

doi:10.15199/48.2025.02.26

Problematyka programowania systemów wizyjnych do identyfikacji owoców

Streszczenie. Systemy wizyjne to zaawansowane zestawy składające się z sensorów obrazu, sprzętu komputerowego oraz wyspecjalizowanych algorytmów oprogramowania. Przetwarzają i analizują obrazy z otoczenia, wspierając kontrolę, automatyzację procesów i inspekcję produktów. Typowe elementy takich systemów to oświetlenie, obiektywy, sensory obrazu, jednostki przetwarzania wizji oraz systemy komunikacji. W przemyśle spożywczym i rolniczym systemy wizyjne są coraz częściej wykorzystywane do identyfikacji owoców, rozpoznawania i klasyfikowania ich na podstawie cech takich jak kolor, kształt, rozmiar i stopień dojrzałości. Badania skupiały się na programowaniu systemów wizyjnych do identyfikacji truskawek z użyciem środowiska Python oraz bibliotek OpenCV. Do oceny skuteczności identyfikacji owoców i poprawności określania ich współrzędnych wykorzystano kamerę inspekcyjną DF Robot OpenMV Cam H7. Kalibracja i uczenie maszynowe zostały przeprowadzone na zestawie owoców o różnych cechach. Algorytm został skonfigurowany do identyfikacji pikseli o wartościach RGB odpowiadających kolorowi czerwonego. Badania obejmowały uczenie maszynowe w celu identyfikacji obiektów, analizę wpływu natężenia światła, wykrywanie obiektów o określonym kolorze oraz ocenę dokładności odczytu współrzędnych owoców. Wyniki pokazały, że system najlepiej identyfikował czerwone truskawki z powodu wysokiego kontrastu. Dostosowanie ekspozycji kamery umożliwia preferencyjne wykrywanie bardziej nasyconych kolorów.

Abstract. Machine vision systems are advanced sets composed of electronic components, computer hardware and specialized software algorithms. They process and analyze images from the environment, supporting control, process automation and product inspection. Typical components include lighting, lenses, image sensors, vision processing units, and communication systems. In the food and agricultural industries, vision systems are increasingly used to identify fruit, recognizing and classifying them based on features such as color, shape, size and degree of ripeness. The research focused on programming vision systems for strawberry identification using the Python environment and OpenCV libraries. The DF Robot OpenMV Cam H7 inspection camera was used to assess the effectiveness of fruit identification and the correctness of determining their coordinates. Calibration and machine learning were performed on a set of fruits with different characteristics. The algorithm was configured to identify pixels with RGB values corresponding to the red color. The research included machine learning for object identification, analysis of the impact of light intensity, detection of objects of a specific color and assessment of the accuracy of reading fruit coordinates. The results showed that the system best identified red strawberries due to high contrast. Adjusting the camera exposure allows for preferential detection of more saturated colors. (**Programming of vision systems for fruit identification**)

Słowa kluczowe: system wizyjny, przetwarzanie obrazu, programowanie, automatyzacja procesu, analiza obrazu

Keywords: vision system, image processing, programming, process automation, image analysis


Wprowadzenie

Systemy wizyjne maszyn to zaawansowane zestawy składające się z zintegrowanych sensorów obrazu (np. kamer), sprzętu komputerowego oraz wyspecjalizowanych algorytmów oprogramowania. Ich rolą jest zapewnienie wsparcia operacyjnego poprzez przetwarzanie i analizę obrazów z otoczenia. Pozyskane dane są następnie wykorzystywane do kontroli, automatyzacji procesów oraz inspekcji produktów i materiałów [1,2]. Typowe komponenty składające się na systemy wizyjne maszyn obejmują oświetlenie, obiektywy, czujniki obrazu, jednostki przetwarzania wizji oraz systemy komunikacyjne [3,4].

Systemy wizyjne do identyfikacji owoców są coraz częściej stosowanymi rozwiązaniami w przemyśle spożywczym i rolnictwie. Ich głównym celem jest automatyczne rozpoznawanie i klasyfikowanie owoców na podstawie ich cech takich jak kolor, kształt, wielkość i stopień dojrzałości [5]. Wykorzystują one zaawansowane algorytmy wizyjne oraz technologie obrazowania celem dokładnego analizowania obrazów owoców, umożliwiając szybką i precyzyjną identyfikację [6]. Z uwagi na te funkcje możliwe jest automatyczne sortowanie owoców według określonych kryteriów jakościowych oraz eliminowanie produktów o niskiej jakości [7,8]. Są one również używane do monitorowania procesów pakowania i magazynowania owoców oraz do optymalizacji zarządzania nimi w łańcuchu dostaw, ale również w zrobotyzowanych systemach zbierających. Funkcje systemów wizyjnych do identyfikacji owoców obejmują min.:

- rozpoznawanie kolorów i wzorców na powierzchni owoców,
- pomiar wielkości i kształtu owoców,
- określanie stopnia dojrzałości i jakości owoców,
- automatyczne sortowanie i segregacja owoców na podstawie ustalonych parametrów [9,10].

Celem pracy badawczej była analiza problematyki programowania systemów wizyjnych w aspekcie skuteczności realizacji procesu identyfikacji truskawek na potrzebę realizacji projektu badawczo-rozwoowego. Prace badawcze prowadzono z wykorzystaniem popularnego środowiska programistycznego Python oraz aplikacją/bibliotekami OpenCV (Open Sources Computer Vision Library) stanowiący jeden z najbardziej popularnych zestawów narzędzi do przetwarzania obrazów i wizji maszynowej. Oferuje ono wiele gotowych funkcji do manipulacji obrazami, wykrywania obiektów, rozpoznawania twarzy itp. Najczęściej spotykanym rozwiązaniem stosowanym w rozwiązaniach przemysłowych, które wykorzystuje obraz do przetwarzania informacji z otoczenia, jest kamera inspekcji wizyjnej [11]. Kamera może być montowana niezależnie (na stałe) lub na robocie. W prowadzonych pracach badawczych realizowano wariant z kamerą umieszczoną na zewnętrznym statywie (rys. 1 – wariant z lewej strony).



Rys. 1. Sposób montażu systemu wizyjnego dla robotów przemysłowych

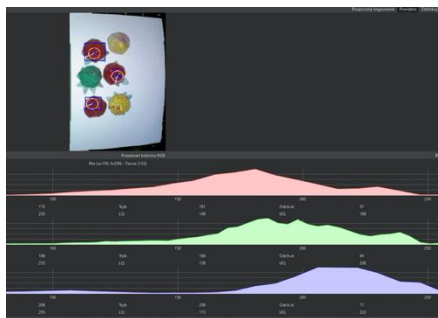
Problematyka programowania systemów wizyjnych

Programowanie systemów wizyjnych do identyfikacji owoców to interdyscyplinarne zagadnienie obejmujące elementy z dziedziny informatyki, sztucznej inteligencji, inżynierii oraz przetwarzania obrazów. Polega na

implementacji algorytmów komputerowego rozpoznawania obiektów, które umożliwiają automatyczną detekcję, klasyfikację oraz analizę owoców na podstawie ich cech wizualnych. Poniżej przedstawiono poszczególne cechy charakterystyczne brane pod uwagę w klasyfikacji systemem wizyjnym.

Zmienność wyglądu owoców

Owoce różnią się znacznie pod względem kształtu, wielkości, koloru, faktury powierzchni, a nawet stopnia dojrzałości (rys. 2). Zdjęcie przedstawia obraz zarejestrowany podczas badań. System wizyjny musi być na tyle zaawansowany, aby potrafił identyfikować zarówno dojrzałe, jak i niedojrzałe owoce, które mogą różnić się kolorem, a także rozpoznawać różnorodne warianty tego samego gatunku owoców, np. różne odmiany jabłek. Dodatkowo, owoce mogą mieć różne plamy, uszkodzenia czy deformacje, co zwiększa poziom trudności przy ich rozpoznawaniu [12].



Rys. 2. Sortowanie truskawek o różnej barwie

Światło i warunki otoczenia

Warunki oświetleniowe znacząco wpływają na skuteczność systemów wizyjnych. Zmienność światła naturalnego, cienie, refleksy czy oświetlenie sztuczne mogą prowadzić do trudności w identyfikacji kolorów i kształtów owoców (rys. 3). Programowanie systemów wizyjnych musi więc uwzględniać mechanizmy kompensacji zmieniających się warunków oświetleniowych, np. poprzez automatyczne dostosowanie parametrów kamery lub zaawansowane algorytmy przetwarzania obrazu, takie jak normalizacja kolorów czy eliminacja cieni [13].



Rys. 3. Oświetlenie kamery

Segmentacja obrazu i detekcja obiektów

Podstawowym problemem w rozpoznawaniu owoców jest poprawna segmentacja obrazu, czyli wydzielenie owocu z tła. W rzeczywistych warunkach owoce często są częściowo zakryte liśćmi, gałęziami, innymi owocami lub elementami otoczenia, co wymaga zaawansowanych algorytmów detekcji obiektów (rys. 4). Techniki takie jak wykrywanie krawędzi, filtrowanie morfologiczne czy analiza obiektów bazująca na uczeniu maszynowym są kluczowe dla

poprawnej segmentacji i rozpoznawania owoców w złożonym tle [14].



Rys. 4. Segmentacja obrazu [10]

Różnorodność i złożoność cech fizycznych

Owoce różnią się nie tylko kolorem, ale także teksturą, połyskiem czy stopniem gładkości powierzchni. Programowanie systemu wizyjnego musi uwzględniać różnorodność cech fizycznych, które mogą wpływać na rozpoznawanie owoców. Algorytmy takie jak analiza tekstury, wykrywanie konturów czy klasyfikacja na podstawie cech kształtu mogą być użyteczne, jednak złożoność tych cech zwiększa trudność dokładnego rozpoznania. Przykładowo, owoce pokryte woskową powłoką lub o gładkiej powierzchni mogą odbijać światło w sposób, który zakłóca obraz [15].

Ocena jakości i klasyfikacja owoców

Częścią systemów wizyjnych może być także automatyczna ocena jakości owoców, co stanowi kolejne wyzwanie. Ocena ta polega na identyfikacji defektów takich jak plamy, wgniecenia, przebarwienia czy inne anomalie (rys. 5). Programowanie takich systemów wymaga stosowania technik analizy obrazu opartych na sztucznej inteligencji (np. sieci neuronowe, algorytmy głębokiego uczenia), które umożliwiają automatyczną klasyfikację owoców na różne klasy jakościowe, przy jednoczesnym zachowaniu wysokiej precyzji i szybkości działania [16].



Rys. 5. Owoce z defektami

Szybkość przetwarzania i ograniczenia sprzętowe

W zastosowaniach przemysłowych systemy wizyjne do identyfikacji owoców muszą być nie tylko dokładne, ale również szybkie, aby sprostać wymaganiom produkcji masowej. Duże ilości danych obrazu muszą być przetwarzane w czasie rzeczywistym, co wymaga zastosowania zaawansowanych algorytmów i odpowiedniej mocy obliczeniowej. Ograniczenia sprzętowe, takie jak rozdzielczość kamery, szybkość transferu danych oraz wydajność procesora, mogą wpływać na skuteczność całego systemu [17].

Uczenie maszynowe i sztuczna inteligencja

Wynikają one z ich rozwoju, co stanowi istotny postęp w programowaniu systemów wizyjnych do identyfikacji owoców. Sieci neuronowe, zwłaszcza głębokie sieci konwolucyjne (CNN), wykorzystywane są do ekstrakcji cech z obrazu i klasyfikacji obiektów. Kluczowym wyzwaniem w tym zakresie jest potrzeba zgromadzenia i odpowiedniego

przetworzenia dużych ilości danych treningowych, które umożliwiają systemowi naukę rozpoznawania różnych gatunków i odmian owoców. Warto także zwrócić uwagę na problem nadmiernej zależności od danych treningowych, co może prowadzić do spadku efektywności systemu, gdy spotka on owoc w warunkach lub o cechach, których wcześniej nie widział [16].


Koszty wdrożenia i skalowalność

Ostatecznym wyzwaniem w programowaniu systemów wizyjnych jest zrównoważenie wysokiej precyzji działania z kosztami implementacji. Systemy te muszą być skalowalne i dostosowane do różnych środowisk produkcyjnych, od małych gospodarstw po duże zakłady przetwórcze. Ograniczenia budżetowe mogą wpłynąć na wybór sprzętu (np. rodzaj kamer) oraz stopień zaawansowania oprogramowania, co w efekcie może ograniczać możliwości systemu [18].

Choć automatyzacja procesów związanych z identyfikacją owoców przynosi liczne korzyści, wdrożenie zaawansowanych systemów wizyjnych może prowadzić do redukcji zatrudnienia na stanowiskach związanych z kontrolą jakości czy sortowaniem. Automatyzacja rodzi pytania natury etycznej, ale jednocześnie przyczynia się do poprawy wydajności oraz redukcji strat w przemyśle spożywczym. W efekcie, programowanie systemów wizyjnych do identyfikacji owoców jest złożonym zagadnieniem technicznym, obejmującym wyzwania związane z przetwarzaniem obrazu, uczeniem maszynowym oraz integracją z procesami automatyzacyjnymi [8].

Metodyka badań

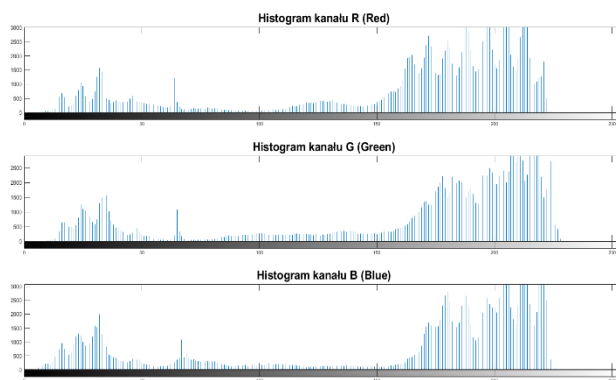
W badaniach oceniano efektywność identyfikacji owoców o określonych parametrach (barwa – reprezentująca stopień dojrzałości) oraz poprawność wyznaczania współrzędnych położenia owoców do podjęcia owocu jako detalu za pomocą chwytaka. Do przeprowadzenia pomiarów złożono stanowisko pomiarowe składające się z: robota Kawasaki Astorix, kamer inspekcji wizyjnej DF Robot OpenMV Cam H7 oraz luksomierz do pomiaru natężenia światła (rys. 6).



Rys. 6. Stanowisko pomiarowe z robotem i systemem wizyjnym

Pierwszym etapem przygotowania funkcjonowania systemu wizyjnego było przeprowadzenie kalibracji i uczenia maszynowego na zestawie detali o zróżnicowanych cechach, takich jak wygląd, kształt, wielkość i parametry, z ich dokładnym oznaczeniem w celu późniejszej walidacji wyników. Przykładowy histogram obrazu przedstawiającego rozkład wartości pikseli w obrazie (rys. 7). Składa się on z pionowych słupków, gdzie na osi X znajdują się wartości pikseli (np. od 0 do 255 dla obrazów o 8-bitowej głębi koloru), a na osi Y liczba pikseli o danej wartości. Histogram może być przydatny do analizy kontrastu, jasności, rozkładu kolorów oraz do uczenia systemu rozpoznającego. Algorytm został skonfigurowany do identyfikacji pikseli o wartościach RGB odpowiadających czerwonej barwie. System używa

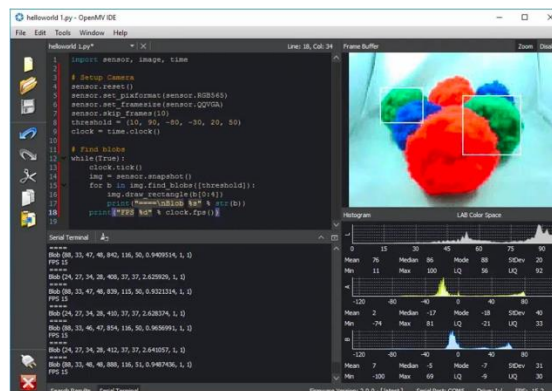
filtrów kolorów, które przepuszczają tylko określone długości fal odpowiadające czerwonej barwie, co sprawia, że inne kolory są ignorowane.



Rys. 6. Histogram z systemu wizyjnego


Algorytm przetwarzanie obrazu wykorzystywany w systemie wizyjnym

OpenMV IDE to zaawansowane środowisko przetwarzania obrazu, które umożliwia realizację różnorodnych zadań wizyjnych w sposób efektywny i elastyczny (rys. 8). Algorytmy przetwarzania obrazu stosowane w tym systemie obejmują złożony zestaw metod, które pozwalają na analizę i ekstrakcję istotnych informacji z obrazów akwizycyjonowanych przez kamerę zainstalowaną na urządzeniu.



Rys. 8. Interfejs programu OpenMV IDE

W systemie wizyjnym OpenMV IDE detekcja obiektów takich jak truskawki za pomocą algorytmu śledzenia koloru (color tracking) opiera się na analizie przestrzeni barw RGB, w której każdy piksel obrazu opisany jest jako kombinacja trzech składowych: czerwonej (R), zielonej (G) oraz niebieskiej (B) (rys. 9). Algorytm przetwarzania obrazu w OpenMV, mający na celu identyfikację truskawek, bazuje na segmentacji obrazu w oparciu o określony zakres kolorystyczny, odpowiadający barwie truskawek. Proces ten rozpoczyna się od akwizycji obrazu, gdzie kamera systemu rejestruje obraz w czasie rzeczywistym, zapisując wartości R, G i B dla każdego pikseli w formacie RGB565, który przypisuje odpowiednie wartości binarne do każdej z komponentów barw.



Rys. 9. Detekcja obrazu i segmentacja kolorów

Następnie definiowany jest zakres kolorystyczny dla składowych R, G i B, który charakteryzuje kolor truskawek (rys. 10). Użytkownik określa minimalne i maksymalne wartości dla każdej składowej, gdzie typowy kolor truskawki cechuje się wysoką wartością składowej czerwonej (R) oraz niższymi wartościami składowych zielonej (G) i niebieskiej (B). Kolejny etap obejmuje segmentację obrazu, gdzie algorytm porównuje wartości R, G, B każdego piksela z ustalonym zakresem kolorystycznym, klasyfikując piksele mieszczące się w tym przedziale jako należące do potencjalnego obiektu (truskawki), podczas gdy pozostałe piksele są ignorowane. Wynikiem segmentacji jest wyodrębnienie obszarów odpowiadających zdefiniowanemu kolorowi.


```

1 import sensor, Image, Line, math
2 from pyb import LED
3 from pyb import UART
4 from pyb import Pin
5
6 #kalibracja
7
8 w_x = 50
9 w_y = 0
10 w_width = 200
11 w_height = 500
12
13 #fisheye_corr = 0.7
14
15 c_fm_px = [(23, 7), (28, 231), (186, 229), (187, 5)]
16 c_fm_p = [(138, 355, 595, 875), (-67, 651, 588, 657), (-63, 877, 363, 426), (142, 891, 359, 874)]
17
18 thresholds = (38, 100, 15, 127, 15, 127)
19
20 off_x = 0
21 off_y = 0
22 off_ang = 0.09084
23
24 rot_val = 10

```

Rys.10. Definicja pola roboczego i zakresu kolorystycznego

Na podstawie pikseli spełniających kryteria zakresu kolorystycznego, algorytm tworzy maskę binarną, gdzie piksele odpowiadające zdefiniowanemu kolorowi otrzymują wartość 1 (biały), a pozostałe są ustawione na wartość 0 (czarny). Maskę tę ułatwia wyodrębnienie obiektów o określonym kolorze z tła. Następnie algorytm przystępuje do analizy wyodrębnionych obszarów (blob detection), identyfikując większe skupiska pikseli, które mogą odpowiadać truskawkom. Wyznaczane są parametry tych obszarów, takie jak ich pozycja, rozmiar oraz współrzędne środka ciężkości. Dla każdego wykrytego obszaru może być rysowany prostokąt lub krzyż, co umożliwia wizualizację wykrytych obiektów na obrazie (rys. 11).



Rys. 11. Zidentyfikowana czerwona truskawka

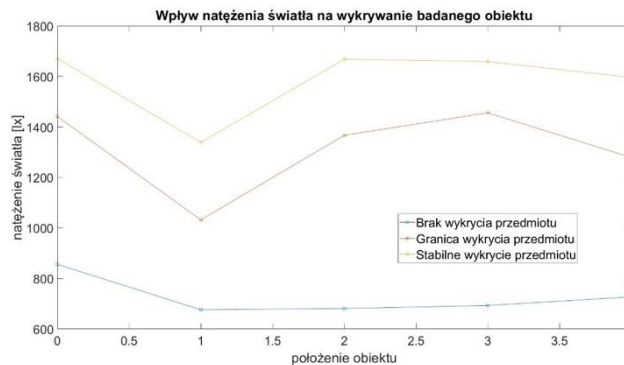
Badania doświadczalne

Przeprowadzone badania obejmowały następujące zagadnienia:

- analizę wpływu natężenia światła na wykrywanie obiektów,
- wykrywanie obiektów o określonej barwie i nasyceniu,
- ocenę dokładności odczytywania współrzędnych położenia owoców w kontekście pozycjonowania chwytaka robota.

W ramach badań eksperymentalnych dokonano analizy wpływu natężenia światła na wykrywanie obiektów, a w szczególności owoców truskawek, przez system wizyjny oparty na kamerze. Celem tej analizy było określenie zależności pomiędzy położeniem obiektu a natężeniem światła niezbędnym do jego wykrycia w trzech kategoriach: brak wykrycia, granica wykrycia oraz stabilne wykrycie. Dla celów badawczych, wyznaczono pięć punktów pomiarowych,

w których monitorowano te zależności, uwzględniając zmienne położenie truskawki oraz zmienne warunki oświetleniowe. Pomiar natężenia światła został przeprowadzony w luksach (lx) i odnosił się do warunków koniecznych dla poprawnego wykrycia obiektu przez kamerę. Wyniki przedstawione na wykresie ukazują, jak zmienne położenie obiektu oraz natężenie oświetlenia wpływają na możliwość jego wykrycia w kolejnych przedziałach detekcji (rys. 12).



Rys. 12. Wpływ natężenia światła na wykrywanie danego obiektu

Zauważono trzy stany logiczne, występujące podczas badań i związane z oświetleniem:

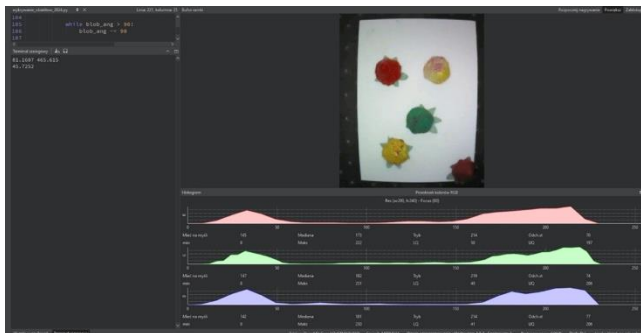
- brak wykrycia obiektu, stan ten odnosi się do sytuacji, w której natężenie światła było zbyt niskie, aby system wizyjny mógł wykryć obiekt. Wartości natężenia światła w tym przedziale są poniżej minimalnego progu detekcji kamery, co wskazuje, że oświetlenie było niewystarczające, aby zapewnić poprawną identyfikację truskawki;
- granica wykrycia obiektu, oznacza minimalne natężenie światła, które pozwala na wykrycie obiektu przez kamerę. Jest to wartość progowa, przy której system zaczyna rozpoznawać truskawkę, choć wykrywanie może być niestabilne i zależne od innych czynników, takich jak zmiana położenia obiektu czy kąt padania światła;
- stabilne wykrycie obiektu, przy którym wartości natężenia światła w tym przedziale są wystarczająco wysokie, aby zapewnić pewne i powtarzalne wykrycie obiektu. Oświetlenie jest w tych warunkach optymalne, co pozwala na skuteczną detekcję bez znaczących zakłóceń. W tej kategorii system działa z największą precyzją i niezawodnością.

Z przeprowadzonej analizy wynika, że poprawne i stabilne wykrycie obiektu zależy nie tylko od odpowiedniego poziomu oświetlenia, ale również od jego położenia względem kamery. W obszarach, w których natężenie światła było zbyt niskie, kamera nie była w stanie wykryć truskawki, co wskazuje na konieczność zwiększenia oświetlenia w tych strefach. W przypadku pozycji, gdzie występowała granica wykrycia, nawet niewielka zmiana w natężeniu światła mogła wpłynąć na skuteczność detekcji, co sugeruje dużą wrażliwość systemu na poziom oświetlenia. Dodatkowo zidentyfikowano nieliniowy charakter zależności między położeniem obiektu a natężeniem światła, co może wynikać z wpływu cieni i odbić światła na skuteczność detekcji. Wskazuje to na potrzebę optymalnego rozmieszczenia źródeł światła w układzie pomiarowym oraz kontrolowania wpływu czynników zewnętrznych takich, jak odbicia i nierównomierne oświetlenie.

Wykrywanie obiektów o określonej barwie i nasyceniu

W badaniu przeanalizowano zdolność systemu wizyjnego do detekcji obiektów o różnej barwie umieszczonych na jednolitym tle. System został skonfigurowany do identyfikacji czerwonych obiektów, a

algorytmy wykorzystywały analizę wartości RGB, aby wykrywać piksele o odpowiednich parametrach kolorystycznych. W eksperymencie system poprawnie rozpoznał jedynie czerwoną truskawkę, spośród trzech próbek (czerwonej, zielonej i żółtej). Czynnikiem wpływającym na ten wynik była konfiguracja systemu, optymalizowana pod kątem wykrywania obiektów o określonej barwie, możliwe jest bardzo precyzyjne stawienie również stopnia nasycenia oraz barwy przejściowej, ponieważ podaje się wartość każdej składowej (rys. 13).



Rys. 13. Widok okna programu

Oświetlenie miało istotny wpływ na efektywność detekcji. Czerwona truskawka była najlepiej oświetlona, co prowadziło do zwiększenia jasności i nasycenia koloru (rys. 14). Jednolite oświetlenie bez cieni i refleksów, umożliwiło systemowi wizyjnemu łatwiejsze rozpoznanie obiektu. Wysoki kontrast pomiędzy czerwoną truskawką a białym tłem dodatkowo ułatwił identyfikację krawędzi i kształtu obiektu.



Rys. 14. Identyfikacja czerwonej truskawki

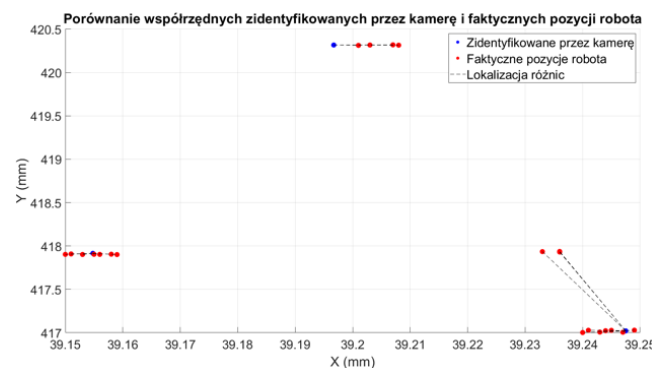
Oprócz oświetlenia, znaczenie miały czułość i ustawienia kamery. Poprawny balans bieli oraz odpowiednio ustawiona ekspozycja umożliwiły systemowi lepszą detekcję rzeczywistych kolorów, szczególnie w warunkach dobrego oświetlenia. W przypadku słabszego oświetlenia kolor czerwony mógłby wydawać się mniej nasycony, co utrudniałoby detekcję.

System wizyjny zastosował algorytmy segmentacji, które dzieliły obraz na fragmenty, umożliwiając wyodrębnienie obiektów na podstawie barwy. Przy odpowiednich warunkach oświetleniowych proces ten był bardziej efektywny, co pozwoliło na precyzyjne rozpoznanie truskawki jako spójnego obiektu.

Ocenę dokładności odczytywania współrzędnych położenia owoców w kontekście pozycjonowania chwytaka robota

Badanie miało na celu ocenę dokładności systemu wizyjnego w odczytywaniu współrzędnych położenia obiektów, które są następnie wykorzystywane do precyzyjnego pozycjonowania chwytaka robota. W eksperymencie porównano współrzędne obiektów wykrytych

przez system wizyjny z rzeczywistymi pozycjami, do których przemieścił się robot. Przeprowadzono 26 prób pomiarowych, analizując dwie grupy punktów: współrzędne wykryte przez kamerę oraz rzeczywiste współrzędne, w które robot został skierowany. Wyniki wizualizowano za pomocą wykresu, na którym niebieskie punkty oznaczały pozycje wykryte przez system, a czerwone punkty odpowiadały rzeczywistym pozycjom robota (rys. 15). Odchylenia pomiędzy tymi punktami były reprezentowane przez linie, których długość wskazywała na wielkość błędu pomiędzy współrzędnymi wykrytymi a rzeczywistymi.



Rys. 15. Skuteczność wyznaczania współrzędnych obiektów

Analiza wyników wykazała, że średnia odchyłka wyniosła 0,13 mm, co wskazuje na wysoką precyzję systemu w ustalaniu pozycji obiektów. Taki wynik sugeruje, że różnice pomiędzy współrzędnymi wykrytymi przez kamerę a rzeczywistymi pozycjami, do których przemieszczał się robot, są bardzo małe. System wizyjny działa zatem z dużą dokładnością, co jest kluczowe dla precyzyjnego pozycjonowania chwytaka. Odchylenie standardowe, wynoszące 0,31 mm, wskazuje na niewielką zmienność wyników pomiarowych.

Precyzja systemu, wyrażona jako odwrotność odchylenia standardowego, wyniosła 3,22. Jest to umiarkowany wynik, który pozwala na zastosowanie systemu w zadaniach o średnim poziomie wymaganej precyzji. W kontekście automatyzacji procesów takich, jak zbiór lub sortowanie owoców, wynik ten jest akceptowalny, jednak w bardziej zaawansowanych aplikacjach mogłoby być wskazane dalsze doskonalenie systemu w celu zwiększenia precyzji. Dokładność systemu, definiowana jako odwrotność średniej odchyłki wyniosła 7,80, co świadczy o jego wysokiej zdolności do poprawnego wykrywania pozycji obiektów. Niska wartość niepewności pomiaru, wynosząca 0,06 mm, dodatkowo potwierdza, że system działa bardzo precyzyjnie i stabilnie, a odczyty współrzędnych są powtarzalne.

Wyniki badania sugerują, że system wizyjny jest wystarczająco precyzyjny do skutecznego pozycjonowania chwytaka robota w zadaniach związanych z automatyzacją zbiorów owoców. Niska średnia odchyłka oraz mała zmienność wyników wskazują, że system może być z powodzeniem wykorzystany w procesach wymagających dokładnego pozycjonowania, takich jak precyzyjne przemieszczanie się robota do miejsc wyznaczonych przez system wizyjny.

Podsumowanie

Badania dotyczące wpływu różnych czynników na skuteczność systemu wizyjnego wykazały istotne zależności między oświetleniem a wykrywaniem obiektów. Minimalne natężenie światła potrzebne do wykrycia obiektu wynosi 1300 lx. Zbyt słabe oświetlenie uniemożliwia poprawne rozpoznanie przedmiotów, a stabilne wykrycie następuje przy odpowiednio wysokim natężeniu światła, co zapewnia

pewne i powtarzalne rozpoznanie. Maksymalna odległość obiektu kamery od stołu roboczego wynosi 30 cm. Jeżeli odległość ta jest większa, kamera nie jest w stanie zidentyfikować obiektu.

Analiza histogramów obrazów w różnych warunkach oświetleniowych wykazała, że dobre oświetlenie poprawia widoczność kolorów i krawędzi, ułatwiając algorytmom przetwarzania obrazu jej wykrycie i rozpoznanie. Wykrywanie czerwonej truskawki na białym tle w obecności innych kolorów potwierdziło skuteczność systemu w rozpoznawaniu kolorów. System wizyjny był w stanie łatwo wykryć czerwoną truskawkę dzięki różnicom w nasyceniu, jasności oraz kontrastowi z białym tłem.

Porównanie złe i dobrze zlokalizowanych obiektów ujawniło konieczność kalibracji lub ulepszenia algorytmów detekcji w systemie wizyjnym. Dobre wzorce w lokalizacji obiektów mogą pomóc w optymalizacji procesu identyfikacji i rozwiązywaniu problemów technicznych, takich jak niewystarczające oświetlenie czy zły kontrast. Badania dotyczące precyzyjnego ustalania położenia obiektów wykazały wysoką dokładność i minimalne odchylenia, potwierdzając efektywność systemu wizyjnego i robota.

Na podstawie przeprowadzonej analizy badań wyciągnięto następujące wnioski:

- minimalne natężenie światła potrzebne do wykrycia obiektu wynosi 1300 lx;
- maksymalna odległość stołu roboczego od obiektu kamery to 30 cm;
- lepsze oświetlenie zwiększa wykrywalność obiektów poprzez poprawę wartości nasycenia i jasności w obrazach;
- potrzeba kalibracji i ulepszenia algorytmów detekcji w celu zwiększenia skuteczności systemu wizyjnego;
- system wizyjny skutecznie wykrywa obiekty na tle o różnych kolorach dzięki programowaniu ukierunkowanemu na specyficzne cechy;
- wysoka precyzja i dokładność systemu wizyjnego oraz robota w ustalaniu położenia obiektów.

Autorzy: dr inż. Marcin Tomasik, Uniwersytet Rolniczy w Krakowie, Katedra Inżynierii Bioprocessów, Energetyki i Automatykacji, ul. Balicka 116B, 30-149 Kraków, e-mail: marcin.tomasik@urk.edu.pl.

mgr inż. Paulina Baluszynska, Uniwersytet Rolniczy w Krakowie, Katedra Inżynierii Bioprocessów, Energetyki i Automatykacji, ul. Balicka 116B, 30-149 Kraków, e-mail: paulina.baluszynska@urk.edu.pl.

LITERATURA

- [1] Baker, H., Dagdelen, J., Li, X.: Robot Vision: A Review. *Journal of Visual Communication and Image Representation*, 47, pp. 138-156, 2017.
- [2] Gómez-Sanchís, J., et al.: A review on machine vision technology in fruit grading. *Journal of Food Engineering*, 204, pp. 21-36, 2017.
- [3] Guerrero, J.J., et. al.: A Survey of Visual Sensors in Agri-Food Robotics. *Sensors*, 16(2), pp. 200, 2016.
- [4] Jain, D., Nandy, S.: Vision-Based Robotic Harvesting of Fruits: A Review. *IEEE Transactions on Automation Science and Engineering*, 17(2), pp. 532-548, 2020.
- [5] Lee, S.; Choi, G.; Park, H.-C.; Choi, C.: Automatic Classification Service System for Citrus Pest Recognition Based on Deep Learning. *Sensors*, 22, pp. 8911, 2022.
- [6] Syed-Ab-Rahman, S.F.; Hesamian, M.H.; Prasad, M.: Citrus disease detection and classification using end-to-end anchor-based deep learning model. *Appl. Intell.*, 52, 927-938 2022.
- [7] Khojastehnazhand, et. al.: Machine Vision Technology in Agriculture for Yield Prediction and Yield Mapping A Review. *Computers and Electronics in Agriculture*, 142, pp. 283-301, 2017.
- [8] Huang, Q., et. al.: Visual Perception for Robots: A Survey. *IEEE Transactions on Visualization and Computer Graphics*, 24(11), pp. 2608-2626, 2018.
- [9] Lu, H., et. al.: Review of Machine Vision Technology Application in Fruit and Vegetable Quality Inspection. *IEEE Access*, 6, pp. 22759-22772, 2018.
- [10] Vasconcelos, F., et. al.: A Review on Computer Vision Techniques Applied to Industrial Robots. *Robotics*, 9(2), pp. 41, 2020.
- [11] Karczewski G.: Systemy wizyjne w robotach Fanuc Robot. Pozyskano z: <https://automatykab2b.pl/prezentacje/40301-systemy-wizyjne-w-robotach-fanuc-robotics>, data pobrania [18.12.2023].
- [12] Lemessa Jembere, A., Jakubowski, T.: Investigating the Impact of UV-C Radiation on the Mechanical Characteristics of Semifinished Potato Tubers Prepared from Varied Potato Cultivars. *Nuclear Technology*, 210, pp. 1-12, 2024.
- [13] Ali K, Johnson BA.: Land-Use and Land-Cover Classification in Semi-Arid Areas from Medium-Resolution Remote-Sensing Imagery: A Deep Learning Approach. *Sensors*. 22(22) pp. 8750. 2022.
- [14] Kielczewski M.: Pozyskano z: Segmentacja obrazu <http://marcin.kielczewski.pracownik.put.poznan.pl/POiSW7.pdf>, data pobrania [18.12.2023].
- [15] Dutt, M.; El-Mohtar, C.A.; Wang, N.: Biotechnological approaches for the resistance to citrus diseases. *In The Citrus Genome*; Springer: Cham, Switzerland, pp. 245–257, 2020.
- [16] Dhiman, P.; et. al.: Novel Deep Learning Model for Detection of Severity Level of the Disease in Citrus Fruits. *Electronics*, 11, pp. 495, 2022.
- [17] Sethy, P.K.; Barpanda, N.K.; Rath, A.K.; Behera, S.K. Image processing techniques for diagnosing rice plant disease: A survey. *Procedia Comput. Sci.*, 167, pp. 516–530, 2020.
- [18] Kutyrev, A., et. al. Robotic Platform for Horticulture: Assessment Methodology and Increasing the Level of Autonomy. *Sensors*, 22, pp. 1-26, 2020.