


Zastosowania danych hiperspektralnych do klasyfikacji roślinności

Powyżej przedstawione wyniki klasyfikacji zbiorowisk roślinnych Tatr Wysokich, jak również Beskidu Niskiego (niepublikowane) wyraźnie potwierdzają przydatność sztucznych sieci neuronowych oraz obrazów hiperspektralnych do identyfikacji poszczególnych zbiorowisk. Uwzględnienie w analizie cech nie tylko spektralnych (fototon), lecz także strukturalnych i teksturalnych (powtarzających się układów poszczególnych pikseli oraz ich sąsiedztwo), pozwoliło uzyskać satysfakcjonujące wyniki klasyfikacji zbiorowisk, które mają często podobne cechy morfologiczne. Analiza poklasyfikacyjna opracowana na kilkuset tysiącach pikseli wykazała, że osiągnięta dokładność oscyluje na poziomie 80-90%; 29 na 42 analizowanych klas uzyskało dokładność producenta i użytkownika powyżej 80% (tab. 24). Oznacza to, że mapy poklasyfikacyjne mogą istotnie wspomagać fitosocjologów w terenowym kartowaniu roślinności. Teledetekcja, która zajmuje się ilościową oraz jakościową analizą odbitych sygnałów, nie jest predysponowana do tworzenia map roślinności rzeczywistej. Wynika to z różnych podejść metodycznych – podczas fitosocjologicznego kartowania zbiorowisk roślinnych zwraca się uwagę na gatunki charakterystyczne dla danej jednostki taksonomicznej. Natomiast z teledetekcyjnego punktu widzenia okazy tych roślin mogą być niewielkich rozmiarów i nie dawać wystarczająco silnej odpowiedzi spektralnej, która mogłaby zostać zarejestrowana przez detektor. C. Joshi, J. De Leeuw i A.K. Skidmore (2006) zwracają uwagę, że do pewnego stopnia rozwiązaniem tego problemu może być wykorzystanie danych hiperspektralnych, analiza subpikselowa oraz zastosowanie sztucznych sieci neuronowych i znajomość ekologii analizowanych zbiorowisk. Przeprowadzone badania wykazały 84% skuteczność klasyfikacji sieciami neuronowymi gatunków inwazyjnych zbiorowisk leśnych, których rozmiary nie stanowią znacznego udziału w koronach drzew (Joshi i inni, 2006).

Jedno z pierwszych opracowań bazujących na cechach spektralnych zbiorowisk roślinnych obszarów górskich wykonał zespół USGS (Stany Zjednoczone)

w roku 2003 (Kokaly i inni, 2003). Autorzy równolegle z lotniczym zobrazowaniem hiperspektralnym AVIRIS pozyskali charakterystyki spektralne dominujących zbiorowisk roślinnych Parku Narodowego Yellowstone. Informacje te posłużyły budowie lokalnej biblioteki spektralnej, która w następnym etapie została wykorzystana do analizy przedziałów absorpcji promieniowania przez poszczególne zbiorowiska (tzw. analiza *continuum removal*). Identyfikacja zakresów promieniowania oraz specyficznych cech spektralnych poszczególnych zbiorowisk pozwoliła na stworzenie map roślinności leśnych (ryc. 37A) i nieleśnych obszarów Parku (ryc. 37B). Przeanalizowane zostały 23 zbiorowiska leśne, każde z nich reprezentowane było przez 15-371 pikseli AVIRIS. Dla innego fragmentu Parku przeanalizowano 15 zbiorowisk nieleśnych (11-510 pikseli). Mapy końcowe zawierały 16 zbiorowisk (ryc. 37). Całkowita dokładność klasyfikacji wyniosła 74,1%, wskaźnik kappa – 0,62, dokładność producenta zawiera się w granicach 66,7-100%, natomiast użytkownika 51,4-93,2% (Kokaly i inni, 2003).

Metodykę badań zbliżoną do zastosowanej w niniejszym opracowaniu ma publikacja A.M. Filipiego i J.R. Jensena (2006) – dotyczy ona wykorzystania sztucznych sieci neuronowych oraz danych hiperspektralnych do badania roślinności rzeczywistej. Autorzy wykorzystali zobrazowanie hiperspektralne AVIRIS oraz symulator wielowarstwowy jednokierunkowy ze wsteczną propagacją błędów (MLP), samoorganizujące się sieci Kohonena (SOM) oraz symulator z rozmytym uczeniem FLVQ (Fuzzy Learning Vector Quantization) do klasyfikacji zbiorowisk łąkowych wybrzeża zlokalizowanego wokół Centrum Lotów J.F. Kennedy'ego na Florydzie. Teren badań cechowała bardzo duża różnorodność biologiczna, wynikająca z dużego zróżnicowania terenu, pokrytego wydmiami i bagnami. Występowały na nim 22 typy zbiorowisk kserotermicznych, suchych, świeżych i wilgotnych (Hall i inni, 1992). Końcowe klasyfikacje wykonane zostały na 11 typach zbiorowisk. Wielkość próbek wykorzystanych do uczenia sieci wahała się od 45 do 404 pikseli, dając w sumie 3089 pikseli.



Ryc. 37. Mapa roślinności Parku Narodowego Yellowstone (źródło: Kokaly i inni, 2003): A – leśnej gór Mount Washburn (Vigorous conifer regrowth – zdrowe lasy iglaste; moderate conifer regrowth – średnio zdrowe lasy iglaste (sukcesja wtórna), Lodgepole pine – sosna wydymowa (*Pinus contorta*), Douglas fir – daglezja (*Pseudotsuga menziesii*), Whitebark pine – sosna *Pinus albicaulis*, Spruce/fir – świerk/jodla, aspen – osika, conifer/meadow mix – drzewa iglaste na polanach); B – nieleśnej Lamar Valley (Fescue/wheatgrass – kostrzewa (*Festuca*)/pszenica, Fescue/needlegrass – kostrzewa (*Festuca*)/grupa traw rosnących w kępach i obejmująca: *Achnatherum*, *Aristida*, *Nassella*, *Stipa*, Sagebrush – *Artemisia tridentata*, Willow/Sedge – wierzby/turzyce, Willow – wierzby, Sedge and wetland – turzyce i bagna)





Fig. 37. The maps of: A – mountain forest cover of Mount Washburn area, B – nonforest cover of Lamar Valley (source: Kokaly et al., 2003)

Do weryfikacji dokładności wykorzystano 1645 pikseli. Wyniki klasyfikacji potwierdziły większą przydatność symulatorów SSN niż referencyjnej klasyfikacji hiperspektralnej MF (ryc. 38, tab. 26), a uzyskana dokładność klasyfikacji nadzorowanych jest porównywalna do

wyników uzyskanych w niniejszej pracy, czyli 84-86% (z tym, że w badaniach roślinności Tatr analizowanych było około 38 klas związanych z roślinnością, czyli 3 razy więcej niż w cytowanej pracy).



Ryc. 38. Porównanie wyników klasyfikacji sztucznymi sieciami neuronowymi: MLPCI – wielowarstwowym perceptronem ze wsteczną propagacją błędów; SOM2DCI – nienadzorowanej, samouczącej się sieci SOM; FLVQCI588 – z rozmytym uczeniem symulatora oraz MF – referencyjnej Matched Filtering (MF). Objasnienia jak w tabeli 26 (źródło: Filippi, Jensen, 2006, zmienione)
 Fig. 38. ANN classification results comparison: MLPCI – MLP with backpropagation errors; SOM2DCI – unsupervised SOM; FLVQCI588 – fuzzy learning algorithm; MF – reference MF classification (source: Filippi, Jensen, 2006, modified)

Tabela 26. Wyniki dokładności klasyfikacji (%) roślinności okolic Centrum Lotów J. F. Kennedy'ego
 Table 26. Classification accuracy (%) of surrounding vegetation of the JFK flight centre, Florida

Klasa Class	Samoorganizująca sieć SOM2DCI		Wielowarstwowy perceptron MLPCI		Sieć z rozmytym uczeniem FLVQCI588		Referencyjna klasyfikacja MF	
Dokładność całkowita Overall accuracy	73,26		86,05		84,38		64,55	
Wskaźnik kappa Kappa coefficient	70,55		84,66		82,82		61,00	
Dokładność znormalizowana Normalized accuracy	65,23		75,85		74,60		57,96	
	Dokł.prod. Prod. acc.	Dokł.użyt. User acc.	Dokł.prod. Prod. acc.	Dokł.użyt. User acc.	Dokł.prod. Prod. acc.	Dokł.użyt. User acc.	Dokł.prod. Prod. acc.	Dokł.użyt. User acc.
<i>Spartina bakeri</i> Merr. <i>Sand cordgrass</i>	73,81	77,50	75,00	90,91	78,95	100,00	52,27	76,67
<i>Pinus elliotii</i> Engelm. <i>Slash pine</i>	91,30	70,00	100,00	80,65	91,67	73,33	77,78	46,67
<i>Quercus virginiana</i> <i>Live oak hammock</i>	55,10	90,00	90,91	93,75	69,05	96,67	63,41	86,67
Gaje cytrusowe <i>Citrus grove</i>	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Winnice <i>Grape vine</i>	90,91	33,33	100,00	90,00	100,00	76,67	100,00	23,33
Zakrzaczenia <i>Unid shrub</i>	87,50	23,33	100,00	32,26	94,44	56,67	46,15	20,00
Wierzby <i>Willow community</i>	50,00	76,67	62,22	93,33	69,05	90,62	60,00	70,00
Trawy bagienne <i>Graminoid marsh</i>	69,70	76,76	87,50	70,00	92,00	76,67	67,65	76,67
<i>Sabal palmetto</i> (Walter) <i>Cabbage palm</i>	74,29	86,67	88,24	100,00	85,71	80,00	73,33	36,67
Busz <i>Serenoa repens</i> (Bartram) z udziałem dębów <i>Oak/Saw Palmetto scrub</i>	64,86	70,59	74,36	96,67	72,73	77,42	35,48	73,33
Sucha, spalona roślinność <i>Dry/burned vegetation</i>	100,00	100,00	100,00	100,00	100,00	100,00	96,77	100,00

Źródło: Filippi, Jensen 2006, zmodyfikowane.
 Source: Filippi, Jensen 2006, modified.

Podobna koncepcja pracy została wykorzystana do klasyfikacji zbiorowisk półnaturalnych terenów półpustynnych Namibii (Oldeland i inni, 2010). Oprócz zobrażenia HyMap autorzy do klasyfikacji wykorzystali także zestaw 8 wskaźników (zawartość chlorofilu, masy zielonej, lignin, celulozy oraz glinu i żelaza w glebie). Nadzorowana klasyfikacja została wykonana w symulatorze SFCM (*supervised fuzzy c-means classifier*; Lucieer, 2006). Uzyskane wyniki dokładności 7 zbiorowisk roślinnych są bardzo dobre, gdyż dokładność całkowita wyniosła 98,18%, a wskaźnik kappa 0,98 (ryc. 39).

Na uwagę zasługuje także opracowanie wykonane w ramach projektu Natura 2000 obszaru Kalmthoutse Heide (Belgia). Autorzy na podstawie kartowania terenowego oraz 63-kanalowego zobrażenia hiperspektralnego AHS sklasyfikowali 27 typów roślinności. Do tego celu wykorzystali rozmieszanie spektralne pikseli (*spectral unmixing*) oraz drzewo decyzyjne. Uzyskana dokładność całkowita wyniosła 0,84, a wskaźnik kappa 0,79 (Delalieux i inni, 2010).

W literaturze można znaleźć dość dużo publikacji dotyczących klasyfikacji różnych gatunków roślin

uprawnych. W opracowaniu zespołu z Uniwersytetu w Trewirze przeanalizowane zostały różne algorytmy klasyfikacji danych, bazujące na analizie głównych składowych PCA (dostępnych w środowisku ENVI). Skanerem HyMAP został zobrażony obszar rolniczy Bitburger Gutland znajdujący się w pobliżu miejscowości Newel w Niemczech (ryc. 40). Wyniki analiz są podobne do osiągniętych w niniejszej pracy, tj. klasyfikacja bazująca na oryginalnych danych (po korekcji atmosferycznej i geometrycznej) pozwoliła uzyskać dokładność 88,7%, wskaźnik kappa wyniósł 0,72. Zastosowanie danych skompresowanych (PCA²³) dało dokładność rzędu 84,6% (wszystkie kanały PCA) oraz 84,3% (wybrane kanały PCA). W przypadku obu klasyfikacji z wykorzystaniem danych PCA wskaźnik kappa wyniósł 0,63 (Mader i inni, 2006).

²³ W niniejszej pracy wykonana została kompresja MNF, która składa się najpierw z dekorelacji szumu na obrazie, a następnie tradycyjnej analizy głównych składowych PCA.






Tabela 27. Macierz transformacji klasyfikacji 15 kanałów MNF zobrazowania HyMAP

Table 27. Error matrix of the classification of HyMAP's 15 MNF bands

Klasy Classes	a	b	c	d	e	f	g	Całkowi- ty zestaw klasyfi- kacyjny Total result class.	Całkowi- ty zestaw uczący Total training class.	Dokł. prod. Prod. acc. %
a-kukurydza a-corn	69859	514	2	59	5	21	19	70479	19782	90,8
b-żyto ozime b-winter rye	108	75321	386	21732	32	143	246	97968	23030	93,5
c-jęczmień ozimy c-winter barley	215	309	89067	981	3073	54	381	94080	88333	98,3
d-pszenica ozima d-winter wheat	342	2862	5	143115	179	227	513	147243	125068	85,3
e-rzepak ozimy e-winter rape	351	400	171	268	116221	46	355	117812	132547	96,3
f-pastwiska f-pastures	5019	643	522	1276	874	64937	898	74169	129732	98,0
g-nieuzytki g-wasteland	1012	472	436	396	248	864	13847	17275	9376	85,2
Zestaw weryfikujący Total ground. truth	76906	80521	90589	167827	120632	66292	16259	619026	Dokładność całkowi- ta = 92,5% Overall accuracy = 92.5%	
Dokł. użyt. User acc. %	99,1	76,9	94,7	97,2	98,7	87,6	80,2			

Źródło: Olesiuk i inni, 2009, zmodyfikowane.

Source: Olesiuk i inni, 2009, modified.




Ryc. 41. Wynik klasyfikacji upraw rolniczych symulatorem sztucznych sieci neuronowych SNNS danych HyMAP: A – z wykorzystaniem wskaźników roślinnych, B – 15 kanałów MNF (źródło: Olesiuk i inni, 2009, zmodyfikowane)

Fig 41. Crop classification results of the SNNS simulator and HyMAP data: A – basing on hyperspectral bands and plant indices, B – 15 MNF bands (source: Olesiuk et al., 2009)


Powyższe wyniki znajdują potwierdzenie w pracach D. Olesiuka wykonanych w ramach stypendium DBU w DLR Oberpfafenhoffen (Olesiuk i inni, 2009). Autor przeanalizował dane HyMAP z rolniczego obszaru Demmin (północno-wschodnie Niemcy). Do klasyfikacji wykorzystał symulator SNNS, a jako dodatkowe warstwy informacyjne – wskaźniki roślinne, wygenerowane w środowisku ENVI z danych obrazowych HyMAP. Najlepsza dokładność klasyfikacji 7 upraw wyniosła 92,5%, natomiast wskaźnik kappa osiągnął wartość 0,91 (tab. 27, ryc. 41).

Dobrym przykładem wykorzystania danych hiperspektralnych AISA są klasyfikacje obrazów hiperspek-

tralnych terenów rolniczych na Półwyspie Miura, zlokalizowanych w pobliżu Tokio. Celem prac było wykonanie klasyfikacji 5 gatunków roślin uprawnych oraz 5 innych kategorii użytkowania (gleby, asfalt, beton, tereny zabudowane oraz wody). Różnica pomiędzy podejściem standardowym a zastosowanym w omawianej publikacji polegała na wydzieleniu wszystkich obiektów pokrytych roślinnością (maska z NDVI), następnie wykonaniu ekstrakcji obiektów poprzez decyzje przebiegu granic (*decision boundary feature extraction* – DBFE) i w kolejnym kroku klasyfikacji homogenicznych obiektów (ECHO), które połączono w poszczególne klasy metodą nadzorowanej klasyfikacji największego prawdopodobieństwa.



Ryc. 42. Wyniki klasyfikacji występowania jeżyn w Parku Narodowym Kościuszko w Australii (źródło: Dehaan i inni, 2007)
 Fig. 42. Classification results of spatial distribution of the *Rubus fruticosus* in Kosciuszko National Park in Australia (source: Dehaan et al., 2007)



Ryc. 43. Analiza składu gatunkowego. Podobnymi kolorami zaznaczono gatunki tworzące dane zbiorowisko. Czarnym tonem wymaskowane zostały wody oraz las. Diagramy przedstawiają tzw. niemetryczne, wielowymiarowe skalowanie (Non-Metric Multidimensional Scaling – NMS; Shepard, 1962), czyli prognozowane występowanie poszczególnych gatunków w analizowanym zbiorowisku. Rozmiar kropek w diagramie oznacza wielkość udziału gatunku w zbiorowisku. Osie diagramów: NMS1, NMS2, NMS3 wyrażają wartości odległości euklidesowej w skali logarytmicznej (Schmidtlein i inni, 2007)

Fig. 43. Species spatial distribution in community. By similar colours plant species, which create community were presented. Water and forest were masked by black areas. Diagrams present non-metric multidimensional scaling (NMS, Shepard, 1962). Size of dots presents the quantity of species in built community. Axes of diagrams (NMS1, NMS2, and NMS3) present the Euclidean distance in a logarithmic scale (Schmidtlein et al., 2007)

Uzyskana dokładność klasyfikacji wyniosła: dokładność całkowita 92,4%, wskaźnik kappa 0,914. Dokładność poszczególnych zbiorowisk wahała się od 79,5 do 100% (Lu i inni, 2007).

Innym przykładem kartowania geobotanicznego jest opracowanie dotyczące rozprzestrzeniania się w Australii inwazyjnego gatunku – jeżyny *Rubus fruticosus*. Obszar badań pokrywał teren Parku Narodowego Kosciuszko (NSW, Australia). Autorzy wykorzystali dane HyMAP oraz metody klasyfikacji dostępne w pakiecie ENVI (m.in. SAM, MTMF, MF, SFF) do identyfikacji zarośli jeżyn. Najlepsze wyniki uzyskano z klasyfikacji Mixture-Tuned Matched Filter (MTMF): dokładność producenta wyniosła 91%, użytkownika 81%, całkowita 92%, a wskaźnik kappa wyniósł 0,715 (ryc. 42; Dehaan i inni, 2007).

Gatunków inwazyjnych dotyczy także opracowanie bazujące na hiperspektralnych zobrazeniach satelitarnych Hyperiona (Tsai i inni, 2007). Biorąc za podstawę analizę głównych składowych (PCA), autorzy kartowali

występowanie inwazyjnego krzewu *Leucaena leucocephala* w południowym Tajwanie. Uzyskana dokładność całkowita klasyfikacji wyniosła 86%, a wskaźnik kappa 0,81 (Tsai i inni, 2007). Podobny poziom dokładności został uzyskany w trakcie klasyfikacji 2gatunków inwazyjnych w Stanach Zjednoczonych: wilczomleczka lancetowatego *Euphorbia esula* oraz chabry *Centaurea maculosa*. Oba gatunki, zawleczone z Europy do Ameryki, należą tam do bardzo uciążliwych. Kartowanie obu gatunków zostało wykonane za pomocą klasyfikacji Beimana Cutlera (*Beiman Cutler Classification* – BCC), która należy do grupy klasyfikacji lasu losowego (*Random Forest*). Rozdzielczość terenowa danych lotniczych Probe-1 wyniosła 5 m, a liczba kanałów 128. W zależności od terenu badań dokładność zawierały się w granicach od 66% do 93%, natomiast końcowa dokładność całkowita wyniosła 86% (Lawrence i inni, 2006; Wood i inni, 2006)²⁴.

²⁴ Więcej przykładów wykorzystania technik hiperspektralnych do badania i kartowania roślinności trawiastej (w tym

Tabela 28. Porównanie dokładności klasyfikacji zbiorowisk roślinnych z wykorzystaniem danych hiperspektralnych i sztucznych sieci neuronowych

Table 28. Comparison of hyperspectral data and ANN classification's accuracies of plant communities

Autor Author	Dokładność całkowita Overall accuracy (%)	Współczynnik kappa Cappa coefficient	Liczba zbiorowisk roślinnych Number of plant communities	Sensor Sensor
Zagajewski, 2010 ²⁵	89,62	0,86	39	DAIS 7915
Kokaly i inni, 2003	74,1	0,62	38	AVIRIS
Delalieux i inni, 2010	84,0	0,79	27	AHS
Filippi, Jensen, 2006	84,38	0,83	22	AVIRIS
Oldeland i inni, 2010	98,18	0,98	7	HyMAP
Olesiuk i inni, 2009	92,5	0,91	7	HyMAP
Mader i inni, 2006	84,6	0,63	6	HyMAP
Mader i inni, 2006	88,7	0,72	6	HyMAP
Lu i inni, 2007	92,4	0,91	5+5	AISA
Tsai i inni, 2007	86,0	0,81	2	Hyperion

Wykorzystanie hiperspektralnych obrazów CASI o rozdzielczości terenowej 4 m pozwoliło wykonać mapę zbiorowisk roślinnych terenów podmokłych południowej części Ontario (Kanada). Autorzy pozyskali z zobrażenia piksele czyste spektralnie i na podstawie charakterystyk spektralnych wykonali klasyfikację SAM oraz największego prawdopodobieństwa. Uzyskana dokładność całkowita klasyfikacji 10 typów roślinności wyniosła 92% (Jollineau, Howarth, 2008).

Ciekawym sposobem badania składu gatunkowego poszczególnych zbiorowisk roślinnych jest koncepcja rozmieszczania spektralnego pikseli i analiza prawdopodobnych gatunków w danym zbiorowisku. Przykładem takiego opracowania jest publikacja zespołu z University of Bayreuth (Niemcy). Na podstawie badań terenowych oraz analizy obrazów HyMAP autorzy stworzyli mapę zbiorowisk roślinnych oraz na diagramach przedstawili skład gatunkowy analizowanych zbiorowisk (ryc. 43). Dokładność wobec referencyjnych zdjęć fitosocjologicznych wahała się od 78 do 92% w zależności od zbiorowiska (Schmidtlein i inni, 2007).

M.L. Clark, D.A. Roberts i D.B. Clark (2005) zaprezentowali podobną florystyczną analizę koron gatunków drzew tropikalnych lasów deszczowych²⁶.

Autorzy, bazując na terenowych pomiarach hiperspektralnych oraz na hiperspektralnej analizie zobrażeń HYDICE, wybrali 40 i 60 najlepszych kanałów spektralnych, na podstawie których wygenerowali charakterystyki spektralne i porównali je z wynikami pomiarów spektrometrem terenowym ASD FieldSpec. Uzyskana zgodność oscylowała wokół 88% (dokładność całkowita), dokładność producenta wyniosła 70-100% w zależności od badanego gatunku (było ich siedem). Dokładność użytkownika wyniosła 81-100%.

gatunków inwazyjnych) można znaleźć na stronie internetowej American Society for Photogrammetry and Remote Sensing (ASPRS) 2006 Annual Conference Reno, Nevada, <http://www.asprs.org/publications/proceedings/reno2006/toc.pdf>

²⁵ Niniejsza publikacja.

²⁶ Obszar badań znajdował się wokół La Selva Biological Station (LSBS) na Kostaryce.

Jak wynika z przedstawionego powyżej przeglądu literatury z prestiżowych czasopism²⁷, klasyfikacja roślinności na podstawie danych hiperspektralnych w sieciach neuronowych jest często praktykowana, a poziom dokładności klasyfikacji innych autorów jest podobny do wyników uzyskanych w niniejszej pracy (tab. 28). Cytowani autorzy stosują podobne algorytmy. W większości przypadków są to symulatory sztucznych sieci (perceptron wielowarstwowy ze wsteczną propagacją błędów lub klasyfikacje na zbiorach rozmytych), a dane hiperspektralne podawane są analizie PCA lub transformacji MNF. Często klasyfikacje bazują na analizie spektrów (MF, MTMF lub SAM).

Współczynnik kappa zawiera się w dość dużym zakresie (0,62-0,98). Na szczególną uwagę zasługuje publikacja F. Tsai i inni (2007). Autorzy osiągnęli bardzo dobry wynik kartując inwazyjne gatunki krzewów w bardzo heterogenicznym środowisku na obrazach satelitarnych Hyperion (30 m). Inni autorzy (Oldeland i inni, 2010; Olesiuk i inni, 2009; Mader i inni, 2006, Lu i inni, 2007) kartując pozornie niewielką liczbę wydzieleni (6-10) osiągnęli także bardzo dobre wyniki. Liczba wydzieleni była z góry założona, często były to bardzo zbliżone morfologicznie klasy (np. zboża ozime i jare w optimum rozwoju fenologicznego wyglądają podobnie).

Przegląd literatury dostarczył ważnej informacji, że techniki hiperspektralne rozwijane są głównie na podstawie danych lotniczych, w mniejszym stopniu satelitarnych. Autorzy bazują na zbliżonych algorytmach, modyfikując je na własne potrzeby. Oznacza to, że na chwilę obecną dominują prace metodyczne, które stosowane i sprawdzane są w skalach lokalnych. Ma to na celu wypracowanie najbardziej optymalnych algorytmów do powszechnego wykorzystania danych i narzędzi hiperspektralnych.

²⁷ W większości przypadków były to *Remote Sensing of Environment* i *International Journal of Remote Sensing*.