



The use of spectral imaging for material identification in waste sorting

Krzysztof TUTAK¹, Mateusz PIESZKO²

¹ *Enformatic Sp. z o.o., ul. Mieszka I 73A, 35-303 Rzeszów, tel.: 48 510 107 946, e-mail: krzysztof.tutak@enformatic.eu*

² *Enformatic Sp. z o.o., ul. Mieszka I 73A, 35-303 Rzeszów, e-mail: mateusz.pieszko@enformatic.eu*

Abstract

This study covers the application of multispectral imaging to identify materials for municipal waste sorting purposes. Three classes of objects were considered by differentiating waste fractions between paper, plastic and organic waste while objects of different classes may have very similar colors which makes their identification difficult with the use of conventional RGB cameras. The pre-processing was applied including the removal of dark frame, radiometric distortion correction and conversion to the reflectance. The classification was undertaken using the nearest neighbor method taking as the similarity measure the Euclidean distance between the normalized spectral signatures. The tests were performed using a 128-channel hyperspectral camera that captures the exact signatures but has a long acquisition time and 16-channel multispectral camera that allows for the processing online. The results obtained for the 128-channel camera were used to select the bands recorded by the multispectral camera. Two variants of band selection were examined.

Keywords: spectral imaging, image processing, identification, classification, waste sorting, recycling

Streszczenie

Wykorzystanie obrazowania spektralnego do identyfikacji materiałów na potrzeby sortowania odpadów

W artykule zastosowano obrazowanie multispektralne do identyfikacji materiałów na potrzeby sortowania odpadów komunalnych. Rozważono trzy klasy obiektów, różniąc frakcje odpadów na: papier, plastik i odpady organiczne, przy czym obiekty różnych klas mogły mieć bardzo zbliżone kolory, co utrudnia ich identyfikację z wykorzystaniem typowych kamer RGB. Zastosowano przetwarzanie wstępne obejmujące usuwanie ramki ciemnej, korektę zniekształceń radiometrycznych i konwersję do refleksyjności. Klasyfikacji dokonano metodą najbliższego sąsiada przyjmując jako miarę podobieństwa odległość euklidesową pomiędzy znormalizowanymi sygnaturami spektralnymi. Testy wykonano z wykorzystaniem 128-kanalowej kamery hiperspektralnej, która rejestruje dokładne sygnatury, ale ma długi czas akwizycji oraz 16-kanalowej kamery multispektralnej pozwalającej na przetwarzanie w trybie online. Wyniki otrzymane dla kamery 128-kanalowej wykorzystano do wyboru pasm rejestrowanych przez kamerę multispektralną. Przebadano dwa warianty wyboru pasm.

Słowa kluczowe: obrazowanie spektralne, przetwarzanie obrazów, identyfikacja, klasyfikacja, sortowanie odpadów, recykling

1. Wprowadzenie

Obecnie obserwuje się na świecie trend polegający na intensyfikacji czynności podejmowanych przez rządy oraz organizacje międzynarodowe w celu zwiększenia zakresu działań związanych z ochroną środowiska naturalnego. Coraz większą uwagę przywiązuje się do odzysku i recyklingu, którego ważnym elementem jest sortowanie odpadów, w celu ich jak największego przetworzenia. Istnieje już pewna liczba funkcjonujących w tym zakresie rozwiązań technologicznych, które nie są jednak doskonałe. Wynika to między innymi z ograniczeń w zakresie zdolności rozpoznawania rodzajów sortowanych materiałów oraz coraz większej ilości surowców stosowanych w produkcji. Ilość generowanych przez człowieka odpadów ciągle rośnie, a wraz z rozwojem społeczeństwa pojawiają się ich nowe rodzaje. Niektóre materiały mogą być niebezpieczne dla zdrowia i życia pracowników obsługujących sortownie. Wszystkie te aspekty powodują, że wciąż istnieje zapotrzebowanie na innowacyjne

technologie, które pozwolą zautomatyzować oraz przyspieszyć proces sortowania odpadów, a także przyczynią się do obniżenia kosztów procesu recyklingu. Celem pracy była analiza możliwości wykorzystania obrazowania multispektralnego do identyfikacji materiałów na potrzeby sortowania odpadów komunalnych. Włączenie w proces sortowania technologii obrazowania spektralnego pozwala na znaczący wzrost zdolności do rozpoznawania materiałów, które identyfikowane są na podstawie sygnatur spektralnych, zawierających dodatkowe informacje o klasyfikowanych obiektach. Dodatkową zaletą jest również łatwość obsługi wykorzystywanych urządzeń oraz możliwość montażu na liniach sortujących odpady.

2. Przegląd literatury

W literaturze związanej z przetwarzaniem obrazu można już odnaleźć publikacje z zakresu sortowania z wykorzystaniem szeroko rozumianego obrazowania spektralnego, przy czym w większości przypadków dotyczą one obrazowania hiperspektralnego. W pracy [1] opisano wykorzystanie obrazowania hiperspektralnego w zakresie bliskiej podczerwieni do sortowania materiałów zawierających celulozę. Automatyczny system do sortowania zużytego sprzętu elektrycznego i elektronicznego zaprezentowano w [2]. Zwrócono tutaj szczególną uwagę na dobór odpowiedniego oświetlenia oraz interfejsu pomiędzy komputerem, a układem rejestrującym dane. Autorzy [3] analizują z kolei możliwość wykorzystania obrazowania hiperspektralnego w zakresie widzialnym oraz bliskiej podczerwieni (400-1000 nm) do identyfikacji rodzajów odpadów stałych powstających w wyniku pewnych procesów produkcyjnych. Próba klasyfikacji materiałów nieżelaznych została podjęta w publikacji [4], w której autorzy połączyli właściwości spektralne oraz przestrzenne we wspólny wektor cech i zastosowali metody logiki rozmytej. Identyfikacja materiałów jest również przedmiotem rozważań w artykule [5], który dotyczy obrazowania hiperspektralnego wykonywanego z powietrza. Autorzy opracowali algorytm uwzględniający zarówno warunki atmosferyczne, jak i geometrię badanego obszaru. W pracy [6] opisano system obrazowania multispektralnego do oceny zawartości chlorofilu w liściach. System umożliwia pomiar w trybie online poprzez zastosowanie konfigurowalnej kamery oraz akwizycję i przetwarzanie sześciu wybranych pasm. Pracą z pokrewnego zakresu jest również publikacja [7], która skupia się na kwestii optymalnego doboru rejestrowanych pasm w systemach służących do identyfikacji materiałów. Dobór pasm odbywa się w sposób iteracyjny tak, aby zwiększyć separowalność kątową między krzywymi spektralnymi. Pozwala to na poprawę skuteczności rozpoznawania nawet w przypadku bardzo podobnych obiektów oraz niewielkiej liczby wzorców.

3. Opis metody

3.1. Obrazowanie hiperspektralne oraz multispektralne

Obrazowanie spektralne to technika, w której dla każdego piksela obrazu mierzy się unikalne sygnatury spektralne obserwowanej powierzchni, pokazujące zależności współczynnika odbicia światła od długości fali [8]. Otrzymuje się w ten sposób trójwymiarowe struktury danych, które mogą być analizowane zarówno w dziedzinie spektralnej (λ) jak i przestrzennej (x, y). W zależności od ilości rozważanych kanałów oraz ciągłości odpowiadających im pasm wyróżnia się obrazowanie multispektralne (kilkanaście dyskretnych kanałów) oraz hiperspektralne (kilkadziesiąt i więcej kanałów, których pasma są na tyle blisko, że otrzymaną sygnaturę można traktować jako ciągłe widmo).

3.2. Opis algorytmu

3.2.1. Przetwarzanie wstępne

Systemy obrazowania spektralnego są zazwyczaj budowane w oparciu o matrycę rejestrującą napięcie, które reprezentuje informacje o ilości światła odbitego od obiektu dla każdego piksela znajdującego się w obrazie. System obrazujący zwraca surowe dane dotyczące wielkości napięcia zamieniane przez przetwornik analogowo-cyfrowy na liczby reprezentowane w określonej skali odwzorowania (określonej jako rozpiętość tonalna). Liczby te nie mogą być bezpośrednio wykorzystane w klasyfikacji, ponieważ reprezentują jedynie względną informację o tym, w jakim stosunku pozostają do wartości uzyskanych dla innych pikseli. W celu uzyskania znormalizowanych danych należy wykonać przetwarzanie wstępne obejmujące odjęcie ramki prądu ciemnego, kalibrację spektralną, korektę radiometryczną oraz przekształcenie do refleksyjności [9]. Dopiero refleksyjność spektralna, zdefiniowana jako stosunek energii odbitej do energii padającej na obiekt, opisuje właściwości

materiału w sposób pozwalający na porównywanie z widmami referencyjnymi i wykorzystywanie w zadaniach klasyfikacji.

Pierwsze ze wspomnianych wyżej procesowań polega na odjęciu ramki prądu ciemnego. Szum spowodowany prądem ciemnym jest obecny we wszystkich elektronicznych systemach obrazujących nawet w przypadku, gdy system nie jest oświetlany. Wielkość szumu elektronicznego zależy od wielu czynników, m. in. warunków, w których pracuje system, czasu pracy urządzenia oraz przede wszystkim od czasu integracji dla przechwytywanych obrazów. Szum elektroniczny powinien zostać usunięty z obrazu przed kolejnymi procesowaniami. W praktyce proces ten przeprowadza się poprzez odjęcie od pobieranych danych, tzw. ramki ciemnej otrzymanej w wyniku uśrednienia ramek zarejestrowanych przy zasłoniętym obiektywie.

Kalibracja spektralna (częstotliwościowa) wykorzystuje dane zarejestrowane podczas kalibracji systemu obrazowania spektralnego, która wykonywana jest zazwyczaj przez producenta kamery. Dane te wykorzystywane są do kalibracji dyspersji spektralnej spektrometru oraz korekcji nieliniowych zniekształceń optycznych (ang. „smile”), które wpływają na faktyczną częstotliwość mierzoną w określonym miejscu matrycy detektorowej.

Korekcja radiometryczna wykonywana jest w celu wyeliminowania zakłóceń wynikających z niedoskonałości optycznych układów kamery. Wykorzystuje się tutaj dedykowaną dla danego układu optycznego macierz współczynników pozwalających na dokonanie korekty wzmocnienia dla każdego piksela. Macierz ta jest dostarczana przez producenta kamery. Procedura kalibracji radiometrycznej zależy również od czasu integracji, który został ustawiony w trakcie pomiaru obrazu spektralnego.

W celu otrzymania informacji o reflektancji materiałów znajdujących się na przechwyconym obrazie hiperspektralnym należy wykonać kalibrację reflektancyjną (normalizację). Wyliczenie reflektancji materiałów oraz towarzysząca mu normalizacja warunków oświetleniowych wymaga znajomości energii światła padającego. Energia ta może zostać zmierzona wprost lub otrzymana z pomiaru elementu o znanej reflektancji (np. szarej karty reflektancyjnej, ang. *grey panel*), który musi znajdować się na scenie podczas rejestracji obrazu. Autorzy artykułu wykorzystali drugie z wymienionych podejść. Wartość radiancji piksela wyrażona jest równaniem:

$$L_{\lambda} = R_{\lambda} \times S_{\lambda} \times A_{\lambda} \times O_{\lambda} \quad (3.1)$$

gdzie:

R – reflektancja materiału,

S – irradiancja spektralna,

A – atmosferyczna transmitancja spektralna [10],

O – optyczna transmitancja spektralna [10].

Analogiczne równanie można zapisać dla materiału referencyjnego o znanej reflektancji:

$$N_{\lambda} = R_{\lambda}^n \times S_{\lambda} \times A_{\lambda} \times O_{\lambda} \quad (3.2)$$


Następnie, znając wartość reflektancji materiału referencyjnego (R_{λ}^n) zmierzoną w laboratorium można wyznaczyć szukaną wartość reflektancji z równania:

$$R_{\lambda} = L_{\lambda} \times \frac{R_{\lambda}^n}{N_{\lambda}} \quad (3.3)$$

Obrazy hiperspektralne wykorzystane w tym artykule zostały poddane wszystkim omówionym wyżej procesowaniom.

3.2.2. Usunięcie tła i szarej karty reflektancyjnej

Następnym krokiem było odrzucenie obszarów obrazu zajmowanych przez tło i szarą kartę reflektancyjną. Podczas obserwacji zauważono, że dla kanału 96, który odpowiada długości fali $\lambda=864$ nm obszary tła i szarej karty są znacząco ciemniejsze od pozostałych elementów w obrazie. Oznacza to, że pochłaniają one mocniej składową światła o tej długości. Pozwoliło to na odfiltrowanie tych obszarów poprzez dokonanie procesu binaryzacji obrazu, a następnie erozji i dylatacji morfologicznej [11]. W dalszym przetwarzaniu uwzględniane są piksele określone przez otrzymaną w ten sposób binarną maskę (rys. 3.1.).



Rys. 3.1. Usuwanie gumy i szarej karty: a) przykładowy obraz dla długości fali $\lambda=864$ nm, b) maska binarna po odfiltrowaniu tła i szarej karty reflektancyjnej [opracowanie własne]

3.2.3. Klasyfikacja w dziedzinie spektralnej

Klasyfikację w dziedzinie spektralnej wykonano z wykorzystaniem metody najbliższego sąsiada w oparciu o przygotowaną wcześniej bazę wzorców. Wykorzystano miarę dopasowania spektrów d :

$$d(\bar{y}_x, \bar{y}_w) = \sqrt{\sum_{i=1}^{128} (\bar{y}_x(i) - \bar{y}_w(i))^2} \quad (3.4)$$

gdzie:

\bar{y}_x - znormalizowane spektrum dla nieznanego materiału,

\bar{y}_w - znormalizowane spektrum dla wzorca,

i - numer kanału.

Normalizację przeprowadzono według równania:

$$\bar{y}(i) = \frac{y(i)}{\sum_{i=1}^{128} y(i)} \quad (3.5)$$

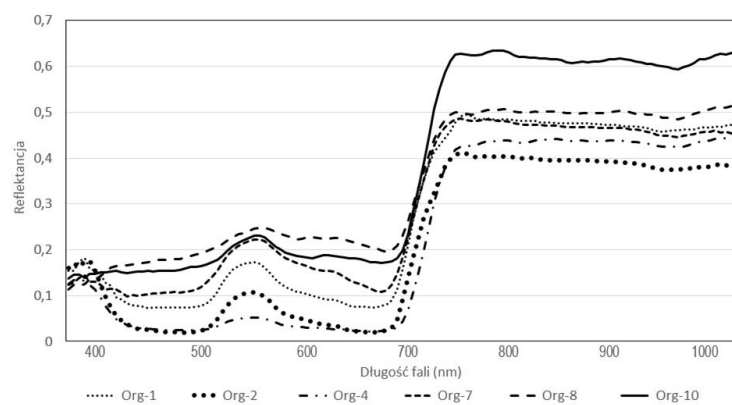
3.2.4. Baza wzorców

Baza wzorców powstała poprzez ręczne wycięcie prostokątnych fragmentów odpowiadających poszczególnym materiałom i wyznaczenie średnich spektrów dla każdego z nich (rys. 3.2.).



Z porównania otrzymanych wzorców można wyciągnąć następujące wnioski:

1. Dla przebiegów odpowiadających związkom organicznym zaobserwowano strome narastające zbocze mieszczące się w przedziale 650-750 nm (por. rys. 3.2.a).
2. Dla większości próbek odpowiadających papierowi zaobserwowano, że powyżej 700 nm przebieg ma łagodny charakter, bez wyraźnych ekstremów z lekką tendencją malejącą (por. rys. 3.2.b).
3. W dominującej liczbie próbek plastiku zaobserwowano liczne ekstrema w zakresie 850-1000 nm z wyraźnym minimum lokalnym dla długości fali około 925 nm (por. rys. 3.2.c).


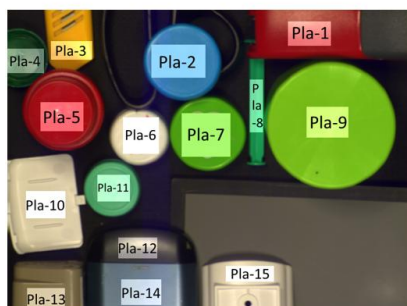
Na podstawie wniosków 1-3 stwierdzono, że cechy charakterystyczne pozwalające wyodrębnić związki organiczne uwidaczniają się w przedziale 650-750 nm, zaś rozróżnienie pomiędzy plastikiem a papierem jest możliwe poprzez analizę przedziału 850-1000 nm. Wstępne wyniki testów potwierdziły także, że nie warto analizować całego zakresu spektralnego. W związku z tym wyznaczanie miary dopasowania spektrów d dla kamery hiperspektralnej ograniczono do wymienionych zakresów spektralnych, które odpowiadają zakresom kanałów 53-75 i 96-128.



a)




b)



c)

Rys. 3.2. Obszary wykorzystywane do tworzenia wzorców wraz z odpowiadającymi im średnimi spektrami dla wybranych: a) związków organicznych, b) papieru i c) plastiku (pokazano tylko wybrane przebiegi) [opracowanie własne]


Po zastosowaniu opisanej metody otrzymano binarne maski odpowiadające poszczególnym materiałom (rys. 3.3.).



Rys. 3.3. Wyniki klasyfikacji w dziedzinie spektralnej: a) wejściowy obraz kolorowy (wygenerowany na podstawie przetwarzanego obrazu hiperspektralnego), b) wyznaczone ręcznie obszary odpowiadające związkom organicznym (kolor zielony), papierowi (kolor niebieski), plastikowi (kolor czerwony) oraz obszary sklasyfikowane jako: c) związki organiczne, d) papier, e) plastik [opracowanie własne]

3.2.5. Przetwarzanie końcowe

Otrzymane w poprzednim kroku maski odpowiadające poszczególnym materiałom poddano dalszemu przetworzeniu w dziedzinie przestrzennej obejmującemu kolejno erozję i dylatację morfologiczną, segmentację z wykorzystaniem algorytmu liniowego przeglądania i sklejeń oraz odrzucenie obiektów o polach powierzchni mniejszych od ustalonej wartości progowej [11]. W wyniku otrzymano obrazy pokazane na rys. 3.4.



Rys. 3.4. Wyniki klasyfikacji: a) związków organicznych, b) papieru, c) plastiku, po zastosowaniu przetwarzania w dziedzinie przestrzennej [opracowanie własne]

W operacjach morfologicznych zastosowano element strukturalny o rozmiarze 3×3 , zaś wartość progowa powierzchni obiektu wynosiła 1000.

3.2.6. Wybór kanałów

Wykorzystanie 128-kanałowej kamery hiperspektralnej pozwala na osiągnięcie zadowalających wyników, jednakże towarzyszy mu długi czas oczekiwania na pomiary. Dzisiejszy rozwój technologii pozwala już na produkcję kamer działających w trybie wideo, jednakże rejestrujących mniejszą liczbę pasm. Redukcja czasu oczekiwania na wyniki pozwala na eliminację jednego z głównych ograniczeń obrazowania hiperspektralnego,

jednakże pociąga za sobą konieczność zbadania skuteczności metody w przypadku radykalnego zmniejszenia liczby rejestrowanych kanałów. Autorzy postawili sobie za cel zbadanie przydatności wykorzystania obrazowania spektralnego do identyfikacji materiałów w przypadku ich rejestracji za pomocą 16-kanałowej kamery spektralnej dokonującej pomiarów w trybie online. Przeanalizowano wyniki uzyskiwane w dwóch konfiguracjach kamery spektralnej zwanych dalej wariantami. W pierwszym przypadku rejestrowane kanały rozmieszczone były równomiernie w całym rozpatrywanym w artykule przedziale (wariant 1), zaś w drugim rejestrowane były kanały rozmieszczone w obszarach, w których zaobserwowano nasilenie występowania dystynktywnych cech w wynikach uzyskiwanych za pomocą kamery 128-kanałowej (wariant 2) (tab. 3.1).

Tabela 3.1. Rozważane warianty wyboru 16 kanałów [opracowanie własne]

Lp.	Wariant 1		Wariant 2	
	Nr kanału	Długość fali [nm]	Nr kanału	Długość fali [nm]
1	16	450	53	638
2	23	483	56	654
3	29	517	59	670
4	36	550	61	680
5	42	583	64	696
6	49	617	67	711
7	55	650	70	727
8	62	683	96	864
9	68	717	99	880
10	74	750	102	896
11	81	783	105	912
12	87	817	108	928
13	93	850	111	944
14	100	883	113	955
15	106	917	116	971
16	112	950	119	987

4. Eksperymenty

4.1. Opis stanowiska

W pracy wykorzystano 128-kanałową kamerę hiperspektralną SOC-710VP pracującą w zakresie 400-1000 nm oraz 16-kanałową kamerę multispektralną SOC-716 rejestrującą dane w tym samym zakresie długości fal w trybie video z szybkością do 30 klatek multispektralnych na sekundę. Oba urządzenia produkowane są przez firmę Surface Optics Corporation [12]. Dla kamery 16-kanałowej możliwy jest, dokonywany u producenta, wybór pasm odpowiadających poszczególnym kanałom. Dane rejestrowane przez obie kamery posiadają 12-bitową rozpiętość tonalną.

W trakcie eksperymentów wykorzystano kartę szarą o 18% reflektancji produkowaną przez firmę Munsell oraz profesjonalne szerokopasmowe oświetlenie stosowane w pomiarach hiperspektralnych.

4.2. Opis bazy danych obrazów

W celu zbadania przydatności obrazowania hiperspektralnego do identyfikacji materiałów autorzy wykonali łącznie ponad 100 pomiarów przy pomocy kamery hiperspektralnej (rejestracja 128 kanałów) oraz kamery multispektralnej (rejestracja 16 kanałów). Rozważono dwa warianty wyboru 16 kanałów. Obiekty należące do rozpatrywanych klas prezentowane były w różnej ilości i rozmaitych konfiguracjach. Każdy z zarejestrowanych obrazów zawierał ponadto element o znanej reflektancji (tzw. szarą kartę).

Materiały wykorzystywane w testach zostały wydzielone z pojemników z rzeczywistymi odpadami wytwarzanymi w gospodarstwach domowych. Rozważono trzy frakcje: papier, plastik i odpady organiczne, przy czym przyjęto założenie, że rozważana próbka może zawierać jednocześnie materiały z każdej z nich, a zadaniem układu wizyjnego jest określenie ich przynależności do konkretnej klasy. W klasie plastik uwzględniono różnokolorowe opakowania, nakrętki oraz plastikowe elementy zabawek, przedmiotów i urządzeń

wykorzystywanych w gospodarstwach domowych. W klasie papier wykorzystano przede wszystkim odpady papierowe różnego rodzaju, koloru oraz gramatury w tym również z nadrukiem oraz widocznymi oznakami zużycia. W przypadku odpadów organicznych wykorzystano części roślin (trawa, liście, gałęzie) w różnym stadium wysuszenia.

4.3. Ocena wyników

Do ilościowej oceny wyników klasyfikacji wykorzystano obrazy z poszczególnymi materiałami obrysowanymi ręcznie (patrz rys. 3.3.b) oraz następujące wskaźniki liczone dla każdego z materiałów:

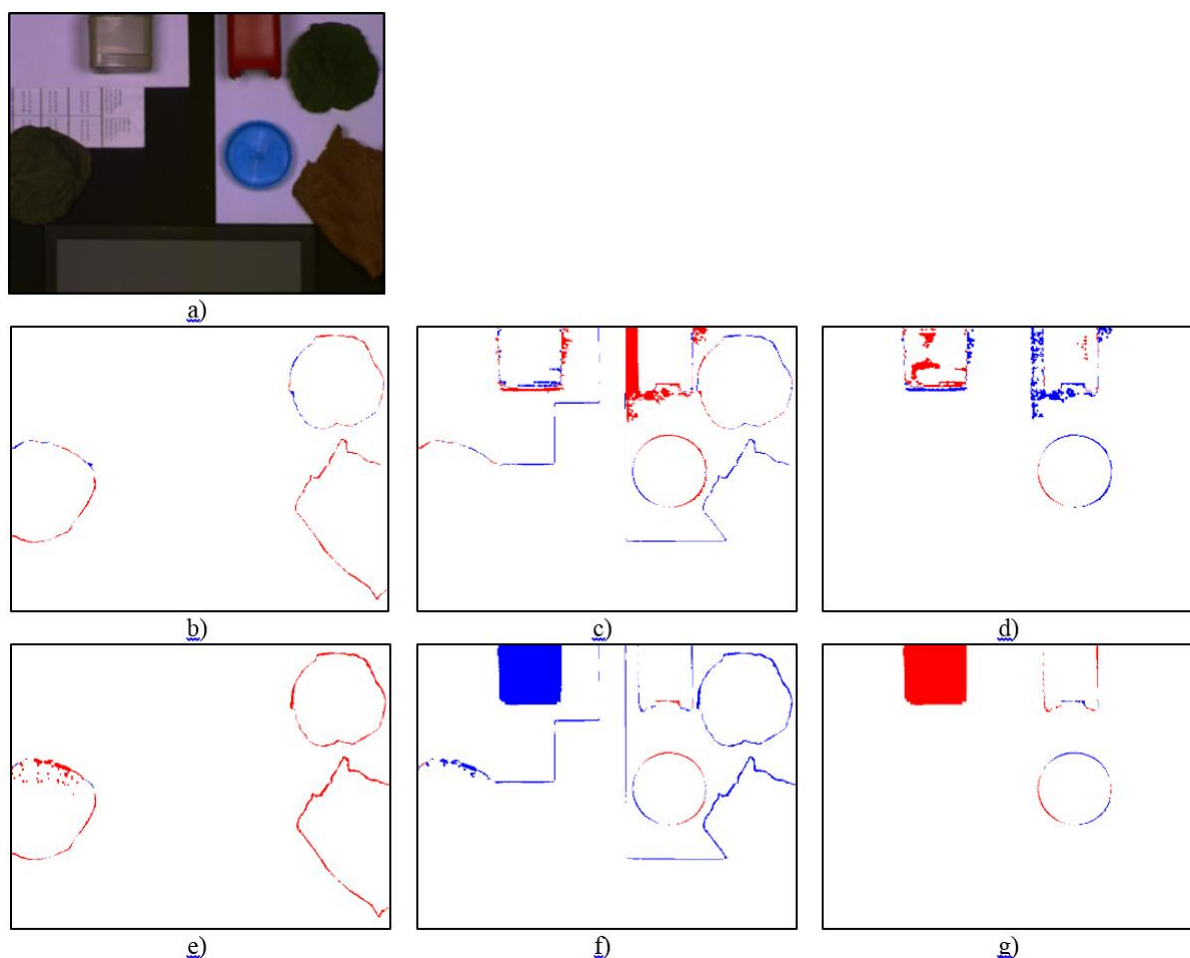
- C % - piksele danego materiału zakwalifikowane poprawnie,
- E % - piksele należące do materiału zakwalifikowane niepoprawnie ($E=100-C$),
- N % - piksele nienależące do materiału zakwalifikowane jako materiał.

Wybrane wyniki pokazano w tab. 4.1.

Tabela 4.1. Wyniki klasyfikacji związków organicznych (C_1 , E_1 , N_1), papieru (C_2 , E_2 , N_2), plastiku (C_3 , E_3 , N_3) dla kamery 128-kanalowej oraz kamery 16-kanalowej w wariantach 1 i 2 [opracowanie własne]


		Numer obrazu testowego										Średnia dla wszystkich obrazów
		1	2	3	4	5	6	7	8	9	10	
128 kanałów	C_1	97,75	93,49	95,80	94,43	98,40	98,30	93,71	99,18	95,18	99,14	96,64
	E_1	2,25	6,51	4,20	5,57	1,60	1,70	6,29	0,82	4,82	0,86	3,36
	N_1	0,16	0,02	18,30	0,01	0,24	0,38	0,05	0,59	0,45	0,33	2,05
	C_2	94,40	59,86	46,26	42,70	83,10	92,23	98,27	86,56	71,73	86,16	76,39
	E_2	5,60	40,14	53,74	57,30	16,90	7,77	1,73	13,44	28,27	13,84	23,61
	N_2	1,25	1,42	0,62	0,00	0,70	6,34	12,06	9,64	0,31	10,26	4,26
	C_3	93,00	97,08	83,56	97,30	93,15	68,46	66,00	57,02	94,77	57,25	80,84
	E_3	7,00	2,92	16,44	2,70	6,85	31,54	34,00	42,98	5,23	42,75	19,16
	N_3	1,25	15,85	1,08	12,07	4,64	1,62	0,68	2,57	5,00	4,04	4,88
16 kanałów (wariant 1)	C_1	96,71	55,01	95,93	94,54	95,27	99,16	97,13	99,33	98,44	99,32	93,31
	E_1	3,29	44,99	4,07	5,46	4,73	0,84	2,87	0,67	1,56	0,68	6,69
	N_1	0,08	0,005	0,13	0,01	0,05	0,41	0,19	0,52	0,64	0,83	0,29
	C_2	99,54	99,92	83,35	84,95	97,87	97,16	98,82	86,98	72,05	87,62	90,87
	E_2	0,46	0,08	16,65	15,05	2,13	2,84	1,18	13,02	27,95	12,38	9,13
	N_2	2,22	11,93	5,85	3,56	2,18	8,24	10,57	9,41	0,80	8,01	6,28
	C_3	89,90	84,76	70,71	72,21	87,07	64,37	64,57	58,53	87,13	64,53	74,39
	E_3	10,10	15,24	29,29	27,79	12,93	35,63	35,43	41,47	12,87	35,47	25,61
	N_3	0,11	0,36	0,11	0,09	0,24	0,44	0,35	2,43	4,60	3,26	1,20
16 kanałów (wariant 2)	C_1	94,96	49,12	95,27	94,28	88,25	98,67	95,52	99,21	94,19	99,26	90,99
	E_1	5,04	50,88	4,73	5,72	11,75	1,33	4,48	0,79	5,81	0,74	9,01
	N_1	0,02	0,00	0,87	0,006	0,07	0,28	0,05	0,68	0,44	0,40	0,28
	C_2	99,54	99,73	68,64	84,59	95,79	92,77	98,42	85,74	70,12	85,85	88,17
	E_2	0,46	0,27	31,36	15,41	4,21	7,23	1,58	14,26	29,88	14,15	11,83
	N_2	6,81	2,38	5,55	0,22	1,28	5,97	10,67	8,86	0,23	8,54	5,05
	C_3	65,37	97,44	64,00	90,30	98,29	69,32	65,63	60,20	94,50	63,78	76,87
	E_3	34,63	2,56	36,00	9,70	1,71	30,68	34,37	39,80	5,50	36,22	23,13
	N_3	0,15	5,78	6,10	0,22	2,88	1,58	0,61	2,67	5,36	4,07	2,94

Błędy klasyfikacji dla przykładowego obrazu testowego pokazane zostały na rys. 4.1.



Rys. 4.1. Błędy klasyfikacji: a) przykładowy obraz testowy, b) – d) błędy E (kolor czerwony) i N (kolor niebieski) odpowiednio dla roślin, papieru, plastiku i kamery 128-kanalowej, e) – g) analogiczne błędy dla kamery 16-kanalowej – wariant 2 [opracowanie własne]

Na rys. 4.2. pokazano wyniki klasyfikacji trudniejszej sceny zawierającej obiekty w różnych odcieniach zieleni należące do trzech rozważanych klas. We wszystkich testowanych wariantach plastikowy obiekt znajdujący się w środku klasyfikowany jest poprawnie, mimo iż jego barwa jest bardzo podobna do kartek papieru umieszczonych w górnych rogach obrazu. Szczególnie obiecujące są wyniki otrzymane dla kamery multispektralnej z kanałami rozmieszczonymi równomiernie (rys. 4.2.d). W tym przypadku wszystkie widoczne w scenie obiekty zostały poprawnie zidentyfikowane.



Rys. 4.2. Wyniki klasyfikacji obrazu zawierającego obiekty w odcieniach zieleni: a) wejściowy obraz kolorowy (wygenerowany na podstawie przetwarzanego obrazu hiperspektralnego), b) wyznaczone ręcznie obszary odpowiadające związkom organicznym (kolor zielony), papierowi (kolor niebieski), plastikowi (kolor czerwony) oraz wynik identyfikacji dla c) kamery 128-kanalowej, d) kamery 16-kanalowej w wariancie 1 i e) kamery 16-kanalowej w wariancie 2 [opracowanie własne]

5. Podsumowanie

Wyniki eksperymentów pokazują, że w przyjętych warunkach oświetlenia możliwa jest identyfikacja badanych materiałów z wykorzystaniem zarówno kamery 128-kanalowej, jak i kamery 16-kanalowej w obu rozpatrywanych wariantach rozmieszczenia kanałów. Rezultaty badań pokazują zbliżoną skuteczność dla wszystkich trzech konfiguracji przyrządów pomiarowych. Najlepsze wyniki osiągnięte zostały dla kamery 16-kanalowej z kanałami rozmieszczonymi równomiernie w całym rozpatrywanym paśmie. W tym przypadku średnio 86,2% pikseli zostało zakwalifikowanych poprawnie. Dla kamery 16-kanalowej w wariancie 2 osiągnięto skuteczność 85,3% zaś dla kamery 128-kanalowej – 84,6%. Wyniku tego nie należy jednak przyjmować z zaskoczeniem, bowiem już w trakcie analizy danych wyraźnie dało się zauważyć, że badane obiekty posiadają cechy dystynktywne w wybranych przedziałach długości fali i analiza danych uzyskanych dla wszystkich 128 kanałów w pełnym rozpatrywanym zakresie spektralnym może zaburzać wyniki klasyfikacji.

Dla niektórych testowanych obiektów należących do klas plastik i papier obserwowano wyniki nieco gorsze od podanych wartości średnich. Skuteczność metody w rozumieniu procentu pikseli zakwalifikowanych poprawnie spadała wtedy poniżej 70%. Świadczy to o tym, że obiekty te mogą sprawiać szczególne trudności w przypadku implementacji zaproponowanej metody w rzeczywistym otoczeniu przemysłowym. Szczególnie dobrze zaproponowana metoda radzi sobie natomiast z obiektami z klasy związków organicznych osiągając w przeważającej ilości przypadków wyniki na poziomie ponad 90%.

W ramach dalszych prac nad rozwijaną metodą autorzy planują zwiększenie liczby testowanych materiałów, badanie skuteczności opracowanej metody w różnych warunkach oświetlenia, zastosowanie różnych klasyfikatorów oraz opracowanie optymalnego sposobu wyboru kanałów w przypadku kamery o ograniczonej liczbie pasm.

Literatura

1. Petra Tatzer, Markus Wolf, Thomas Panner: Industrial application for inline material sorting using hyperspectral imaging in the NIR range. *Real-Time Imaging* 11, 2. Academic Press, 2005, s. 99-107.
2. Artzai Picón, Ovidiu Ghita, Pedro M. Iriondo, Arantza Bereciartua, Paul F. Whelan: Automation of waste recycling using hyperspectral image analysis. *Emerging Technologies and Factory Automation (ETFA) Conference*. IEEE, 2010, s. 1-4.
3. Bonifazi G., Serranti S., Bonoli A.: Innovative Recognition-Sorting Procedures Applied to Solid Waste: The Hyperspectral Approach. *Sustainable Development and Planning IV* vol. 2. WIT Press, 2009, s. 885-894.
4. Artzai Picón, Ovidiu Ghita, Paul F. Whelan, Pedro M. Iriondo: Fuzzy Spectral and Spatial Feature Integration for Classification of Nonferrous Materials in Hyperspectral Data. *IEEE Transactions on Industrial Informatics*, 5 (4). IEEE, 2009, s. 483-494.
5. Glenn Healey, David Slater: Models and Methods for Automated Material Identification in Hyperspectral Imagery Acquired Under Unknown Illumination and Atmospheric Conditions. *Geoscience and Remote Sensing*, IEEE Transactions vol. 37, no. 6. IEEE, 1999, s. 2706 - 2717.
6. Joan Vilaa, Javier Calpea, Filiberto Plab, Luis Gómezza, Joseph Connellc, John Marchantd, Javier Callejae, Michael Mulqueenf, Jordi Muñozza, Arnoud Klarenb: SmartSpectra: Applying multispectral imaging to industrial environments. *Real-Time Imaging Volume 11, Issue 2*. Elsevier, 2005, s. 85–98.
7. Keshava, N.: Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 7. IEEE, 2004, s. 1552 – 1565.
8. Chein-I Chang: *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Springer Science & Business Media, 2003.
9. Da-Wen Sun: *Hyperspectral Imaging for Food Quality Analysis and Control*. Academic Press, 2010, s. 50.
10. Brian C. Smith: *Fundamentals of Fourier Transform Infrared Spectroscopy*. CRC Press, 2011.
11. Gary Bradski: *Learning OpenCV. Computer Vision with the OpenCV Library*. O'Reilly, 2008.
12. <http://surfaceoptics.com/products/hyperspectral-imaging/>

*Badania realizowane w ramach Projektu "Zbadanie możliwości śledzenia, identyfikacji i kontroli jakości przy użyciu 16-32 kanałowej kamery do obrazowania spektralnego w zakresie 400-1000 nm",
Nr WDRPPK.01.03.00-18-044/13 współfinansowanego ze środków Unii Europejskiej z Europejskiego
Funduszu Rozwoju Regionalnego oraz Budżetu Państwa w ramach
Regionalnego Programu Operacyjnego Województwa Podkarpackiego.
Inwestujemy w rozwój województwa podkarpackiego.*

