, s. 2053–2056. doi: 10.1109/ICIP.2011.6115883.
- [56] Y. Wei, Q. Tian, i T. Guo, „An Improved Pedestrian Detection Algorithm Integrating Haar-Like Features and HOG Descriptors”, *Adv. Mech. Eng.*, t. 5, s. 546206, sty. 2013, doi: 10.1155/2013/546206.
- [57] L. C. Padierna, M. Carpio, A. Rojas-Domínguez, H. Puga, i H. Fraire, „A novel formulation of orthogonal polynomial kernel functions for SVM classifiers: The Gegenbauer family”, *Pattern Recognit.*, t. 84, s. 211–225, grudz. 2018, doi: 10.1016/j.patcog.2018.07.010.
- [58] M. Bilal i M. S. Hanif, „Benchmark Revision for HOG-SVM Pedestrian Detector Through Reinvigorated Training and Evaluation Methodologies”, *IEEE Trans. Intell. Transp. Syst.*, t. 21, nr 3, s. 1277–1287, mar. 2020, doi: 10.1109/TITS.2019.2906132.
- [59] S. Zhang, R. Benenson, M. Omran, J. Hosang, i B. Schiele, „Towards Reaching Human Performance in Pedestrian Detection”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 40, nr 4, s. 973–986, kwi. 2018, doi: 10.1109/TPAMI.2017.2700460.
- [60] S. Zhang, C. Bauckhage, i A. B. Cremers, „Efficient Pedestrian Detection via Rectangular Features Based on a Statistical Shape Model”, *IEEE Trans. Intell. Transp. Syst.*, t. 16, nr 2, s. 763–775, kwi. 2015, doi: 10.1109/TITS.2014.2341042.
- [61] T. Yu, B. Mo, F. Liu, H. Qi, i Y. Liu, „Robust thermal infrared object tracking with continuous correlation filters and adaptive feature fusion”, *Infrared Phys. Technol.*, t. 98, s. 69–81, maj 2019, doi: 10.1016/j.infrared.2019.02.012.
- [62] P. Dollár, Z. Tu, P. Perona, i S. Belongie, „Integral Channel Features”, zaprezentowano na British Machine Vision Conference (BMVC), sty. 2009. doi: 10.5244/C.23.91.
- [63] P. Dollár, R. Appel, S. Belongie, i P. Perona, „Fast Feature Pyramids for Object Detection”, *IEEE Trans. Pattern Anal. Mach. Intell.*, t. 36, nr 8, s. 1532–1545, sie. 2014, doi: 10.1109/TPAMI.2014.2300479.
- [64] S. Zhang, R. Benenson, i B. Schiele, „Filtered Channel Features for Pedestrian Detection”, sty. 2015.
- [65] Y. Jia i in., „Caffe: Convolutional Architecture for Fast Feature Embedding”. arXiv, 20 czerwiec 2014. doi: 10.48550/arXiv.1408.5093.
- [66] A. Krizhevsky, I. Sutskever, i G. E. Hinton, „ImageNet classification with deep convolutional neural networks”, *Commun. ACM*, t. 60, nr 6, s. 84–90, maj 2017, doi: 10.1145/3065386.
- [67] K. He, X. Zhang, S. Ren, i J. Sun, „Deep Residual Learning for Image Recognition”. arXiv, 10 grudzień 2015. doi: 10.48550/arXiv.1512.03385.
- [68] Zifeng Wu, Chunhua Shen, Anton van den Hengel, Wider or Deeper: Revisiting the ResNet Model for Visual Recognition, *Pattern Recognition*, Volume 90, 2019, Pages 119-133, ISSN 0031-3203, <https://doi.org/10.1016/j.patcog.2019.01.006>.

- [69] F. Chollet, „Xception: Deep Learning with Depthwise Separable Convolutions”, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, lip. 2017, s. 1800–1807. doi: 10.1109/CVPR.2017.195.
- [70] B. Zoph, V. Vasudevan, J. Shlens, i Q. V. Le, „Learning Transferable Architectures for Scalable Image Recognition”. arXiv, 11 kwiecień 2018. doi: 10.48550/arXiv.1707.07012.
- [71] M. Tan i Q. V. Le, „EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks”. arXiv, 11 wrzesień 2020. doi: 10.48550/arXiv.1905.11946.
- [72] M. Tan i Q. V. Le, „EfficientNetV2: Smaller Models and Faster Training”. arXiv, 23 czerwiec 2021. doi: 10.48550/arXiv.2104.00298.
- [73] K. Piniarski, P. Pawłowski, i A. Dąbrowski, „Tuning of Classifiers to Speed-Up Detection of Pedestrians in Infrared Images”, *Sensors*, t. 20, nr 16, Art. nr 16, sty. 2020, doi: 10.3390/s20164363.
- [74] P. Viola i M. J. Jones, „Robust Real-Time Face Detection”, *Int. J. Comput. Vis.*, t. 57, nr 2, s. 137–154, maj 2004, doi: 10.1023/B:VISI.0000013087.49260.fb.
- [75] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY: Springer, 2000. doi: 10.1007/978-1-4757-3264-1.
- [76] L. Guo, P.-S. Ge, M. Zhang, L. Li, i Y. Zhao, „Pedestrian detection for intelligent transportation systems combining AdaBoost algorithm and support vector machine”, *Expert Syst Appl*, t. 39, s. 4274–4286, mar. 2012, doi: 10.1016/j.eswa.2011.09.106.
- [77] Z. Wang, S. Yoon, S. J. Xie, Y. Lu, i D. S. Park, „A High Accuracy Pedestrian Detection System Combining a Cascade AdaBoost Detector and Random Vector Functional-Link Net”, *Sci. World J.*, t. 2014, s. e105089, maj 2014, doi: 10.1155/2014/105089.
- [78] K.-K. Kong i K.-S. Hong, „Design of coupled strong classifiers in AdaBoost framework and its application to pedestrian detection”, *Pattern Recognit. Lett.*, t. 68, s. 63–69, grudz. 2015, doi: 10.1016/j.patrec.2015.07.043.
- [79] Y.-L. Hou, Y. Song, X. Hao, Y. Shen, M. Qian, i H. Chen, „Multispectral pedestrian detection based on deep convolutional neural networks”, *Infrared Phys. Technol.*, t. 94, s. 69–77, lis. 2018, doi: 10.1016/j.infrared.2018.08.029.
- [80] K. Park, S. Kim, i K. Sohn, „Unified multi-spectral pedestrian detection based on probabilistic fusion networks”, *Pattern Recognit.*, t. 80, s. 143–155, sie. 2018, doi: 10.1016/j.patcog.2018.03.007.
- [81] D. Čirjak, I. Miklečić, D. Lemić, T. Kos, i I. Pajač Živković, „Automatic Pest Monitoring Systems in Apple Production under Changing Climatic Conditions”, *Horticulturae*, t. 8, nr 6, Art. nr 6, cze. 2022, doi: 10.3390/horticulturae8060520.
- [82] P. Rajan, B. Radhakrishnan, i L. P. Suresh, „Detection and classification of pests from crop images using Support Vector Machine”, w *2016 International Conference on Emerging Technological Trends (ICETT)*, paź. 2016, s. 1–6. doi: 10.1109/ICETT.2016.7873750.
- [83] M. Cardim Ferreira Lima, M. E. Damascena de Almeida Leandro, C. Valero, L. C. Pereira Coronel, i C. O. Gonçalves Bazzo, „Automatic Detection and Monitoring of Insect Pests—A Review”, *Agriculture*, t. 10, nr 5, Art. nr 5, maj 2020, doi: 10.3390/agriculture10050161.

- [84] A. Guarnieri, S. Maini, G. Molari, i V. Rondelli, „Automatic trap for moth detection in integrated pest management”.
- [85] M.-S. Liao *i in.*, „Development of an autonomous early warning system for *Bactrocera dorsalis* (Hendel) outbreaks in remote fruit orchards”, *Comput. Electron. Agric.*, t. 88, s. 1–12, paź. 2012, doi: 10.1016/j.compag.2012.06.008.
- [86] H. Waghmare, R. Kokare, i Y. Dandawate, „Detection and classification of diseases of Grape plant using opposite colour Local Binary Pattern feature and machine learning for automated Decision Support System”, w *2016 3rd International Conference on Signal Processing and Integrated Networks (SPIN)*, luty 2016, s. 513–518. doi: 10.1109/SPIN.2016.7566749.
- [87] P. Jiang, Y. Chen, B. Liu, D. He, i C. Liang, „Real-Time Detection of Apple Leaf Diseases Using Deep Learning Approach Based on Improved Convolutional Neural Networks”, *IEEE Access*, t. 7, s. 59069–59080, 2019, doi: 10.1109/ACCESS.2019.2914929.
- [88] H. Lu *i in.*, „CONet: A Cognitive Ocean Network”, *IEEE Wirel. Commun.*, t. 26, nr 3, s. 90–96, cze. 2019, doi: 10.1109/MWC.2019.1800325.
- [89] M. Fraiwan, E. Faouri, i N. Khasawneh, „On Using Deep Artificial Intelligence to Automatically Detect Apple Diseases from Leaf Images”, *Sustainability*, t. 14, nr 16, Art. nr 16, sty. 2022, doi: 10.3390/su141610322.
- [90] S. S. Harakannanavar, J. M. Rudagi, V. I. Puranikmath, A. Siddiqua, i R. Pramodhini, „Plant leaf disease detection using computer vision and machine learning algorithms”, *Glob. Transit. Proc.*, t. 3, nr 1, s. 305–310, cze. 2022, doi: 10.1016/j.gltp.2022.03.016.
- [91] I. Abbas *i in.*, „Different Real-Time Sensor Technologies for the Application of Variable-Rate Spraying in Agriculture”, *Sens. Actuators Phys.*, t. 316, s. 112265, sie. 2020, doi: 10.1016/j.sna.2020.112265.
- [92] V. Partel, L. Costa, i Y. Ampatzidis, „Smart tree crop sprayer utilizing sensor fusion and artificial intelligence”, *Comput. Electron. Agric.*, t. 191, s. 106556, grudz. 2021, doi: 10.1016/j.compag.2021.106556.
- [93] H. Asaei, A. Jafari, i M. Loghavi, „Site-specific orchard sprayer equipped with machine vision for chemical usage management”, *Comput. Electron. Agric.*, t. 162, s. 431–439, lip. 2019, doi: 10.1016/j.compag.2019.04.040.
- [94] J. Seol, J. Kim, i H. I. Son, „Field evaluations of a deep learning-based intelligent spraying robot with flow control for pear orchards”, *Precis. Agric.*, t. 23, nr 2, s. 712–732, kwi. 2022, doi: 10.1007/s11119-021-09856-1.
- [95] F. B. P. Malavazi, R. Guyonneau, J.-B. Fasquel, S. Lagrange, i F. Mercier, „LiDAR-only based navigation algorithm for an autonomous agricultural robot”, *Comput. Electron. Agric.*, t. 154, s. 71–79, lis. 2018, doi: 10.1016/j.compag.2018.08.034.
- [96] S. C. Hespeler, H. Nematy, i E. Dehghan-Niri, „Non-destructive thermal imaging for object detection via advanced deep learning for robotic inspection and harvesting of chili peppers”, *Artif. Intell. Agric.*, t. 5, s. 102–117, sty. 2021, doi: 10.1016/j.aiia.2021.05.003.

- [97] D. Q. da Silva, F. N. dos Santos, A. J. Sousa, i V. Filipe, „Visible and Thermal Image-Based Trunk Detection with Deep Learning for Forestry Mobile Robotics”, *J. Imaging*, t. 7, nr 9, Art. nr 9, wrz. 2021, doi: 10.3390/jimaging7090176.
- [98] „Sensors | Free Full-Text | Tree Trunk Recognition in Orchard Autonomous Operations under Different Light Conditions Using a Thermal Camera and Faster R-CNN”. <https://www.mdpi.com/1424-8220/22/5/2065> (dostęp 24 sierpień 2023).
- [99] J. Radcliffe, J. Cox, i D. M. Bulanon, „Machine vision for orchard navigation”, *Comput. Ind.*, t. 98, s. 165–171, cze. 2018, doi: 10.1016/j.compind.2018.03.008.
- [100] E. Hamuda, M. Glavin, i E. Jones, „A survey of image processing techniques for plant extraction and segmentation in the field”, *Comput. Electron. Agric.*, t. 125, s. 184–199, lip. 2016, doi: 10.1016/j.compag.2016.04.024.
- [101] G. Gupta, „Algorithm for Image Processing Using Improved Median Filter and Comparison of Mean, Median and Improved Median Filter”, 2011, <https://www.semanticscholar.org/paper/Algorithm-for-Image-Processing-Using-Improved-and-Gupta/ee7686f5e5c990127ca31ffb7a3ce95c4e395143> (dostęp 24 sierpień 2023)
- [102] S. Opiyo, C. Okinda, J. Zhou, E. Mwangi, i N. Makange, „Medial axis-based machine-vision system for orchard robot navigation”, *Comput. Electron. Agric.*, t. 185, s. 106153, cze. 2021, doi: 10.1016/j.compag.2021.106153.
- [103] „Content Based Image Retrieval using Gabor Filters and Color Coherence Vector | IEEE Conference Publication | IEEE Xplore”. <https://ieeexplore.ieee.org/document/8692123> (dostęp 24 sierpień 2023).
- [104] I. T. Jolliffe i J. Cadima, „Principal component analysis: a review and recent developments”, *Philos. Trans. R. Soc. Math. Phys. Eng. Sci.*, t. 374, nr 2065, s. 20150202, kwi. 2016, doi: 10.1098/rsta.2015.0202.
- [105] G. Gao, K. Xiao, i Y. Jia, „A spraying path planning algorithm based on colour-depth fusion segmentation in peach orchards”, *Comput. Electron. Agric.*, t. 173, s. 105412, cze. 2020, doi: 10.1016/j.compag.2020.105412.
- [106] Ratajkiewicz H., Maksym B. Możliwości zastosowania wybranych związków powierzchniowo-czynnych pochodzenia naturalnego i olei stosowanych w technologii farmaceutycznej do zwalczania szkodników. W Poszukiwanie nowych rozwiązań w ochronie upraw ekologicznych, red. Matyjaszczyk E., 381-388 ss. Instytut Ochrony Roślin – Państwowy Instytut Badawczy, Poznań, 2008, 393 ss.
- [107] Ratajkiewicz H.. Strategie adaptacyjne polskiego rolnictwa do zmian klimatycznych w zakresie ochrony roślin. III Polska Konferencja ADAGIO. 15-17.04.2009r.
- [108] Bykov, S. World trends in the creation of robots for spraying crops. *E3S Web Conf.* 2023, 380, 0101. <https://doi.org/10.1051/e3sconf/202338001011>.
- [109] Khanna, M.; Singh, L.K.; Thawkar, S.; Goyal, M. PlaNet: A robust deep convolutional neural network model for plant leaves disease recognition. *Multimed. Tools Appl.* 2023, 83, 4465–4517. <https://doi.org/10.1007/s11042-023-15809-9>.

- [110] Daniel, C.; Grunder, J. Integrated Management of European Cherry Fruit Fly *Rhagoletis cerasi* (L.): Situation in Switzerland and Europe. *Insects* 2012, 3, 956–988. <https://doi.org/10.3390/insects3040956>.
- [111] Katsoyannos, B.I.; Papadopoulos, N.T.; Stavridis, D. Evaluation of Trap Types and Food Attractants for *Rhagoletis cerasi* (Diptera: Tephritidae). *J. Econ. Entomol.* 2000, 93, 1005–1010.
- [112] Emgu, C.V. Library Documentation. Available online: <https://www.emgu.com/wiki/files/4.4.0/document/html/8dee1f02-8c8a-4e37-87f4-05e10c39f27d.htm> (accessed on 20 December 2023).
- [113] Góral, P.; Pawłowski, P.; Dąbrowski, A. System bezprzewodowego zdalnego sterowania dla pojazdu autonomicznego. *Przegląd Elektrotechniczny* 2019, 95, 114–117. <https://doi.org/10.15199/48.2019.10.25>.
- [114] Góral, P. Pawłowski P., Dąbrowski A., „Modułowy system wizyjny do autonomicznych inspekcji i oprysków sadowniczych” *Przegląd Elektrotechniczny*, ISSN 0033-2097, R. 98 Nr 2/2022 - s. 70-75, doi:10.15199/48.2022.02.14,
- [115] Soika G., Lisek J., Bryk H., Hołdaj M., Program ochrony czereśni, Instytut ogrodnictwa, Skierniewice 2024
- [116] Pettit R., Pettit F., Robert & Cheng, Chao & Amos, Christopher. Artificial intelligence, machine learning, and deep learning for clinical outcome prediction. *Emerging Topics in Life Sciences*, 5, (2021) doi: 10.1042/ETLS20210246.
- [117] <https://www.deeplearningbook.org/>, (dostęp 20 maj 2024)
- [118] K. Weiss, T. M. Khoshgoftaar, i D. Wang, „A survey of transfer learning”, *J. Big Data*, t. 3, nr 1, s. 9, maj 2016, doi: 10.1186/s40537-016-0043-6.
- [119] F. Zhuang i in., „A Comprehensive Survey on Transfer Learning”, *Proc. IEEE*, t. 109, nr 1, s. 43–76, sty. 2021, doi: 10.1109/JPROC.2020.3004555.
- [120] „ImageNet”. <https://www.image-net.org/> (dostęp 24 sierpień 2023).
- [121] K. W. Church, Z. Chen, i Y. Ma, „Emerging trends: A gentle introduction to fine-tuning”, *Nat. Lang. Eng.*, t. 27, nr 6, s. 763–778, lis. 2021, doi: 10.1017/S1351324921000322.
- [122] Soniya, S. Paul, i L. Singh, „A review on advances in deep learning”, *IEEE Workshop on Computational Intelligence: Theories, Applications and Future Directions (WCI)*, grudz. 2015, s. 1–6. doi: 10.1109/WCI.2015.7495514.
- [123] G. Vrbančič i V. Podgorelec, „Transfer Learning With Adaptive Fine-Tuning”, *IEEE Access*, t. 8, s. 196197–196211, 2020, doi: 10.1109/ACCESS.2020.3034343.
- [124] J. Brownlee, „How to Avoid Overfitting in Deep Learning Neural Networks”, *MachineLearningMastery.com*, 16 grudzień 2018. <https://machinelearningmastery.com/introduction-to-regularization-to-reduce-overfitting-and-improve-generalization-error/> (dostęp 24 sierpień 2023).

- [125] „What is Overfitting in Deep Learning [+10 Ways to Avoid It]”. <https://www.v7labs.com/blog/overfitting>,<https://www.v7labs.com/blog/overfitting> (dostęp 24 sierpień 2023).
- [126] Góral, P.; Pawłowski, P.; Piniarski, K.; Dąbrowski, A. Multi-Agent Vision System for Supporting Autonomous Orchard Spraying. *Electronics* 2024, 13, 494. <https://doi.org/10.3390/electronics13030494>
- [127] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, i Z. Wojna, „Rethinking the Inception Architecture for Computer Vision”, w 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), cze. 2016, s. 2818–2826. doi: 10.1109/CVPR.2016.308.
- [128] Fawzy A., Evaluating Deep Learning Models: The Confusion Matrix, Accuracy, Precision and Recall,<https://blog.paperspace.com/deep-learning-metrics-precision-recall-accuracy/>, (dostęp 01 styczeń 2023)