

## **Automatyczna interpretacja obrazów z kamery ADS40 dla celów kontroli teledetekcyjnej upraw w systemie IACS**

*Streszczenie.* Przy kontroli wniosków rolników o dopłaty bezpośrednie wykorzystuje się również, oprócz kontroli na miejscu, metody teledetekcyjne. Jest to poważne zadanie i wyzwanie przed którym staje polska fotogrametria i teledetekcja. Danymi źródłowymi są zdjęcia lotnicze (czarno-białe i kolorowe) wykonane w różnych skalach oraz wysokorozdzielcze obrazy satelitarne. W referacie przedstawiono wstępne wyniki oceny przydatności obrazów wykonanych fotogrametryczną kamerą cyfrową ADS40 dla celów kontroli teledetekcyjnej, sprawdzono skuteczności automatycznej klasyfikacji oraz możliwość jej poprawy wykorzystując różnego rodzaju filtry „adaptive”.

### **1. Wprowadzenie**

Zasady budowy „polskiego IACS-u” reguluje ustawa o krajowym systemie ewidencji producentów, ewidencji gospodarstw rolnych oraz ewidencji wniosków o przyznanie płatności dnia 18 grudnia 2003 r. W wyniku negocjacji z Unią Europejską i zgodnie z postanowieniami traktatu akcesyjnego „polski IACS” tworzony jest według zasad obowiązujących dla uproszczonego (obszarowego) systemu dopłat bezpośrednich z możliwością dokonania dopłat uzupełniających dla wybranych rodzajów upraw. W obu przypadkach podstawą naliczania ich wysokości jest powierzchnia gruntu zgłoszonego i uprawnionego do dopłat. Przy budowie systemu identyfikacji działek (ang. LPIS- Land Parcel Identification System) za działkę odniesienia przyjęto działkę ewidencyjną, a bazę referencyjną w systemie stanowi baza danych opisowych ewidencji gruntów i budynków.

Przewiduje się, że około 5.5% wniosków rolników będzie podlegało kontroli. W pierwszej kampanii kontrolnej (zakończonyj 15 września 2004 roku) stosowane były dwie metody kontroli: tradycyjna inspekcja terenowa oraz teledetekcyjna połączona z terenową weryfikacją upraw ( ang. RFV – rapid field visit), [Podlewski 2004].

Kraje członkowskie, w których obowiązuje inny niż w Polsce system płatności, bardzo chętnie korzystają z kontroli teledetekcyjnej, która jest metodą tańszą od klasycznej (o ile posiada się gotową ortofotomapę całego kraju oraz mapę katastralną w postaci wektorowej), pracując wyłącznie na zdjęciach i ograniczając kontrole terenowe. Niestety stosowanie tego typu kontroli w Polsce nie jest jeszcze możliwe, ponieważ potrzebny jest LPIS stworzony w technologii GIS-owej, którego Polska jeszcze nie posiada i który ma być gotowy zgodnie z harmonogramem za 2 lata. Mimo wszystko już teraz należy brać pod uwagę możliwość wykorzystania tego typu kontroli w przyszłości.

W przypadku Polski, tegoroczna kontrola teledetekcyjna polegała jedynie na ustaleniu powierzchni na podstawie ortofotomapy, natomiast na miejscu (w terenie)

przewodzona była kontrola rodzaju upraw oraz spełnienia wymagań dobrej kultury rolnej. Był to swego rodzaju pilotaż, którym objęte zostało 5 obiektów o łącznej powierzchni około 2 tys km<sup>2</sup> obejmującej około 10 000 gospodarstw. Do kontroli wykorzystywano wysokorozdzielcze ortofotografie z satelity Quickbird, Ikonos oraz archiwalne ortofotomapy (z roku 2003), [Podlewski 2004].

Artykuł stanowi syntezę pracy dyplomowej wykonanej na Wydziale Geodezji Górniczej i Inżynierii Środowiska Akademii Górniczo-Hutniczej w Krakowie przez M. Chojowską pod kierunkiem W. Mierzwy [Chojowska 2004].

W analizie oparto się na danych pochodzących z Francji, ale wydaje się, że pewne wnioski mogą znaleźć zastosowanie również do warunków występujących w Polsce.

## **2. Cyfrowa kamera lotnicza ADS40 (Airborne Digital Sensor)**

Od kilku lat czołowe firmy na rynku producentów kamer lotniczych prowadzą prace nad lotniczymi kamerami cyfrowymi dającymi obrazy zbliżone pod względem jakości geometrycznej i radiometrycznej do zdjęć wykonywanych tradycyjnymi kamerami fotogrametrycznymi. Obecnie istnieje już kilka takich kamer np. modułowa kamera cyfrowa DMC 2001 (firmy Z/I Imaging), lotnicza kamera cyfrowa HRSC (Niemieckie Centrum Kosmiczne DLR) czy lotnicza kamera cyfrowa ADS40 (firmy LH Systems).

W pracy zostały wykorzystane zdjęcia wykonane cyfrową kamerą lotniczą ADS40. Kamera ta jest na rynku fotogrametrycznym od niedawna i ciągle jeszcze jest na etapie badań wszystkich jej możliwości. Bardzo dobre parametry techniczne, duża rozdzielczość i możliwość rejestracji wielospektralnych obrazów, sprawia, że kamera ta staje się coraz bardziej popularna wśród zachodnich firm fotogrametrycznych. Szczególnie interesująca jest możliwość wykorzystania wielospektralnych obrazów wykonanych tą kamerą do klasyfikacji automatycznej.

Głównym celem pracy było sprawdzenie przydatności kamery cyfrowej ADS40 pod względem teledetekcyjnym, a więc jaka jest dokładność klasyfikacji obrazów kamery ADS40 oraz czy jej wyniki mogą zostać wykorzystane przy automatycznej identyfikacji działek rolnych przy sprawdzaniu wniosków o dopłaty.

Zasada działania kamery i jej budowa są szeroko opisane w literaturze i nie będą tutaj omawiane, [Kurczyński 1999, 2000, Sandau i inni 2000].

W użyciu są też wykonane na zamówienie inne wersje kamery. Hanneman [Hanneman, 2004] przedstawił zmodyfikowaną kamerę ADS40 posiadającą 10 liniiek sensorów: 3\*PAN, 2\*(RGB), IR. O rozdzielczości radiometrycznej 12 bit (4096 wartości na kanał).

Wyznaczenie elementów orientacji zewnętrznej - kluczowe dla konstrukcji typu skaner - przestało być problemem dzięki zintegrowaniu dwóch systemów: GPS i INS (Inertial Navigation System). System GPS pozwala rejestrować trajektorię lotu (X, Y, Z) natomiast Inercjalny system nawigacyjny INS mierzy przyspieszenia wzdłuż trzech osi oraz zmiany kątowych pochyleń kamery. Ciągłe integrowanie (sumowanie)

tych pomiarów w czasie pozwala wyznaczyć bardzo dokładnie trajektorię lotu samolotu (z błędem rzędu 2 cm) i kąty pochyleń.

### **3. Dane wykorzystane w pracy.**

Wszystkie dane wykorzystane w pracy zostały udostępnione przez Wspólnotowe Centrum Badawcze Unii Europejskiej (JRC - Joint Research Centre), jednostkę Agriculture and Fisheries (stara nazwa MARS – Monitoring Agriculture with Remote Sensing).

Na dane składały się:

- 1) Zobrazowania kamery cyfrowej ADS40 – zdjęcia pozyskane w maju 2003 roku na terenie południowej Francji. Analizie poddano, obszar 48 km<sup>2</sup> (6 km na 8 km), Zdjęcia wykonano w skali około 1:80 000. Rozmiar piksela terenowego wynosił 50cm, obrazy stanowiły prawdziwe ortofotomapy (ang. True Ortho), z precyzyjną korekcją geometryczną (błąd średni około 0.5 - 0.75m).Pozyskane dane są wielospektralne, zawierają kanały: panchromatyczny, RGB i bliskiej podczerwieni.
- 2) Próbki terenowe podstawowych upraw rolnych zebrane w okresie pozyskiwania obrazów. Dane te w postaci wektorowej z podłączoną bazą danych (\*.shp, \*.dbf), zawierają dodatkową dokumentację w postaci zdjęć przedstawiających poszczególne uprawy.
- 3) Dane z francuskiego LPIS-u - wnioski od francuskich rolników zawierające informację na temat zgłoszonego rodzaju uprawy dla danej działki.

Całość prac można podzielić na trzy podstawowe etapy:

- Przeprowadzenia standardowej klasyfikacji automatycznej stosując klasyfikację nadzorowaną – algorytm maksymalnego prawdopodobieństwa.
- Analizy możliwości poprawy rezultatów klasyfikacji przy zastosowaniu różnego rodzaju filtrów „adaptive”.
- Porównanie wyników automatycznej klasyfikacji z rzeczywistymi danymi z francuskiego LPIS-u (wnioski rolników).

Większość prac została przeprowadzona przy wykorzystaniu programów ENVI, ArcView, IDRISI. Dodatkowo zostały wykorzystane programy PCI oraz Erdas do wstępnego przygotowania danych oraz licznych konwersji formatów.

### **4. Automatyczna klasyfikacja nadzorowana – algorytm maksymalnego prawdopodobieństwa.**


Po przeanalizowaniu współczynników korelacji międzykanałowej oraz miar statystycznych dla par sygnatur pól treningowych podjęto decyzję o zastosowaniu wszystkich czterech kanałów spektralnych do klasyfikacji obrazu.

Wyodrębniono 14 rodzajów klas:

1. zboże
2. kukurydza / słoneczniki (nie było różnicy spektralnej pomiędzy tymi dwoma uprawami, dlatego zostały one połączone, a dla ułatwienia, w dalszej części pracy będzie

wykorzystana tylko nazwa „kukurydza”).

3. trawa
4. trawa ścięta
5. bagno
6. kanał (woda)
7. szklarnie
8. tereny zakrzaczone
9. las
10. nieużytki
11. gleba
12. skała wapienna
13. drzewka oliwne
14. drzewka owocowe.



Rys. 3. Obraz po klasyfikacji algorytmem maksymalnego prawdopodobieństwa.

Podstawą do oceny dokładności wykonanej klasyfikacji było porównanie obrazu testowego (złożonego z pól testowych) zawierającego „prawdziwy” obraz pokrycia terenu z wynikiem klasyfikacji poprzez nałożenie obu obrazów zapewniające porównywanie atrybutów odpowiadających sobie pikseli. Pozwoliło to na zbudowanie tzw. „macierzy błędów”, która przedstawia statystykę zgodności między klasami porównywanych obrazów. **Pola testowe** (piksele kontrolne, odniesienia) stanowiły reprezentatywne powierzchnie o jednoznacznej identyfikacji pokrycia terenu. Pola te zostały wyznaczone w oparciu o zinterpretowaną kompozycję barwną jak również z wykorzystaniem innych wiarygodnych źródeł danych (włącznie z wywiadem terenowym – próbki terenowe) o elementach pokrycia rozważanego obszaru.

W pracy wykorzystano dwa rodzaje pól testowych:

- **pola testowe** zlokalizowane przez użytkownika na podstawie próbek terenowych, wybierane równoległe z polami treningowymi (w przypadku klasyfikacji nadzorowanej)
- **losowe próbki testowe** wybierane losowo spośród wszystkich pól testowych za pomocą określonego algorytmu. W tym przypadku wykorzystano algorytm **proporcjonalny** (ang. Stratified Random Sample) – program dzieli wszystkie pola na grupy i spośród nich wybierane są pojedyncze, losowo wybrane próbki, ich wielkość i ilość jest proporcjonalna do ilości wszystkich pól w danej klasie.

Stworzona została macierz błędów według której obliczono:

- całkowitą dokładność
- index kappa
- błąd nadmiaru (commission error)
- błąd pominięcia (omission error)

Ocena dokładności wyników klasyfikacji została przedstawiona w tabeli nr 1

Tabela nr 1

Porównanie oceny dokładności wykonanej dla oryginalnego obrazu i dla obrazu po filtracji filtrem Frost [7x7], wykorzystując pola testowe.

Stosując pola testowe		Obraz oryginalny				Frost Filter [7x7]			
Całkowita dokładność		80.9444%				89.0439%			
Kappa index		0.7931				0.8809			
Nr	Klasa	Poprawnie sklasyfikowane [%]	Błąd nadmiaru [%]	Błąd pominięcia [%]	Ilość [%]	Poprawnie sklasyfikowane [%]	Błąd nadmiaru [%]	Błąd pominięcia [%]	Ilość [%]
1	zboże	<b>49.91</b>	19.57	<b>50.09</b>	<b>5.49</b>	<b>73.24</b>	35.34	<b>26.76</b>	<b>10.0</b>
2	kukurydza	93.04	6.13	6.96	11.2	95.26	0.16	4.74	10.8
3	trawa	81.19	33.15	18.81	<b>9.23</b>	58.41	23.48	41.59	<b>5.80</b>
4	trawa ścięta	92.31	5.95	7.69	6.22	97.88	0.81	2.12	6.25
5	bagno	76.31	17.83	23.69	7.44	90.99	5.86	9.01	7.75
6	kanał	100.00	0.78	0.00	8.65	100.00	0.00	0.00	8.59
7	szklarnie	71.54	11.85	28.46	3.55	83.46	6.47	16.54	3.90
8	tereny zakrzewione	69.64	29.94	30.36	5.61	81.25	7.14	18.75	4.94
9	las	63.23	46.67	36.77	5.80	95.53	20.34	4.47	5.86
10	nieużytek	85.25	11.49	14.75	7.90	99.59	14.13	0.41	9.51
11	gleba	98.09	0.83	1.91	12.2	100.00	0.00	0.00	12.3
12	skała	85.58	36.73	14.42	7.09	95.19	21.64	4.81	6.37
13	d. oliwne	72.05	35.29	27.95	4.28	77.29	8.76	22.71	3.26
14	d. owocowe	58.45	47.63	41.55	5.33	81.69	15.64	18.31	4.62

Całkowita dokładność klasyfikacji wyniosła 80%. Największy problem stanowiło rozróżnienie *zboża* i *trawy*, które wyglądały bardzo podobnie szczególnie, że zdjęcia zostały wykonane w połowie maja. Analizując macierz błędów można było zauważyć, że bardzo duży procent *zboż* został niepoprawnie sklasyfikowany jako trawa. Widać to po bardzo dużej wartości błędu pominięcia dla *zboż* (50%) i stosunkowo dużej wartości błędu nadmiaru dla *traw* (ponad 30%).

## 5. Analiza możliwości poprawy rezultatów klasyfikacji przy zastosowaniu różnego rodzaju filtrów typu „adaptive”.

Filtry „adaptive” są dosyć szczególnymi filtrami, oparte są na metodzie *cyfrowego filtru splotowego*, ale wykorzystywane są przede wszystkim do filtracji obrazów radarowych charakteryzujących się licznymi szumami (ang. *speckle*). Filtry „adaptive” usuwają te szумы, przy jednoczesnym zachowaniu krawędzi, wygładzają obraz, ale bez usuwania krawędziowych i ostrych cech obrazu, takich jak linie (granice działek). Działają podobnie jak filtry dolnoprzepustowe, ale nie powodują pogorszenia się rozdzielczości obrazu.

Bardzo istotnym elementem w wykorzystaniu automatycznej klasyfikacji dla celów CAPI (fotointerpretacji wspomaganą komputerowo) jest otrzymanie w wyniku klasyfikacji odpowiedniego procentu „czystych” pikseli w granicach danej działki rolnej (70% - 80%). Problemem jest, że tego typu obrazy, charakteryzują się bardzo wysoką rozdzielczością, a co się z tym wiąże – są bardzo szczegółowe, z wieloma detalami, co powoduje wysoką różnorodność w zasięgu granic działek. Dlatego właśnie jednym z zadań pracy było sprawdzenie czy tego rodzaju filtry potrafią poprawić wyniki automatycznej klasyfikacji dla wysokorozdzielczych obrazów, przez wygładzenie tego typu szczegółów bez usunięcia granic działek.

Sprawdzono następujące rodzaje filtrów „adaptive”:

- *Frost Filter*
- *Lee Filter*
- *Gamma Filter*
- *Enhanced Frost Filter* (Ulepszony Frost Filter)
- *Enhanced Lee Filter* (Ulepszony Lee Filter)

Każdy z tych filtrów ma swój unikalny algorytm, ale wszystkie oparte są na obliczeniach powiązanych z odchyleniem standardowym, różnice między nimi są właściwie nieznaczne. Przeprowadzono filtrację obrazów ADS40 filtrami „adaptive” o różnych wielkościach okien filtrujących: 5x5, 7x7, 9x9, 11x11.

Jednym z czynników wskazujących na możliwość poprawy wyników klasyfikacji poprzez uprzednie zastosowanie filtrów „adaptive” było obliczenie odległości *Jeffries-Matusita* pomiędzy wybranymi klasami dla obrazu oryginalnego jak i dla obrazu po filtracji. Odległość JM występuje w przedziale od 0 do 2. Najlepsze wyniki rozłączności pomiędzy klasami przyjmuje się dla wartości 2 natomiast najgorsze dla 0, przy czym za wartość graniczną wystarczającą dla klasyfikacji można przyjąć wartość 1.8.

W tabeli nr 2 przedstawiono obliczone odległości JM, ale tylko dla par klas o najgorszej rozłączności dla obrazu oryginalnego. Jak widać wszystkie wartości uległy poprawie po zastosowaniu filtrów „adaptive”, natomiast większość z nich (wszystkie zaznaczone na zielono) przekroczyły wartość graniczną 1.85. Niestety w dalszym ciągu nie uległa poprawie rozłączność pomiędzy zbożem i trawą, odległość JM jest najmniejsza pomiędzy tymi dwoma klasami (zaznaczona na biało).

Tabela nr 2  
Porównanie odległości JM dla obrazu oryginalnego i dla obrazu po filtracji filtrem Frost, rozmiar okna 7x7

Klasa	Klasa	Obraz oryginalny	Frost Filter [7x7]
Zboże	trawa	<b>0.78</b>	<b>1.09</b>
	t.zakrzaczony	1.10	1.75
	d.oliwne	1.83	<b>1.99</b>
	d. owocowe	1.20	<b>1.94</b>
Trawa	t.zakrzaczony	1.45	<b>1.85</b>
trawa ścięta	nieużytek	1.73	<b>1.96</b>
	skała	1.78	<b>2.00</b>
Las	bagno	1.69	<b>2.00</b>
	t.zakrzaczony	1.45	<b>2.00</b>
	nieużytek	1.43	<b>1.96</b>
drzewka oliwne	bagno	1.51	<b>1.97</b>
	t.zakrzaczony	1.56	<b>1.98</b>
	las	0.80	1.84
	nieużytek	1.81	<b>1.94</b>
	d. owocowe	1.36	<b>1.97</b>
drzewka owocowe	t. zakrzaczony	0.72	1.62
	las	1.68	<b>1.98</b>
	trawa	1.43	<b>1.94</b>

## 6. Rezultaty zastosowania filtrów „adaptive” w celu poprawy wyników automatycznej klasyfikacji.

Dla każdego obrazu przefiltrowanego różnymi rodzajami filtrów „adaptive”, z różnymi wielkościami okien, przeprowadzono automatyczną klasyfikację. Klasyfikacja została wykonana z takimi samymi założeniami jak w przypadku obrazu oryginalnego, stosując te same pola treningowe oraz algorytm maksymalnego prawdopodobieństwa. Porównano wyniki klasyfikacji dla:

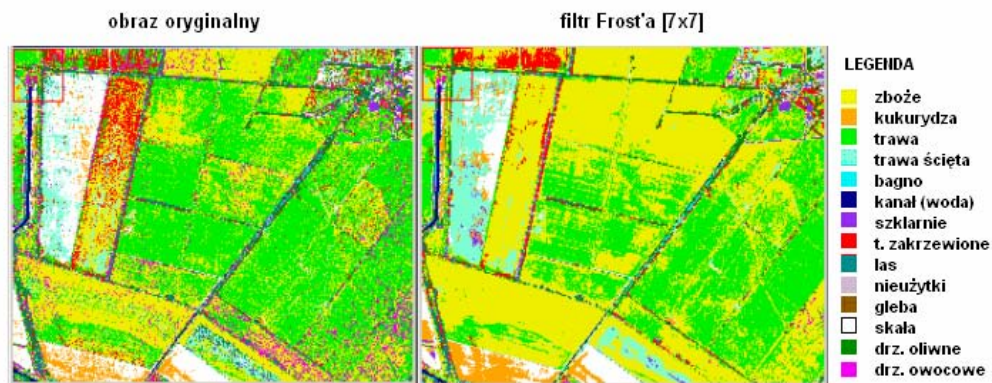
- obrazów oryginalnych i obrazów po zastosowaniu filtracji „adaptive”,
- różnych rodzajów filtrów,
- różnych wielkości okien filtrujących.

Poniżej przedstawiono przykład sklasyfikowanego obrazu po filtracji filtrem Frost, rozmiar okna 7x7.

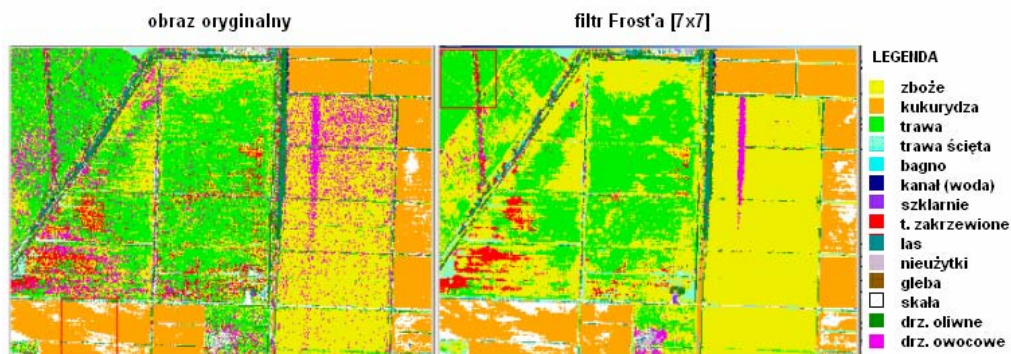


Rys.4. Sklasyfikowany obraz po zastosowaniu filtru Frost, rozmiar okna 7x7.

Sklasyfikowany obraz po zastosowaniu *filtrów „adaptive”* wygląda dużo lepiej niż dla obrazu oryginalnego. Uprawy w granicach działek są bardziej jednolodne a obraz posiada mniej „ziarnistą” strukturę. Szczegółowe porównanie sklasyfikowanych obrazów przed i po zastosowaniu filtrów „adaptive”, przedstawiono w powiększeniu poniżej.



Rys.5. Porównanie sklasyfikowanych obrazów: oryginalnego i po filtracji filtrem Frost [7x7]. [7x7], wykorzystując pola testowe



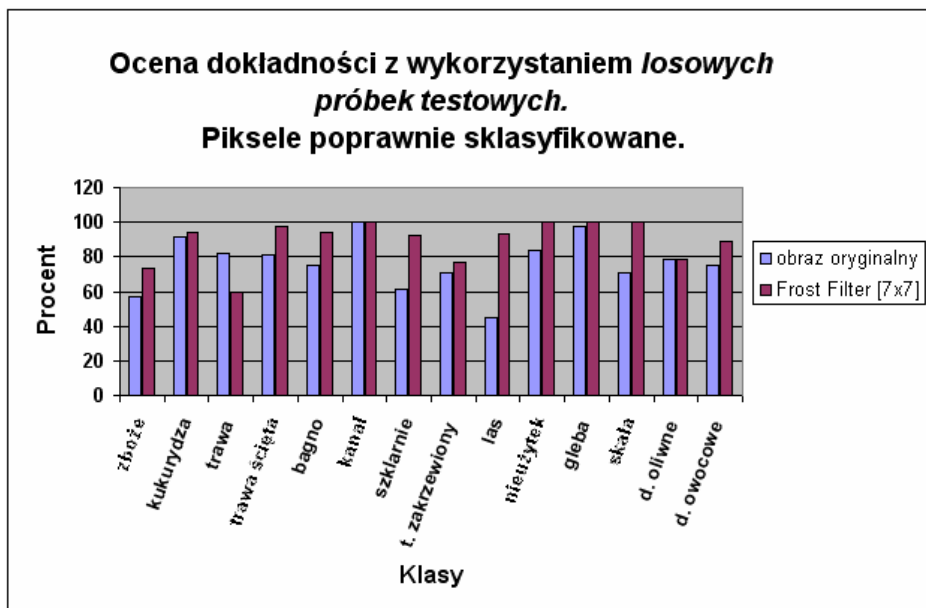
Rys.6. Porównanie sklasyfikowanych obrazów: oryginalnego i po filtracji filtrem Frost [7x7].



Analizując „macierz błędów” dla sklasyfikowanych obrazów po zastosowaniu filtrów „adaptive”, widać znaczącą poprawę rezultatów automatycznej klasyfikacji. Ocenę dokładności przeprowadzono wykorzystując te same **polo testowe** oraz **losowe próbki testowe** jak w przypadku oceny klasyfikacji przeprowadzonej dla oryginalnego obrazu.

Najlepsze wyniki zostały osiągnięte po zastosowaniu filtrów: *Frost*, *Gamma*, *Enhanced Frost* i *Enhanced Lee* z rozmiarem okna 7x7, po ich zastosowaniu całkowita dokładność poprawiła się z 80.9% do 89.0%, natomiast Kappa index wzrósł się z 0.79 do 0.88.

Szczegółowe różnice oceny dokładności wykonanej dla oryginalnego obrazu i dla obrazu po filtracji filtrem *Frost* [7x7] stosując pola testowe przedstawiono w tabeli nr 2, natomiast ocenę dokładności wykonaną przy pomocy losowych próbek terenowych przedstawiono w formie wykresu



Rys.7. Porównanie ilości pikseli poprawnie sklasyfikowanych po klasyfikacji obrazu oryginalnego i obrazu po filtracji filtrem *Frost* [7x7].

Różnica pomiędzy wyżej wymienionymi filtrami była nieznaczna ale analizując bardzo szczegółowo wyniki, najlepsze rezultaty zostały osiągnięte po filtracji filtrem *Frost*, z rozmiarem okna 7x7.

Tabela nr 3

Porównanie różnych wielkości okien filtrujących

	Frost Filter [5x5]	Frost Filter [7x7]	Frost Filter [9x9]	Frost Filter [11x11]
Całkowita dokładność	88,59%	89,04%	88,34%	86,34%
Kappa index	0,876	0,8809	0,8732	0,8515

Porównanie różnych rodzajów filtrów „adaptive”

	<i>Frost Filter</i>	<i>Gamma Filter</i>	<i>Enhanced Lee (Frost) Filter</i>	<i>Lee Filter</i>
Całkowita dokładność	89,04%	89,04%	89,03%	85,94%
Kappa index	0,881	0,8809	0,8807	0,8473

## 7. Porównanie wyników klasyfikacji automatycznej z rzeczywistymi danymi

Ostatnim etapem praktycznej części pracy było porównanie wyników automatycznej klasyfikacji z rzeczywistymi danymi z francuskiego LPIS-u, wniosków od rolników. Porównanie danych polegało na nałożeniu działek w postaci wektorowej na sklasyfikowany obraz, zliczenie pikseli poszczególnych klas w obrębie wektora działki a następnie wybór tylko tych działek, w obrębie których piksele odznaczają się jednorodnością. W przypadku klasyfikacji, względna liczba pikseli wewnątrz granic działek określa czy dana działka przynależy do danej klasy użytków gruntowych, czy też nie. Na przykład, jeżeli 80 % pikseli wewnątrz granicy należy do klasy „kukurydza”, można przyjąć, że dana działka została zaklasyfikowana jako kukurydza i dopiero wtedy można dokonać porównania z klasą zgłoszonej przez rolnika uprawy.


Niestety nie ma przyjętych norm określających procentowy próg jednorodności wewnątrz działki, jednak nie powinno być to mniej niż 70%. W pracy, przy wyborze działek charakteryzujących się jednorodnością pikseli w obrębie granic przyjęto 70% próg.



Rys.8. Zasada wyboru działek z jednorodną uprawą.

Niestety działki podlegające sprawdzeniu są tak zwanymi ilotami. Pojęcie to występuje we Francji, są to działki rolne należące do jednego rolnika, ale w obrębie których może występować więcej niż jedna uprawa. Niestety uprawy wewnątrz działki nie były wektoryzowane, co uniemożliwiło ich porównanie z wynikami klasyfikacji, nieznana była także powierzchnia poszczególnych upraw.

Ostatecznie, po usunięciu działek z wieloma uprawami do porównania pozostało tylko 65 działek rolnych (rys.9.).



Rys.9. Badany obszar z nałożonymi 65 działkami, dla których zostanie dokonane porównanie zgłoszonych upraw z wynikami klasyfikacji.

Wyniki przedstawione zostały w tabeli nr 5.

Tabela nr 5

Porównanie wyników klasyfikacji automatycznej z rzeczywistymi danymi

	Działki charakteryzujące się 70% jednorodnością pikseli w obrębie granic	Ilość wniosków zgodnych z wynikami klasyfikacji
Obraz oryginalny	17%	87%
Obrazu po filtracji filtrem Frost [7x7]	30%	80%

## 8. Wnioski

W wyniku przeprowadzonych badań osiągnięto dość dobre rezultaty dla automatycznej klasyfikacji wykonanej na zobrażowaniach kamery cyfrowej ADS40. Przetworzenie oryginalnych zdjęć filtrami typu „adaptive” powoduje wzrost dokładności klasyfikacji z 80% do 89%.

Wyniki te są stosunkowo dobre biorąc pod uwagę fakt, że klasyfikacja została przeprowadzona tylko na obrazie z jednego nalotu. Dodatkowo, zdjęcia zostały wykonane w połowie maja, a obszar badań w większości pokryty był przez *trawy* i *zboża*, które w tym okresie wyglądają bardzo podobnie. Dlatego też, większość problemów występujących podczas klasyfikacji dotyczyła rozróżnienia tych dwóch klas, których odpowiedzi spektralne były bardzo zbliżone.

Po wykonaniu klasyfikacji obrazu oryginalnego, znaczna część *zboż* została błędnie sklasyfikowana jako *trawy*, zastosowanie *adaptive filter* poprawiło sytuację, ale mimo to dokładność klasyfikacji dla tych dwóch klas jest najgorsza.

Pod względem oceny dokładności zobrazowań kamery ADS40, wyniki klasyfikacji, szczególnie po zastosowaniu filtrów „adaptive”, przedstawiają się bardzo dobrze. Ocena zmienia się, gdy weźmie się pod uwagę wykorzystanie zdjęć do identyfikacji upraw działek rolnych dla systemu IACS.

Wysoka rozdzielczość, a co się z tym łączy duża różnorodność pikseli w obrębie granic działek rolnych, powodują, że nieznaczna część sklasyfikowanych działek kwalifikuje się w przyjętym 70% progu jednorodności. Niestety zdjęcia zostały wykonane w okresie, kiedy nie ma widocznej różnicy pomiędzy *trawą* a *zbożem*, dlatego znaczna część działek zawiera wymieszane piksele tych dwóch klas, nie mieszcząc się w 70% progu. Po zastosowaniu *adaptive filters*, procent działek spełniających 70% próg zwiększył się jedynie o 13% ( z 17% do 30% ).

Biorąc pod uwagę tak niski procent działek dla których jednoznacznie można stwierdzić użytkowanie gruntów, rola zobrazowań kamery ADS40 przy identyfikacji działek rolnych dla IACS znacznie maleje, nie można się całkowicie na nich opierać ale mogą one znacznie usprawnić proces CAPI.

Badania te są jedynie wstępem, wykorzystano tylko obrazy z jednego okresu (maj), co jest stanowczo niewystarczające do przeprowadzenia odpowiedniej klasyfikacji. Biorąc pod uwagę bardzo dobre wyniki oceny dokładności uzyskane tylko dla obrazów z jednego okresu, istnieje duża szansa na znaczną poprawę, również pod względem jednorodności, zastosowania klasyfikacji dla obrazów wieloczasowych.

Mimo że, zastosowanie filtrów „adaptive” w przypadku obrazów z kamery ADS40 przyniosło znaczną poprawę wyników klasyfikacji, sądzimy, że podobne badania należy sprawdzić również dla innych zobrazowań.

### **Bibliografia**

Kurczyński Zdzisław, 1999 „Zmierzch tradycyjnej kamery lotniczej?”, GEODETA Magazyn Geoinformacyjny, nr 11 (54), listopad 1999,

Kurczyński Zdzisław, 2000 „Nowe wyzwania i szanse”, GEODETA Magazyn Geoinformacyjny, nr 12 (67), grudzień 2000.

Chojowska Monika 2004, “Automatyczna interpretacja obrazów z fotogrametrycznej kamery cyfrowej (ADS40) dla celów systemu IACS”- praca dyplomowa magisterska, Wydział Geodezji Górniczej i Inżynierii Środowiska, AGH – Kraków, lipiec 2004

Hanemann Klaus-Dieter 2004, „ Leica-Geosystems Digital Camera ADS40 and Laser Scanner ALS 50-83: Technology and First Results”, Materiały szkoleniowe, Seminarium X Międzynarodowych Targów GEA, Kraków wrzesień 2004

Podlewski Jacek 2004, “Podsumowanie kampanii kontrolnej wniosków o przyznanie płatności bezpośrednich do gruntów rolnych, kierunki rozwoju kontroli w kolejnych latach”, referat wygłoszony na Seminarium X Międzynarodowych Targów GEA, Kraków wrzesień 2004