


TELEDETEKCJA ŚRODOWISKA

ISSN 0071-8076

43

dawniej **FOTOINTERPRETACJA** w GEOGRAFII

WARSZAWA 2010



POLSKIE TOWARZYSTWO GEOGRAFICZNE
Klub Teledetekcji Środowiska

RADA PROGRAMOWA

Dr hab. inż. Krzysztof Będkowski (Szkoła Główna Gospodarstwa Wiejskiego), Doc. dr hab. inż. Elżbieta Bielecka (Instytut Geodezji i Kartografii), Prof. dr hab. Jerzy Cierniewski (Uniwersytet im. Adama Mickiewicza), Prof. dr hab. Andrzej Ciołkosz (Instytut Geodezji i Kartografii), Prof. dr hab. Katarzyna Dąbrowska-Zielińska (Instytut Geodezji i Kartografii), Dr hab. inż. Beata Hejmanowska (Akademia Górniczo-Hutnicza), Doc. dr hab. inż. Stanisław Lewiński (Instytut Geodezji i Kartografii), Dr Mieczysław Kunz (Uniwersytet im. Mikołaja Kopernika), Dr Małgorzata Mycke-Dominko (Uniwersytet Warszawski), Prof. dr hab. Jan R. Olędzki (Uniwersytet Warszawski), Dr Marek Ostrowski (Uniwersytet Warszawski), Dr Bogdan Zagajewski (Uniwersytet Warszawski), Prof. dr hab. inż. Tomasz Zawila-Niedźwiecki (Instytut Badawczy Leśnictwa)

REDAKCJA

Prof. dr hab. Jan R. Olędzki – Redaktor Naukowy
Dr Bogdan Zagajewski – Zastępca Redaktora Naukowego
Mgr Alicja Folbrier – Sekretarz Redakcji

Redaktor tomu:

Prof. dr hab. Jan R. Olędzki

Recenzent:

Doc. dr hab. Anna Kozłowska (IGiPZ PAN)

Pozycja finansowana przez: Klub Teledetekcji Środowiska Polskiego Towarzystwa Geograficznego; Uniwersytet Warszawski – ze środków na naukę – badania własne BW 1945/2010 oraz Wydział Geografii i Studiów Regionalnych; Fundację Wspierania Rozwoju Radiokomunikacji i Technik Multimedialnych; Projekt VI PR, EU HYPER-I-NET MRTN-CT-2006-035927

© Klub Teledetekcji Środowiska PTG 2010

ISSN 0071-8076

Adres Redakcji:

Klub Teledetekcji Środowiska PTG
Ul. Krakowskie Przedmieście 30, 00-927 Warszawa, tel.. (48) 022 5520654

Wydawca:

Klub Teledetekcji Środowiska Polskiego Towarzystwa Geograficznego
ul. Krakowskie Przedmieście 30, 00-927 Warszawa

Redakcja techniczna: Katedra Geoinformatyki i Teledetekcji WGiSR UW

Skład, przygotowanie do druku i druk: Zakład Graficzny Uniwersytetu Warszawskiego

Ul. Krakowskie Przedmieście 26/28, 00-927 Warszawa

Nakład 500 egz.

Wydanie I – 200 egz., Wydanie II (elektroniczne) – 300 egz.

Na okładce: Symulacja widoku z punktu zlokalizowanego nad Kuźnicami, na wysokości 4500 m npm na Dolinę Gąsienicową (na drugim planie widać Dolinę Pięciu Stawów Polskich). Na zgeneralizowany Numeryczny Model Terenu nałożona została kompozycja RGB kanałów MNF 432 6 linii zobrazowania DAIS 7915. Wchylenie od poziomu wynosi -29 stopni (obraz wyostrzony na linię równoleżnikowo przebiegającą do północnego brzegu Czarnego Stawu Gąsienicowego), kąt widzenia 30 stopni.

Druk i oprawa: Zakład Graficzny Uniwersytetu Warszawskiego

Zam. 832/2010

Bogdan Zagajewski

**OCENA PRZYDATNOŚCI
SIECI NEURONOWYCH
I DANYCH HIPERSPEKTRALNYCH
DO KLASYFIKACJI ROŚLINNOŚCI
TATR WYSOKICH**

**ASSESSMENT OF NEURAL NETWORKS AND IMAGING
SPECTROSCOPY FOR VEGETATION CLASSIFICATION
OF THE HIGH TATRAS**

Warszawa 2010

Pracę dedykuję żonie Małgosi oraz dzieciom: Marysi i Michałowi

TELEDETEKCJA ŚRODOWISKA

ISSN 0071-8076

dawniej **FOTOINTERPRETACJA** w GEOGRAFII

43

WARSZAWA 2010

Spis treści – Contents

Wstęp	7
Podstawy teledetekcji hiperspektralnej	11
Rejestracja lotniczych obrazów hiperspektralnych	18
Podstawy metodyczne klasyfikacji danych hiperspektralnych	23
Wskaźnik czystości piksela PPI (Pixel Purity Index)	23
Transformacja Minimum Noise Fraction (MNF)	25
Klasyfikacja Spectral Angle Mapper (SAM)	26
Sztuczne sieci neuronowe (SSN)	27
Architektura sztucznych sieci neuronowych	30
Uczenie sieci metodą wstecznej propagacji błędów	36
Wstępne przetwarzanie danych hiperspektralnych Tatr Wysokich	38
Korekcja geometryczna obrazów hiperspektralnych	39
Korekcja atmosferyczna obrazów hiperspektralnych	40
Procedura klasyfikacji danych hiperspektralnych	45
Tworzenie wzorców do klasyfikacji i weryfikacji poklasyfikacyjnej	45
Wybór i przygotowanie kanałów DAIS 7915 do klasyfikacji	46
Klasyfikacja i procedury poklasyfikacyjne	54
Wyniki klasyfikacji roślinności Tatr Wysokich	57
Zastosowania danych hiperspektralnych do klasyfikacji roślinności	90
Podsumowanie	100
Wnioski	102
Podziękowania	103
Literatura	105
Akronimy	112

Ocena przydatności sieci neuronowych i danych hiperspektralnych do klasyfikacji roślinności Tatr Wysokich

Assessment of neural networks and Imaging Spectroscopy for vegetation classification of the High Tatras

Słowa kluczowe: kartowanie roślinności, sztuczne sieci neuronowe, fuzji ARTMAP, dane hiperspektralne, TPN, zbiorowiska roślinne

Keywords: plant mapping, ANN, fuzzy ARTMAP, hyperspectral data, Tatra National Park, plant communities

This research aims to discover potential of hyperspectral remote sensing data for mapping high-mountain vegetation ecosystems. First, the importance of mountain ecosystems to global system should be stressed: due to environmental fragility and location of plant species and communities at the upper levels of habitats, mountainous ecosystems form a very sensitive indicator of global climate change. Furthermore, a variety of biotic and abiotic factors that influence spatial distribution of vegetation in the mountains are producing diverse mosaic of habitats leading to high biodiversity. Mountain plants developed specific adaptations to survive at the fringe of life (pigment content, plant tissue structure etc.). These adaptations have direct impact on their reflectance properties which can be acquired and quantified using hyperspectral imagery interpretation techniques. These changes are characterised by a large number of closely spaced spectral channels. Application of remote sensing techniques allows vegetation research and mapping in areas that are otherwise inaccessible. This could be due to low accessibility of terrain, very short vegetative period and unstable weather conditions. Mapping vegetation and its condition is often constrained or even prevented using traditional, field mapping techniques. To protect a delicate balance in mountainous environments vegetation cover (a perfect indicator of all the other components of biosphere) should be researched in detail and mapped with sufficient level of accuracy. This is of particular importance for the proper management as both anthropogenic pressure and local disturbances (avalanches, solifluction after extensive rainfalls) can have significant impact on vegetation, leading to disturbance, and eventually – disintegration of plant cover. It is anticipated, that vegetation mapping and condition analysis can be achieved using hyperspectral, high ground resolution imagery and digital and field remote sensing techniques.

Artificial Neural Network (NN/ANN) algorithms use whole object characteristics (spectral, structural and/or textural properties, where the relationship between pixels are also taken

into account). These relationships among the spatial patterns of the image frequently appear over natural biotopes and plant communities with closed coverage. Traditional classification methods that use parametrical approaches do not show satisfying results. The implemented neural network is the fuzzy ARTMAP (FAM) simulator. For training the neural network, particular layers of the covering vegetation classes were used that were identified via field mapping while the aircraft was operating. In the same time separate field data was collected for validation purposes too. For hyperspectral data compression the Minimum Noise Fraction transformation (MNF) was used. This method may be especially useful to separate and classify vegetation or land cover units.

The High Tatras are located within the MAB Biosphere Reserve and encompasses alpine and subalpine zones of the Tatra National Park (TPN). The area extends within: 49°10'30"–49°16'00" N and 19°45'30"–20°07'30" E rectangle, encompassing approximately 110 km². However, in this publication only Polish part of the Tatra Mountains (so called "High Tatras") was analysed (Figure 15).

Vegetation in the area has been well researched (since the 1920's), however most of the research has been carried out on transects or glades. Plant species have been well identified and described, however detailed maps of vegetation are available only for selected areas. The most of the research area is covered by natural and seminatural key units: peaty and boggy communities, avalanche meadows, tall herb communities (*Adenostylion*), grassland communities after grazing, subalpine dwarf scrub communities, willow thicket (*Chamaenerion angustifolium-Salix silesiaca* community), mountain-pine scrub on silikat substrate (*Pinetum mugho carpaticum silicicum*), mountain-pine scrub (*Pinetum mugho carpaticum silicicum*) in a complex with epilithic lichen communities, mountain-pine scrub on calcareous substrate (*Pinetum mugho carpaticum calcicum*), montane spruce forest (*Plagiothecio-Piceetum*) and lakes.

In this study a DAIS 7915 hyperspectral data was classified that was acquired on 04 August 2002 by the German Aerospace Center (DLR) in the frame of the HySens PL02_05 project. This instrument is a 79-channel imaging spectrometer operating in the wavelength range 0.4-12.5 μm with 15 bit radiometric resolution. After preprocessing the obtained ground resolution was 3 meters.

The classification procedures (Figure 21) began with a preparation of reference layers of 42 dominant classes for the fuzzy ARTMAP teaching (Figure 22A). This stage based on terrain acquired data. For validation's map Spectral Angle Mapper (SAM) was used; in the first step, basing on field sampled polygons and endmembers obtained from DAIS data (corresponding to the key areas from the ground mapping) a pre-validation map was created. In the second step, basing on terrain mapping validation polygons of each analysed class were reselected (Figure 22B, Table 4).

Parallel to this procedure, an exploration from all 79 bands covering the VIS-TIR regions of the spectrum was made. The first step was a band's information analysis and the reselection of 60 spectral bands was made (Figures 23 and 24). The second step was to reduce the data dimensionality to 40 original and 20 MNF bands.

For the actual classification of the plant communities, a fuzzy ARTMAP simulator was used. In order to obtain the desired results 5000 and 10 000 iterations were used while training the Neural Net. Each set of image bands and reference layer contained a detailed DEM of analysed area.

Classification accuracy was measured using ENVI software's algorithms based on test and training sets. The overall accuracy was measured throughout a pixel by pixel comparison post classification images to ground truth map (prepared from SAM and field' verified mapping). The final results of the High Tatras polygon are shown in Tables 5-24, and the classification images present in Figures 28-35.

Generally, the forty-band set of input data offered higher accuracy (1-2%) than the twenty-MNF-band set (Tables 23 and 24). In the first case, the overall accuracy value achieved was 88.6%, and kappa coefficient was 0.8740.

In the case of 20 MNF bands, the overall accuracy was 82.6%, and kappa coefficient 0.8310.

Two of four-two analysed classes weren't classified properly: *Salicetum herbaceae* in a complex with *Empetro-Vaccinietum* (class# 6) and grassland communities after grazing in a complex with ruderal communities (#32). The worst classification results were achieved in the range of 44-80% for *Oreochloa distichae-Juncetum trifidi* scree form with *Juncus trifidus* (#14), *Festuca picta* community (#30), *Vaccinium myrtillus* community in a complex with tall herb communities (#36) and willow thicket – *Chamaenerion angustifolium-Salix silesiaca* community (#37).

The best results were achieved for: *Oreochloa distichae-Juncetum trifidi typicum* (#8); *Oreochloa distichae-Juncetum trifidi sphagnetosum* (#11), *Oreochloa distichae-Juncetum trifidi* subalpine anthropogenic form (#16), *Caricetum fuscae subalpinum* (#21), *Empetro-Vaccinietum* in a complex with *Pinetum mugho* (34), mountain-pine scrub on silikat substrate (38) and waters

Hyperspectral data showed significant potential for discriminating different vegetation types. The use of an artificial neural network is a proper method for mapping plant communities; it should be a supporting tool for traditional vegetation mapping. The increased number of bands while classification is being done (more than 40) does not offer a significantly better overall accuracy, but the worst results are not so low like in the case of twenty-MNF band sets. The processing time of MNF-transformed data was significantly shorter while provides less accurate classification results (3-6% less overall accuracy compared to using forty-band sets). A long training time is the most inconvenient aspect of this kind of classification.

Wstęp

Tereny górskie stanowią jeden z najcenniejszych, a jednocześnie najtrudniejszych obiektów badawczych. Duża wartość przyrodnicza ekosystemów górskich wynika z obecności wysoce wyspecjalizowanych biotopów o niewielkiej tolerancji na zmiany w przyrodzie oraz mnogości powiązań między żywymi i abiotycznymi komponentami środowiska (Falińska, 1997). Przejawia się to w ogromnej różnorodności i skomplikowanej strukturze przestrzennej roślinności górskiej, która jest bardzo dobrym wskaźnikiem aktualnego stanu i procesów zachodzących w środowisku przyrodniczym gór. Badania nad roślinnością pociągają za sobą szereg problemów, dotyczących zarówno przedmiotu badań, jak i stosowanych metod. Problemy te są spowodowane głównie trudnościami eksploracyjnymi, długim okresem zalegania pokrywy śnieżnej oraz krótkim i zmiennym sezonem wegetacyjnym. Wszystko to wydłuża czas potrzebny do zebrania odpowiednich i statystycznie wiarygodnych informacji. Do niedawna problemem był dostęp do precyzyjnej lokalizacji obiektów (brak DGPS) oraz szczegółowych, wiarygodnych materiałów podkładowych i referencyjnych.

Teledetekcyjne badania obszarów wysokogórskich są także zaliczane do najtrudniejszych, gdyż:

- a) urozmaicona rzeźba terenu wpływa na kierunek odbicia promieniowania elektromagnetycznego. Na zdjęciach obserwuje się to w postaci zróżnicowanego oświetlenia powierzchni do- i odsłonecznych. W efekcie daje to zmienne charakterystyki spektralne obiektu, który znajduje się na różnych ekspozycjach terenu;
- b) duże deniwelacje terenu oraz heterogeniczność środowiska zwiększają liczbę mieszanych pikseli (miksele);
- c) wraz ze wzrostem bezwzględnej wysokości maleje miąższość atmosfery. Zwiększa to dopływ wysoce energetycznego promieniowania krótkofalowego

(UV), wymuszając na roślinach znaczące przystosowania morfologii i anatomii. Najważniejsze z nich to ilościowe zmiany:

- stosunków barwników fotosyntetycznie czynnych (np. wzrost chlorofilu b oraz karotenoidów, pełniących funkcję ochronną);
- struktur komórkowych (wzrost warstwy kutikuli);
- zawartości węgla, nutrientów, celulozy, lignin oraz pokrywania liści substancjami ochronnymi, np. woskami, kutikulą, czy odpowiedniego ustawiania liści do kierunku padania promieni słonecznych (Caldwell, 1971).

Adaptacje te na tyle zmieniają własności spektralne roślin, że są rejestrowane przez sensory teledetekcyjne (Barnes i inni, 1990) i utrudniają identyfikację roślinności położonej na różnych wysokościach bezwzględnych;

- d) obszary wysokogórskie cechują się dużą dynamiką zmian pogody i częstą obecnością chmur i ich cieni. Wyklucza to fragmenty obrazów z dalszych analiz;
- e) duże zróżnicowanie środowiska utrudnia znalezienie odpowiednio dużych i homogenicznych powierzchni kalibracyjnych oraz poligonów referencyjnych o odpowiednich charakterystykach spektralnych.

Wspomniane powyżej problemy wymagają stosowania licznych algorytmów eliminujących geometryczne i atmosferyczne zniekształcenia. Zastosowanie teledetekcji hiperspektralnej¹ pozwala na znaczącą eliminację

¹ Teledetekcja hiperspektralna pozyskuje dane w dużej liczbie kanałów (np. 300 w lotniczym skanerze APEX) w wąskich zakresach spektralnych (2-10 nm) i o dużej rozdzielczości radiometrycznej (np. 15-bitowej, co równa się 32 768 poziomom szarości pomiędzy czernią i bielą) oraz w przypadku obrazów lotniczych dużej rozdzielczości terenowej (1-5 m).

szumów i pozyskanie czystych spektralnie charakterystyk analizowanych obiektów (van der Meer, de Jong, 2001). Zatem zapis sygnału odbitego od obiektów w wielu zakresach promieniowania elektromagnetycznego pozwala rejestrować cenne informacje o komponentach ekosystemu wysokogórskiego. Na podstawie uzyskanych charakterystyk spektralnych tworzy się wskaźniki teledetekcyjne, które informują o jakości badanego obszaru.

Promieniowanie elektromagnetyczne odbite, absorbowane lub transmitowane przez organy roślin, procesy fizjologiczne oraz strumienie gazów zawartych w roślinie (CO_2 , O_2 , pary wodnej) interferują na poziomie liści (Jarvis, 1993; 1995). Na poziomie rośliny procesy te są modyfikowane przez składowe atmosfery znajdujące się w bezpośrednim sąsiedztwie liści. Wpływa na to temperatura, wilgotność, ciśnienie, wiatr, promieniowanie odbite od innych obiektów oraz rozpraszanie światła, stężenie gazów (Ball i inni, 1986). Procesy te mają podobną intensywność na tzw. *leaf boundary layer*, czyli homogenicznych powierzchniach odpowiadających liściom (*leaf clusters*) cechujących się podobnymi właściwościami spektralnymi (Anderson i inni, 2003). Na przestrzeniach pomiędzy tymi powierzchniami zachodzą interakcje z innymi obiektami, np. glebami. Na poziomie baldachimu roślinności (*canopy*) następuje ujednoczenie strumieni gazów i termiki. Wysokość takiej homogenicznej warstwy, tzw. *atmospheric boundary layer* (ABL) wynosi do 50-100 m i zależy m.in. od rodzaju powierzchni i wysokości (lasu) analizowanego zbiorowiska (Anderson i inni, 2003; Wullschlegler i inni, 2000).

Właściwości materiałów, które generują sinusoidalną falę elektromagnetyczną – charakteryzującą dany obiekt w każdym zakresie widma – nazywa się właściwościami spektralnymi obiektu. Są one rejestrowane za pomocą urządzeń aktywnych (radary, lidary) lub pasywnych (spektrometry, radiometry, skanery). W pierwszym przypadku źródło promieniowania interferującego z obiektem jest częścią zestawu pomiarowego, w drugim zaś przypadku źródłem promieniowania jest najczęściej Słońce. Właściwości spektralne obiektów rejestrowane są jako charakterystyki spektralne obiektu (krzywe odbicia spektralnego).

Teledetekcyjna identyfikacja gatunków i zbiorowisk roślinnych bazuje na rejestracji promieniowania elektromagnetycznego, interferującego ze strukturami komórkowymi, morfologią i procesami fizjologicznymi roślin. Odbywa się ono w sposób powtarzalny i charakterystyczny w ściśle określonych przedziałach widma dla poszczególnych gatunków i zbiorowisk roślinnych. Rejestracja ta odbywa się w postaci fotointerpretacyjnych cech bezpośrednich i pośrednich² (Ciołkosz i inni, 1999). Wykorzystanie sieci neuronowych do klasyfikacji roślinności pozwala bazować nie

² Fotointerpretacja obrazów teledetekcyjnych bazuje na cechach bezpośrednich (fototon, barwa, struktura, tekstura, kształt, wielkość, cień obiektu) oraz pośrednich (obecność innych obiektów, cień). Kompleksowa analiza zdjęć umożliwia rozróżnienie obiektów, których identyfikacja z innych materiałów jest utrudniona, np. łąka i pastwisko, las iglasty i liściasty.

tylko na fototonie/barwie, ale także innych cechach fotointerpretacyjnych

We współczesnych badaniach środowiska kluczowym elementem jest dostęp do aktualnych danych, które obrazują zmiany zachodzące w przyrodzie w sposób trwały, powtarzalny i obiektywny. Teledetekcja, która pozyskuje informacje o obiektach w sposób zdalny, oferuje badaczom cenne produkty. Najprostsze z nich to aktualne materiały referencyjne, np. ortofotomapy, czy wysokorozdzielcze zdjęcia satelitarne. Dostępne są także wielokanałowe dane, które pozwalają na tworzenie teledetekcyjnych wskaźników wybranych komponentów (roślinność, gleby, wody, itp.). Jedną z najważniejszych korzyści wynikających z wykorzystania danych teledetekcyjnych jest to, że zobrazowanie terenu odbywa się w stosunkowo krótkim czasie i obejmuje relatywnie duże powierzchnie. Wszystko to odbywa się według ściśle określonych procedur, powtarzalnych w czasie.

Celem niniejszej publikacji jest przetestowanie nowej metody przetwarzania danych hiperspektralnych i ich klasyfikacji symulatorem sztucznych sieci neuronowych do tworzenia map roślinności rzeczywistej terenów wysokogórskich. Cel ten wymaga zastosowania licznych, także nowatorskich rozwiązań, takich jak:

- Parametryczna korekcja geometryczna. Polega ona na obliczeniu zależności geometrycznej pomiędzy skanerem a obrazowanym terenem przedstawionym w 3D przy uwzględnieniu wszystkich właściwości układu optyczno-mechanicznego skanera oraz Numerycznego Modelu Terenu (NMT). Pozwala to na wierne odwzorowanie wielkości i lokalizacji każdego piksela (w terenach górzystych wielkość piksela ze względu na deniwelację może się znacząco zmieniać) i naniesienie ich na wyidealizowane geometrycznie zobrazowanie. Do geometryzacji niezbędne są parametry lotu samolotu z inercyjnego systemu nawigacji (INS)³, na pokładzie którego zainstalowany jest obrazujący skaner hiperspektralny;

- Pełna korekcja atmosferyczna, z uwzględnieniem normalizacji topograficznej i radiometrycznej oraz empirycznego modelowania dwukierunkowości odbicia promieniowania (BRDF – *Bidirectional Reflectance Distribution Function*). Procedura ta ogranicza wpływ orografii terenu, zmienności atmosfery oraz geometrii słońce–obiekt–detektor, co w efekcie pozwala na radiometryczne porównanie odpowiedzi spektralnych obiektów przedstawionych na różnych liniach zobrazowania lub znajdujących się na różnych ekspozycjach terenu;

- Opracowanie metody tworzenia wzorców do klasyfikacji, a także weryfikacji danych poklasyfikacyjnych. Ze

³ Pochodzących z bezwładnościowego systemu rejestracji lotu samolotu (INS – *Inertial Navigation System*) oraz różnicowego GPS. Systemy te rejestrują w czasie rzeczywistym zmiany kierunku lotu we wszystkich osiach oraz przyspieszenia i opóźnienia, a także zmiany położenia i czasu względem punktu początkowego. Do najważniejszych parametrów, które rejestrowane są w trakcie lotu, należy zaliczyć: bieżącą pozycję i linię drogi, przyspieszenia, prędkość względem Ziemi, kierunek znoszenia, prędkości i przyspieszenia kątowe we wszystkich osiach, kurs rzeczywisty i magnetyczny.

względu na dużą liczbę oraz złożoność obiektów wymagana jest statystycznie duża próba, która posłużyłaby do klasyfikacji oraz weryfikacji danych poklasyfikacyjnych;

– Opracowanie algorytmu wyboru kanałów oraz kompresji danych. Ze względu na dużą ilość danych wejściowych do klasyfikacji (72 kanały zobrazowania, wzorce do uczenia sieci oraz NMT), jednym z priorytetowych kierunków działań jest optymalny wybór jakości i ilości poszczególnych kanałów zobrazowania;

– Wybór i opracowanie metody klasyfikacji. Ze względu na złożoną strukturę danych wejściowych (dane zapisane były w postaci 15- i 16-bitowej⁴) i wyjściowych (wzorce zbiorowisk roślinnych), optymalnym algorytmem klasyfikacji jest metoda nieparametryczna, czyli uwzględniająca w procesie klasyfikacji nie tylko cechy spektralne obrazu (fototonalne), ale także strukturalne i teksturalne (przestrzenne ułożenie pikseli tworzących poszczególne obiekty). Wykorzystanie danych hiperspektralnych, cechujących się rejestracją ciągłego widma (zapisanego w wielu wąskich kanałach w pełnym zakresie widma elektromagnetycznego o dużej rozdzielczości radiometrycznej), pozwala zastosować symulatory sztucznych sieci neuronowych i analizę zbiorów rozmytych⁵. Symulatory bazujące na logice rozmytej i analizie cech nieparametrycznych dostarczają większej ilości danych do systemu klasyfikującego niż ma to miejsce w standardowych klasyfikacjach, które bazują na jasności pikseli;

– Analiza poklasyfikacyjna obejmuje standardowe procedury: geometryzacji obrazów poklasyfikacyjnych, ich wektoryzację oraz analizy statystyczne uzyskanych dokładności. Do tego celu wykorzystany został pakiet ENVI 4.6. Ocena dokładności obejmuje opracowanie macierzy błędów, współczynnika kappa oraz dokładności: całkowitej, producenta i użytkownika, niedoszacowanie oraz przeszacowanie klasyfikacji. Uzyskane wyniki prezentowane są w postaci map i tabel wartości procentowych oraz liczby pikseli każdego sklasyfikowanego zbiorowiska.

Uzasadnieniem podjęcia się zadania opracowania metody klasyfikacji danych hiperspektralnych sieciami neuronowymi w celu uzyskania mapy roślinności jest fakt, iż do chwili obecnej nie powstała szczegółowa mapa roślinności rzeczywistej polskiej części Tatr, mimo licznych i szczegółowań opracowań naukowych, które są prowadzone od początku XX w. (Szafer i inni, 1923, 1927; Pawłowski i inni, 1928; Pawłowski, 1956; Balcerkiewicz, Wojterska, 1978; Balcerkiewicz, 1984; Mirek, 1996; Kozłowska, Plit, 2002; Kozłowska, 2006). Opraco-

wanie algorytmu klasyfikacji danych hiperspektralnych pozwoli w perspektywie kilku najbliższych lat⁶ opracować dane źródłowe w postaci wstępnej wersji mapy roślinności, weryfikowanej w wyniku terenowych prac fitosocjologicznych, których efektem będzie szczegółowa mapa roślinności Tatr. Dane teledetekcyjne będą mogły także stanowić jeden z głównych elementów stałego monitoringu rozmieszczenia i kondycji roślinności tatrzańskiej.

Hipotezą badawczą niniejszego opracowania jest stwierdzenie, że zastosowanie obrazów hiperspektralnych, które charakteryzują się dużą rozdzielczością przestrzenną, spektralną oraz radiometryczną, pozwala traktować je jako dane ciągłe (ciągłość zapisu spektralnego i radiometrycznego), a to umożliwi zastosowanie symulatorów sieci neuronowych bazujących na koncepcji logiki rozmytej do klasyfikacji zbiorowisk roślinnych obszarów wysokogórskich.

Obszar badawczy objął polską część Tatr Wysokich. Szczegółowe prace terenowe prowadzone były na poligonie kluczowym Dolina Gąsienicowa. Analizie poddano 42 klasy wydzieleni; do głównych jednostek należy zaliczyć: pionierskie zbiorowiska roślin zarodnikowych, zbiorowiska porostów naskalnych, zbiorowiska piargów i żwirków, zbiorowiska wyleżyskowe (4 wydzielenia), ubogie murawy piętra alpejskiego (10 wydzieleni), kompleksy przestrzenne ubogich muraw alpejskich z innymi zbiorowiskami (3), żyzne murawy alpejskie, torfowiska i młaki (3), traworośla i ziołorośla (5), subalpejskie murawy powypasowe (4), borówczyska (4), liściaste zbiorowiska zaroślowe, subalpejskie zarośla kosodrzewiny (3), bór górnoreglowy oraz wody powierzchniowe. Na badanym obszarze dominują naturalne i półnaturalne zbiorowiska roślinne (Kozłowska, 2006).

Opracowanie automatycznych metod przetwarzania i klasyfikacji danych jest szczególnie ważne w aspekcie wykorzystania powszechnie dostępnych danych hiperspektralnych (np. Hyperion). W perspektywie 2-3 najbliższych lat powinny być dostarczane nowe dane z sensorów EnMAP oraz PRISMA. DLR⁷ oraz GFZ⁸ planują, że dane EnMAP⁹ będą udostępniane bezpłatnie. Wpłyne to niewątpliwie na wzrost zainteresowania badaniami nad wykorzystaniem technik hiperspektralnych do analiz ekosystemów lądowych i morskich. Dlatego wszelkie prace studyjne są w pełni uzasadnione, gdyż rozwijają algorytmy i metody, dostarczając gotowych narzędzi mniej zaawansowanym naukowo odbiorcom.

⁴ Dane tzw. oryginalne, czyli po korekcji geometrycznej i atmosferycznej, cechowały się rozdzielczością 15-bitową, natomiast dane po dekokorelacji szumu i analizie głównych składowych (tzw. transformacji Minimum Noise Fraction – MNF) zapisane były w skali 16-bitowej.

⁵ Do niniejszych analiz wykorzystany został symulator fuzzy ARTMAP, opracowany przez zespół prof. Paolo Gamby z Uniwersytetu w Pawii i udostępniony autorowi w ramach kontraktu ESR 6 (*advanced classification algorithms*) projektu UE MCRTN Hyper-i-net (www.hyperinet.eu).

⁶ Na rok 2011-2012 planowane jest umieszczenie hiperspektralnego skanera EnMAP na orbicie satelitarnej. Rejon Tatr jest jednym z kluczowych obszarów badawczych, a Katedra Geoinformatyki i Teledetekcji WGiSR UW jest naukowym partnerem tego przedsięwzięcia (zajmuje się badaniami roślinności górskiej i pogórskiej).

⁷ Deutsches Luft und Raumfahrt Zentrum (Niemiecka Agencja Kosmiczna).

⁸ GeoForschungsZentrum Potsdam (Niemcy).

⁹ Environmental Mapping and Analysis Program – niemiecka hiperspektralna misja satelitarna.

Kartowanie roślinności z wykorzystaniem technik hiperspektralnych sięga początku lat 1990. (Adams i inni, 1993; Benediktsson, 1995; Ray, Murray 1996; Ashton, Schaum, 1998). Prace te koncentrowały się głównie nad rozwojem metod i koncepcji badań hiperspektralnych. Chodziło o analizę cech spektralnych, pozyskanych ze zwiększonej liczby kanałów danego piksela. Z jednej strony punktem wyjścia były dane wielospektralne, a z drugiej strony tworzone były modele empiryczne bazujące na nieobrazujących pomiarach hiperspektralnych z eksperymentów polowych i laboratoryjnych.

W Polsce badania hiperspektralne rozpoczęły się 13.08.2001 r. zobrazowaniem AISA (SPECIM¹⁰). Sensor ten został wykorzystany do zobrazowania Puszczy Niepołomickiej w 32 kanałach spektralnych w ramach programu 5FP EU IST 1999-2002 Foremms. Polskim uczestnikiem tego projektu był Wydział Leśny AR w Krakowie, a kierownikiem projektu dr Piotr Wężyk (Solberg, Wężyk, 2000; Wężyk i inni, 2003; Wężyk, Wertz, 2005). Kolejny rozdział badań hiperspektralnych z pełną, ciągłą rejestracją widma elektromagnetycznego przypadł na

¹⁰ Spektrometr AISA wykonuje zobrazowania w modułach pracujących w zakresie 430-900 nm ze zmienną rozdzielczością spektralną w zakresie 1,63-9,8 nm, umożliwiając wykonanie zobrazowania do 286 kanałów. Pole widzenia wynosi 21° w linii poprzecznej do lotu i 0,055° wzdłuż linii lotu, dając przestrzenną rozdzielczość 360 pikseli w linii zobrazowania, co przy wysokości lotu 1000 m daje rozdzielczość przestrzenną 1 m. Firma SPECIM jest współpartnerem Katedry Geoinformatyki i Teledetekcji WGiSR UW w kontrakcie ESR10 europejskiego projektu Hyper-i-net.

rok 2002, w którym wykonane zostały naloty dwoma hiperspektralnymi skanerami: ROSIS z rejestracją 115 kanałów oraz DAIS 7915 (79 kanałów) nad 3 polskimi obszarami badawczymi: Tatrami Wysokimi, zlewnią Bystrzanki w Beskidzie Niskim oraz kopalnią siarki w Machowie i Jeziórcie. Dwa pierwsze poligony zobrażowano w ramach projektu HySens PL02_05 przygotowanego przez Zakład Teledetekcji Środowiska WGiSR UW, a uzyskane obrazy DAIS 7915 są przedmiotem analizy xprezentowanej w niniejszej publikacji. Poligon z Tarnobrzieskiego Zagłębia Siarkowego był zobrażowany w ramach projektu HySens PL02_04 przygotowanego przez Zakład Fotogrametrii i Informatyki Teledetekcyjnej, WGGiŚ AGH (Hejmanowska, Głowienka, 2004).

Do innych prac naukowych wykorzystujących zobrazowania hiperspektralne należy zaliczyć badania jakości wód z wykorzystaniem satelitarnych zobrazowań CHRIS/Proba jezior mazurskich (Osińska-Skotak i inni, 2005) oraz danych Hyperion Zbiornika Dobczyckiego (Hejmanowska i inni, 2006).

Autor niniejszej publikacji od lat zajmuje się wykorzystaniem teledetekcji hiperspektralnej w badaniach roślinności i tworzeniem nowych algorytmów pozwalających na kartowanie gatunków i zbiorowisk roślinnych, analizę ich stanu biofizycznego oraz analizę wpływu czynników stresogennych na odpowiedź spektralną, np. zwiększone promieniowanie w warunkach wysokogórskich, czy obecności substancji toksycznych (Zagajewski, Sobczak, 2003; Zagajewski i inni, 2004; 2007; Zagajewski, Jarocińska, 2009; Zagajewski, Olesiuk, 2009).

Podstawy teledetekcji hiperspektralnej

W roku 1988 Międzynarodowe Towarzystwo Fotografometrii i Teledetekcji (ISPRS) zdefiniowało teledetekcję wspólnie z fotogrametrią jako „dział nauk technicznych zajmujących się pozyskiwaniem wiarygodnych informacji o obiektach fizycznych i ich otoczeniu drogą rejestracji, pomiaru i interpretacji obrazów lub ich reprezentacji cyfrowych, uzyskiwanych dzięki sensorom niebędącym w bezpośrednim kontakcie z tymi obiektami” (za: Sitek, 1992; 2000). Identyfikującą definicję teledetekcji przyjmuje PAU w swoim Słowniku Geoinformatycznym (Słownik, 2001). Od 2007 r. ISPRS rekomenduje ogólną definicję określającą teledetekcję jako „pomiary lub pozyskanie informacji poprzez instrument, który nie ma bezpośredniego kontaktu z badanym obiektem lub zjawiskiem” (Glossary, 2000). Zatem najistotniejszą cechą teledetekcji jest pozyskiwanie, przetwarzanie i analizowanie informacji o badanych obiektach lub zjawiskach za pomocą promieniowania elektromagnetycznego, magnetycznego lub fal akustycznych. Fale te mogą być emitowane lub odbijane od badanych obiektów. Warto zwrócić uwagę, że cały proces pozyskania informacji odbywa się w sposób zdalny, czyli detektor sygnału nie ma fizycznego kontaktu z obiektem lub zjawiskiem będącym przedmiotem zainteresowania (de Jong, van der Meer, 2004).

W roku 1985 A.F.H. Goetz na łamach *Science* zdefiniował dane hiperspektralne jako dane teledetekcyjne obejmujące ponad 40 kanałów spektralnie ciągłych o szerokości połówkowej od 10 do 20 nm (Goetz i inni, 1985). Różnią się one od danych wielospektralnych, które operują liczbą kanałów mniejszą niż 20, a ich rozdzielczość spektralna wynosi kilkadziesiąt nanometrów. Wymaga to stosowania odmiennych algorytmów przetwarzania i analizy obrazów (Taranik, Settle, 1982).

Początki badań spektroskopowych sięgają lat 1670-72, wtedy to I. Newton (1642/3-1727) udowodnił, że widmo elektromagnetyczne składa się z monochromatycznych przedziałów promieniowania, które można rozszczepić, a następnie połączyć w światło. Kolejnym krokiem były prace J. von Fraunhofera (1787-1827)

z zakresu optyki (1814) w których opisał linie spektralne (linie Fraunhofera) umożliwiające badanie spektralne obecności lub braku wybranych związków (linie absorpcyjne i emisyjne). Prace te zostały niezależnie rozwinięte przez G. Kirchoffa (1842-1887) i R. Günsena (1811-1899), którzy opracowali metodę analizy spektralnej, stwierdzając, że każdy pierwiastek jest ściśle związany z określonymi liniami Fraunhofera podając długości fal odpowiadających za absorpcję określonych molekuł, np. linia Fraunhofera A odpowiada O_2 i absorbuje w 759,37 nm, linia D1 oznacza sód (Na) i absorbuje w 589,594 nm. Pierwszym obszernym opracowaniem poświęconym analizie widmowej było dzieło sir W. Hugginsa (1824-1910) wydane w roku 1866 *Spectrum analysis etc.* (Petykiewicz, 1986; Bogusz i inni, 1997).

Spektroskopia jest częścią fizyki i jest definiowana jako nauka zajmująca się powstawaniem, przesyłaniem, pomiarami i interpretacją widm elektromagnetycznych powstałych w wyniku współdziałania promieniowania elektromagnetycznego i materii¹ (Swain, Davis, 1978; Petykiewicz, 1986; Kumar i inni, 2001). Spektroskopia obejmuje badania właściwości obiektów za pomocą informacji niesionej przez falę elektromagnetyczną w poszczególnych jej długościach. Może się to odbywać na drodze cyfrowych analiz za pomocą spektrometrów lub też obrazujących spektrometrów, w warunkach terenowych (lotniczych bądź satelitarnych) lub laboratoryjnych. Cechy spektralne obiektu powstają w wyniku oddziaływania energii z molekułami gazów, płynów i ciał stałych i są charakterystyczne dla danego obiektu. Promieniowanie powstałe z tych interakcji jest charakterystyczne dla danego układu. Możliwość inter-

¹ W odróżnieniu od spektrometrii (wywodzącej się ze spektrofotometrii), która oznacza pomiary fotonów w funkcji długości fali. W teledetekcji wykorzystanie matematycznych analiz kształtu fali przez próbkowanie obrazu jest rzadko spotykane, gdyż zdecydowanie częściej wykorzystuje się bezpośrednie pomiary obiektu spektrometrami, bądź lotniczymi lub satelitarnymi skanerami (Suits, 1983; Kumar i inni, 2001).

akcji pomiędzy poszczególnymi kompozycjami molekuł powoduje, że możliwa jest identyfikacja nawet bardzo skomplikowanych układów (Swain, Davis, 1978). W naturalnych warunkach środowiskowych wiele cech spektralnych jest trudnych do detekcji, gdyż następuje addycja spektr, potęgując lub eliminując poszczególne sygnały (Suits, 1983).

Przed podjęciem decyzji o wykorzystaniu teledetekcyjnych danych obrazowych priorytetem jest określenie potrzeb i celów jakim mają one służyć, ponieważ nie istnieje uniwersalny skaner/detektor, którego obrazy będą „dobre na wszystko”. Podczas planowania misji badawczej należy w pierwszej kolejności określić rozdzielczości: przestrzenną, spektralną, radiometryczną oraz czasową.

Rozdzielczość przestrzenna określana jest wielkością najmniejszej rejestrowanej powierzchni terenu, przedstawianej jako najmniejszy homogeniczny element obrazu (piksel – *picture element*). W technicznym ujęciu rozdzielczość ta jest determinowana przez chwilowe pole widzenia detektora (*IFOV*)² oraz wysokość lotu³. W przypadku wysokorozdzielczych sensorów (np. Ikonos, QuickBird)⁴ rozdzielczość ta waha się od 0,6 do

4 m, dla satelitów środowiskowych wartości te oscylują w granicach kilkudziesięciu – kilkuset metrów (np. Landsat ETM+ 15-60 m, SPOT HRVR 10-20 m, a SPOT Vegetation 1000 m), dla satelitów meteorologicznych wielkość piksela znacząco przekracza wartość kilometra (np. piksel Meteosat wynosi 2,5-5,0 km w punkcie nadirowym).

Rozdzielczość spektralna definiowana jest szerokością połówkową zastosowanych filtrów; wpływa to na liczbę kanałów w jakich wykonywane jest zobrazowanie. W przypadku sensorów satelitarnych szerokość połówkowa stosowanych detektorów panchromatycznych obejmuje kilkaset nanometrów (zazwyczaj cały zakres widzialny), natomiast poszczególnych kanałów spektralnych wynosi kilkadziesiąt nanometrów (QuickBird: kanał panchromatyczny rejestrowany jest w zakresie 450-900 nm, zakres B 450-520 nm, G 520-600 nm, R 630-690 nm, Near-IR 760-900 nm; Landsat ETM+: kanał panchromatyczny: 520-900 nm, kanały: 1: 450-520 nm, 2: 520-600 nm, 3: 630-690 nm, 4: 760-900 nm, 5: 1550-1750 nm, 6: 10420-12500 nm, 7: 2080-2350 nm). Specjalną grupę sensorów stanowią instrumenty hiperspektralne, w przypadku których rozdzielczość spektralna

Tabela 1. Specyfikacje techniczne wybranych sensorów hiperspektralnych

Table 1. Technical specification of selected hyperspectral sensors

Sensor Sensor	AVIRIS	DAIS 7915	RODIS	HyMap	ARES	EnMap	Hyperion
Pole widzenia <i>Field of view (FOV)</i>	34°	52°	16°	61,3°	65°	2,63° wzdłuż linii <i>along-track</i>	0,622°
Chwilowe pole widzenia <i>Instantaneous field of view (IFOV)</i>	1 mrad	3,3 mrad	0,56 mrad	2,09 mrad	2 mrad	0,63 arcsek.	42,5 μrad
Liczba pikseli w linii <i>Number of pixels in line</i>	677	512	512	512	816	1024 (30 km szerokość ścieżki) <i>across-track</i>	7,5 km szerokość ścieżki <i>across-track</i>
Częstotliwość skanowania <i>Scanning frequency</i>	12 Hz	6-24 Hz	-	6-24 Hz	10-25 Hz	230 Hz	
Rozdzielczość terenowa <i>Terrain resolution</i>	2-20 m	5-20 m	1-6 m	3-10 m	2-15 m	30 m	30 m
Liczba kanałów <i>Number of bands</i>	224	79	115	126	160	218	220
Zakres spektralny <i>Spectral range</i>	0,38-2,5 μm	0,5-12,6 μm	430-860 nm	0,4-2,5 μm	0,4-11,5 μm	0,42-2,45 μm	0,4-2,5 μm
Rozdzielczość spektralna <i>Spectral resolution</i>	10 nm	20 nm-2 μm	4 nm	15-20 nm	14-140 nm	5-10 nm	10 nm
Sposób skanowania <i>Scanning mode</i>	whisk broom	whisk broom	push broom	whisk broom	whisk broom	push broom	push broom

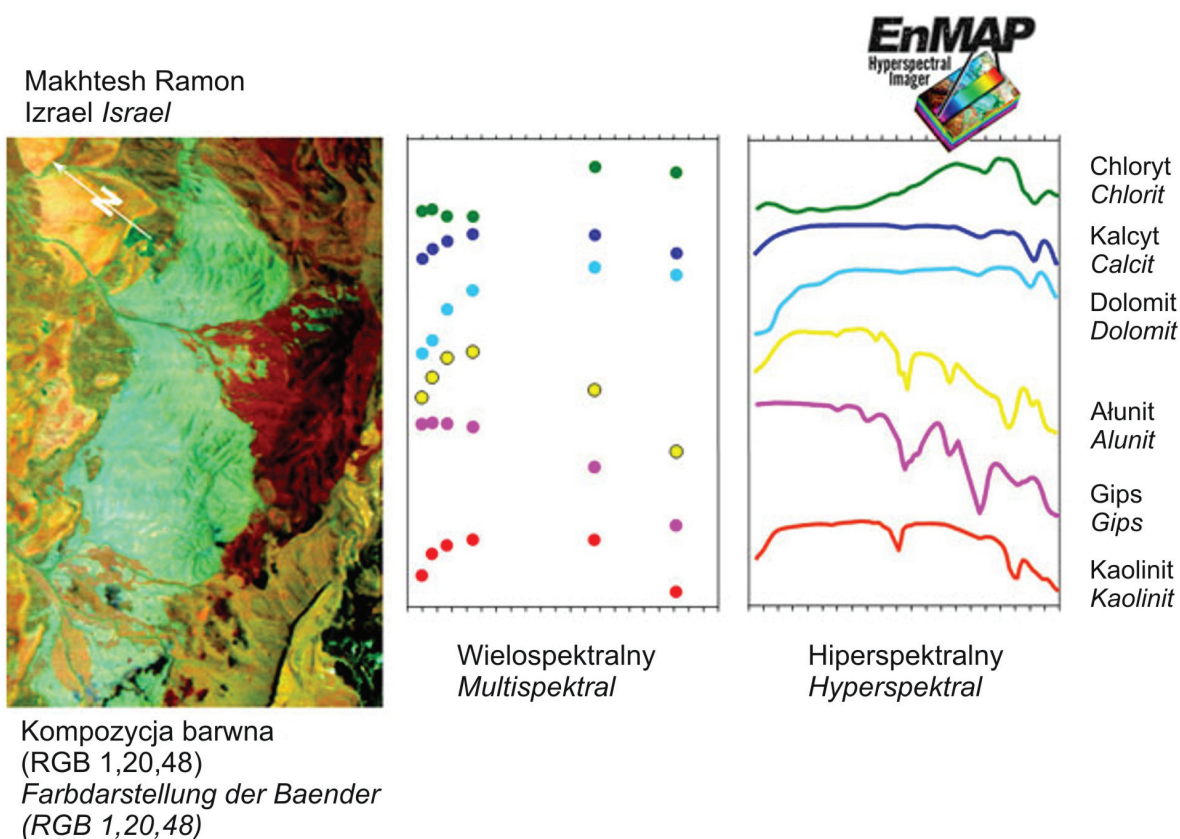
² Instantaneous Field of View (chwilowe pole widzenia detektora). FOV – *Field Of View* (pole widzenia).

³ W praktycznym wymiarze im mniejszy piksel, tym zobrazowanie przedstawia więcej szczegółów, pociągając za sobą zwiększenie wielkości plików, co w przypadku badań prowadzonych na większych obszarach jest znaczącym utrudnieniem.

⁴ Dane techniczne pochodzą ze strony www.eurimage.com, <http://eo1.usgs.gov/hyperion.php> oraz domowych stron poszczególnych systemów satelitarnych.

wynosi od kilku do kilkunastu nanometrów, a liczba stosowanych kanałów w większości przypadków przekracza sto (tab. 1). Za przykład może służyć skaner EnMAP, którego rozdzielczość przestrzenna wynosi 30 m (szerokość pasa 30 km), a spektralna 5-10 nm, liczba rejestrowanych kanałów 228 w zakresie 420-2450 nm (ryc. 1).

Poza spektralnymi różnicami w analizie obrazów wielo- i hiperspektralnych istotną różnicą tkwi w roz-



Ryc. 1. Porównanie spektrów pozyskanych z detektora wielospektralnego oraz symulacji charakterystyk spektralnych 218-kanalowego zobrazowania EnMAP (źródło: www.enmap.org, www.enmap.de)

Fig. 1. Comparison of spectra derived from the multi-, and simulated 218-band EnMAP scanner (source: www.enmap.org, www.enmap.de)

dzielnosci radiometrycznej. Odgrywa to dużą rolę przy cyfrowym przetwarzaniu danych, gdyż wymaga stosowania algorytmów uwzględniających nawet 32 768 stopni szarości pomiędzy bielą a czernią (rozdzielczość 15-bitowa obrazów DAIS 7915). Połączenie ogromnej rozdzielności spektralnej i radiometrycznej danych hiperspektralnych pozwala traktować te dane jako ciągłe (o ciągłej charakterystyce spektralnej). Umożliwia to dokładną analizę substancji i procesów zachodzących w badanych obiektach (tab. 2).

Rozdzielczość radiometryczna, zgodnie z definicją *Glossary of remote sensing technology* (Glossary, 2000) oznacza ilość energii potrzebnej do podniesienia sygnału obrazu o jeden poziom. Natomiast zgodnie z ogólnie przyjętą definicją rozdzielczość radiometryczna oznacza liczbę poziomów, na jakich może zostać zapisany zarejestrowany sygnał. A. Ciołkosz i A. Jakomulska (2004) definiują ją także jako czułość detektora na różnicowanie wielkości energii docierającej do niego od poszczególnych obiektów terenowych. Oznacza to liczbę rozróżnialnych poziomów sygnału wyrażonych na czarno-białych zdjęciach tonami szarymi (achromatycznymi). Oko ludzkie jest zdolne do rozróżnienia kilku-kilkunastu poziomów szarości. Jednakże zastosowanie większej liczby poziomów ułatwia łatwiejszą obróbkę cyfrową i wykonanie bardziej zaawansowanych klasyfikacji. Obecne dane satelitarne zapisane są w kilku-kilkudziesięciu tysiącach stopni szarości

(Landsat ETM+ – 256 poziomów, QuickBird – 2048, Hyperion – 4096).

Rozdzielczość czasowa oznacza czas niezbędny do wykonania ponownego zobrazowania danego obszaru. Dla satelitów meteorologicznych jest on bardzo krótki (MSG – 15 min, Meteosat – 30 min), natomiast dla satelitów środowiskowych wynosi kilkanaście dni (Ikonos – 11 dni, Landsat – 16 dni, Hyperion 16 – dni).

Teledetekcja jest znaczącym narzędziem wspierającym badania środowiska. Operuje różnymi zakresami widma elektromagnetycznego, w zależności od konkretnych potrzeb oferuje zróżnicowane produkty. Wykorzystanie tej – jednej z najnowocześniejszych – technologii w znaczący sposób ułatwia poznanie środowiska przyrodniczego i przekształceń wywołanych przez człowieka oraz prowadzenie stałego monitoringu metodami w pełni zobjektywizowanymi, w skalach od lokalnych po globalne. W praktyce, aplikacyjne zastosowanie teledetekcji hiperspektralnej obejmuje szeroki zakres zagadnień badawczych, takich jak atomowa i molekularna struktura materii, diagnostyka plazmy, rozwój instrumentów, badanie materii oraz identyfikacja substancji. Spektroskopia (w tym obrazowa)⁵ jest przedmiotem badań nauk przyrodniczych, fizyki, chemii, inżynierii genetycznej,

⁵ W literaturze angielskiej teledetekcja hiperspektralna nazywana jest także *hyperspectral remote sensing* lub *Imaging Spectroscopy*, czyli spektroskopia obrazowa.

Tabela 2. Zastosowanie wybranych zakresów absorpcji promieniowania elektromagnetycznego przez molekuly i procesy biochemiczne wykorzystywane w badaniach hiperspektralnych środowiska

Table 2. Application of selected wavelengths for absorption analysis of molecules and biochemical processes in hyperspectral researches of environment

Długość fali (nm) Wavelength (nm)	Zastosowanie Application	Źródło informacji Information source
439	analiza absorpcji neoksantyny (ksantofil) <i>neoxanthin absorption analysis</i>	Ruban i inni, 1993
443	analiza absorpcji wiołaksantyny (ksantofil) <i>violaxanthin absorption analysis</i>	Ruban i inni, 1993
445	analiza absorpcji luteiny (ksantofil) <i>lutein absorption analysis</i>	Ruban i inni, 1993
446	analiza absorpcji a-karotenu <i>a-carotene absorption analysis</i>	Ruban i inni, 1993
463	analiza absorpcji b-karotenu <i>b-carotene absorption analysis</i>	Ruban i inni, 1993
470	analiza absorpcji karotenoidów ogółem <i>carotenoids absorption analysis</i>	Ruban i inni, 1993
530-630	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Gitelson, Merzlyak, 1997
531	analiza cyklu ksantofili i procesy absorpcji energii przez tylakoidy. Najczęściej stosowane miary to PRI (<i>Photochemical Reflectance Index</i>) i LUE (<i>photosynthetic Light Use Efficiency</i>) <i>analysis of xanthophylls' cycles and energy absorption by thylakoids. The most used indicators: PRI and LUE</i>	Barton, North, 2001
540	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Gitelson, Merzlyak, 1997
550	analiza zawartości chlorofilu, zakres do analiz chlorozy <i>chlorophyll content analysis, chlorosis analysis range</i>	Gitelson, Merzlyak, 1997, Adams i inni, 1999
555	normalizacja efektu wpływu atmosfery oraz analiza AVI (<i>Angular Vegetation Index</i>) <i>normalisation of atmospheric effect's influence and AVI analysis</i>	Plummer i inni, 1994; North, 2002
570	analiza cyklu ksantofili (podobnie jak zakres 531 nm). Wrażliwy na zawartość chlorofilu <i>analysis of xanthophylls' cycles (similar to 531 nm range). Sensitive for chlorophyll content</i>	Barton, North, 2001; Gitelson, Merzlyak, 1997
650	analiza chloroz <i>chlorosis analysis</i>	Adams i inni, 1999
663,2	analiza absorpcji chlorofilu a <i>chlorophyll a absorption</i>	Lichtenthaler, Wellburn, 1983
646,8	analiza absorpcji chlorofilu b <i>chlorophyll b absorption</i>	Lichtenthaler, Wellburn, 1983
670	normalizacja efektu glebowego i analizy AVI, kanał do analiz niewielkich ilości chlorofilu <i>normalisation of soil effect's influence and AVI analysis. Band for low chlorophyll content analysis</i>	Plummer i inni, 1994; North, 2002; Gitelson, Merzlyak, 1997
680	analiza absorpcji chlorofilu <i>chlorophyll absorption</i>	Datt, 2000
695	analiza stresu roślinnego PSI (760/695 nm) <i>Plant Stress Index</i>	Carter, 1994
697-713	analiza konarów drzew liściastych <i>deciduous' trees branches analysis</i>	Cochrane, 2002
680	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Datt, 1999
690	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Gitelson, Merzlyak, 1997
696-733	analiza drzew liściastych <i>deciduous' trees analysis</i>	Cochrane, 2000
700	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Gitelson, Merzlyak, 1997
703, 704	analiza stresu roślin (<i>red edge inflection</i>) <i>plant stress analysis</i>	Shaw i inni, 1998; Datt, 1999

710	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Gitelson, Merzlyak, 1997
719	analiza stresu roślin (<i>red edge inflection</i>) <i>plant stress analysis</i>	Shaw i inni, 1998
750, 754	analiza stresu roślin (<i>red edge inflection</i>) <i>plant stress analysis</i>	Datt, 1999
760/695	analiza stresu roślin <i>Plant Stress Index</i> <i>plant stress analysis</i>	Carter, 1994
842-950	analiza drzew liściastych <i>deciduous' trees analysis</i>	Cochrane, 2001
850	analiza zawartości chlorofilu <i>chlorophyll content analysis</i>	Datt, 1999
870	normalizacja efektu glebowego, AVI analiza <i>normalisation of soil effect's influence, AVI analysis</i>	Plummer i inni, 1994; North, 2002
900	analiza turgoru roślin (zawartość wody) <i>plant turgor analysis (water content)</i>	Fourty, Baret, 1998
970	analiza absorpcji wody w liściach <i>leaves' water absorption analysis</i>	Aldakheel, Danson, 1997
1240	analiza turgoru roślin iglastych <i>coniferous plant turgor analysis</i>	Dawson i inni, 1998
1380	analiza turgoru roślin (zawartość wody) <i>plant turgor analysis (water content)</i>	Fourty, Baret, 1998
1450	analiza absorpcji wody w liściach <i>leaves' plant turgor analysis</i>	Aldakheel, Danson, 1997
1510	analiza absorpcji białek i związków azotu w drzewach iglastych <i>protein and nitrogen absorption analysis of coniferous trees</i>	Dawson i inni, 1998
1630	normalizacja frakcji absorbowanej energii z zakresu fotosyntezy (fAPAR) <i>normalisation of fAPAR</i>	Plummer i inni, 1994; North, 2002
1650-1850	analiza zawartości wody w zbożach (pszenicy) <i>normalisation of water content in cereals (wheat)</i>	Tian i inni, 2001
1720	analiza zawartości ligniny i celulozy <i>lignin and cellulose content analysis</i>	Dawson i inni, 1998
1730	analiza suchych liści, absorpcja węglowodorów <i>dry leaves analysis, hydrocarbon absorption range</i>	Datt, 2000; Hoerig i inni, 2001
1870	analiza zawartości suchej masy <i>dry matter content analysis</i>	Fourty, Baret, 1998
1910	analiza turgoru roślin (zawartość wody) <i>plant turgor analysis (water content)</i>	Fourty, Baret, 1998
2160	analiza zawartości suchej masy <i>dry matter content analysis</i>	Fourty, Baret, 1998
2180	analiza absorpcji białek i związków azotu <i>protein and nitrogen absorption analysis</i>	Dawson i inni, 1998
2310	analiza suchych liści, absorpcja węglowodorów <i>dry leaves analysis, hydrocarbon absorption range</i>	Hoerig i inni, 2001; Fourty, Baret, 1998

astronomii, przemysłu spożywczego, przetwórczego oraz metalurgicznego (Kumar i inni, 2001). Techniki i metody teledetekcji hiperspektralnej, która w ostatnich latach przeżywa rozkwit, odgrywają ważną rolę w badaniach środowiska. Wynika to z postępów i rozwoju elektroniki, która zezwala na konstrukcję wielu przenośnych urządzeń do badań naziemnych, lotniczych i satelitarnych. Owocuje to zwiększeniem rozdzielczości spektralnej, radiometrycznej oraz terenowej pozyskiwanych danych. W przypadku naziemnych instrumentów hiperspektralnych standardem jest operowanie setkami, czy tysiącem bardzo wąskich kanałów w zakresie 350-2500 nm (Vane, Goetz, 1993). Jako przykład mogą służyć hiperspektralne spektrometry ASD

FieldSpec⁶. Wielowymiarowe obrazy hiperspektralne charakteryzują się dużą pojemnością informacyjną. Operowanie danymi wymaga zatem stosowania innych algorytmów i procedur niż miało to miejsce w przypadku wielospektralnych danych. Pozyskanie ciągłego widma, zapisanego na tysiącach stopni szarości pozwala na stosowanie np. koncepcji logiki rozmytej w analizie danych (Thenkabail i inni, 2004).

⁶ Instrument ten składa się z 3 detektorów (Si oraz 2x InGaAs), które rejestrują promieniowanie z rozdzielczością 3 nm w zakresie widzialnym bliskiej podczerwieni (do 1075 nm) i 10 nm w podczerwieni (1000-2500 nm). Dane techniczne pochodzą ze strony http://www.asdi.com/products_specifications-FS3.asp.

Liderem w rozwoju technik hiperspektralnych są Stany Zjednoczone, które rozpoczęły prace naukowe, konstrukcyjne oraz aplikacyjne nad wdrożeniem technologii hiperspektralnej do wojskowych oraz cywilnych zastosowań. Do najważniejszych amerykańskich osiągnięć zalicza się: oprogramowanie ENVI; biblioteki spektralne, np. ASTER Spectral Library, USGS Spectral Library; instrumenty do badań naziemnych (np. spektrometry GER oraz FieldSpec, które są podstawowym wyposażeniem każdego laboratorium zajmującego się technikami hiperspektralnymi), lotniczych (AVIRIS) i satelitarnych (Hyperion). Podobnych przykładów można podać znacznie więcej. Do wiodących ośrodków zajmujących się konstrukcją należy zaliczyć ośrodki australijskie, a szczególnie firmę inżynierską Integrated Spectronics Pty Ltd., która wyprodukowała powszechnie znany w Europie skaner hiperspektralny HyMap oraz obecnie testowany ARES, a także firmę HyVista, zajmującą się aplikacją danych teledetekcyjnych – w tym hiperspektralnych – do badania środowiska.

W Europie badaniom hiperspektralnym poświęca się wiele uwagi i finansuje się liczne przedsięwzięcia z tego zakresu. W skali europejskiej przełomowym momentem był rok 2000 oraz projekt *5th Frame Program of UE HPRI-CT-1999-00075: HySens – DAIS/ROSIIS Imaging Spectrometers at DLR*, który był przygotowany i koordynowany przez Niemiecką Agencję Kosmiczną DLR (Holzwarth i inni, 2004). W ramach tej inicjatywy spopularyzowana została idea badań hiperspektralnych, znacząca część europejskich laboratoriów teledetekcyjnych uzyskiwała dostęp do danych oraz algorytmów ich przetwarzania.

Dla europejskich ośrodków teledetekcyjnych ważna jest *Special Interest Group on Imaging Spectroscopy* w ramach *European Association of Remote Sensing Laboratories (EARSeL SIG IS)*. Grupa ta organizuje co dwa lata konferencje naukowe, gromadzące wielu specjalistów zajmujących się konstruowaniem urządzeń, tworzeniem oprogramowania oraz praktycznym i komercyjnym wykorzystaniem tych narzędzi. Konferencja taka odbyła się także w Polsce na Uniwersytecie Warszawskim w 2005 r. (*4th EARSeL Workshop on Imaging Spectroscopy*⁷; Zagajewski i inni, 2005). Spotkaniem tym towarzyszy wiele przedsięwzięć wyznaczających ramy pracy na kolejne lata.

W ostatnich latach zintensyfikowane zostały prace nad rozwojem technik hiperspektralnych, jako przykłady europejskiej myśli technologicznej mogą służyć kolejne projekty EU: HySens oraz HyEurope (podobnie jak wspomniany już HySens projekt ten był koordynowany przez DLR i bazował na zobrażeniach wykonanych przez skaner HyMap). Kolejne znaczące przedsięwzięcie to HYRESSA (*HYperspectral REmote Sensing in Europe*⁸). Celem projektu była identyfikacja

użytkowników i dostawców danych hiperspektralnych oraz analiza ich potrzeb; analiza jakości, standardów, dostępu, protokołów oraz zakresów spektralnych danych; budowa strategii szerokiego dostępu do technologii hiperspektralnej wśród europejskich użytkowników i potencjalnych klientów, szczegółowa analiza istniejących protokołów i standardów pozyskania danych, procedur przetwarzania i dokumentowania pomiarów terenowych; opracowanie dalekosiężnych planów rozwoju technik hiperspektralnych w Europie. Kolejny istotny projekt EU to Hyper-i-net (*Hyperspectral Imaging Network*⁹). Głównym celem tego przedsięwzięcia jest integracja europejskich ośrodków zajmujących się technikami hiperspektralnymi z zakresu konstruowania sensorów i przetwarzania danych, standaryzacja procedur od pozyskania informacji aż po wytworzenie wysoce specjalistycznych produktów bazujących na danych hiperspektralnych, utworzenie mostu pomiędzy metodami badawczymi wykorzystywanymi przez teledetekcję i inne dyscypliny nauki, transfer wiedzy i doświadczeń pomiędzy instytucjami badawczymi i naukowymi oraz przedsiębiorstwami. Jednym z istotnych punktów planu pracy tego projektu jest wykształcenie kilkunastu specjalistów z zakresu technik hiperspektralnych. W najbliższej perspektywie w Europie planowane są kolejne programy bazujące na nowych skanerach hiperspektralnych ARES¹⁰ oraz APEX¹¹, które obecnie są przygotowywane (APEX jest po pierwszych lotach testowych).

Poza wspomnianymi powyżej przykładami, rozwijane są w Europie inne instrumenty, np. system sensorów AISA (AISA+, AISA Eagle, AISA Hawk i AISA Dual) firmy SPECIM (Finlandia)¹². Pracują one w zakresie widzialnym i bliskiej podczerwieni (AISA+ 400-970 nm, maksymalnie do 244 kanałów spektralnych). Z innych systemów na uwagę zasługuje produkt firmy Norsk Elektro Optikk AS (NEO AS)¹³ – HySpex. Jest

⁹ Projekt Nr MRTN-CT-2006-035927, finansowany przez UE w ramach 6 Programu Ramowego (<http://www.hyperinet.eu>). Czas trwania 2007-2010.

¹⁰ Lotniczy, hiperspektralny spektrometr obrazujący (http://www.ares.caf.dlr.de/intro_en.html). Budowany na zlecenie DLR oraz GFZ Poczdam (Niemcy) przez Integrated Spectronics, Sydney, Australia. Sensor ma pracować w zakresie 0,45-2,45 μm oraz 8-13 μm , obrazując w 160 kanałach spektralnych.

¹¹ Lotniczy, hiperspektralny spektrometr obrazujący (<http://apex.vgt.vito.be/htdocs/modules/APEX>). Produkt będący wynikiem współpracy RSL Uniwersytetu w Zurichu (Szwajcaria) oraz VITO (Belgia). Spektrometr ma pracować w 300 kanałach spektralnych w zakresie 0,4 – 2,5 μm .

¹² (<http://www.specim.fi/index.html>). Misją firmy jest rozwój instrumentów do zastosowań przemysłowych i pomiarowych na potrzeby gospodarki oraz do badań teledetekcyjnych, w tym do badań hiperspektralnych. Sztandarowym instrumentem jest grupa urządzeń AISA, operujących w zakresie widzialnym, bliskiej i średniej podczerwieni, obrazujących maksymalnie w 560 kanałach spektralnych (<http://www.specim.fi/products-aisa.html>).

¹³ NEO AS – prywatna firma naukowo-badawcza ukierunkowana na badania z zakresu elektroniki i optyki. Obecnie fir-

⁷ 4th EARSeL Workshop on Imaging Spectroscopy <http://www.wgsr.uw.edu.pl/zts/workshop/index.html>.

⁸ HYRESSA. Projekt Nr 026194 finansowany przez UE w ramach 6 Programu Ramowego (<http://www.hyressa.net>). Czas trwania 2006-2008.

to hiperspektralna kamera pracująca w 160 pasmach z zakresu promieniowania widzialnego i bliskiej podczerwieni (do 1600 nm). Rozdzielczość spektralna wynosi 3,7 nm, a radiometryczna 12 bitów. Zarówno sama kamera, jak i system wspomagający pozyskiwanie i przetwarzanie danych obrazowych zasługuje na uwagę i należy się spodziewać, że w najbliższych latach nastąpi znaczący wzrost prac naukowo-aplikacyjnych przy udziale tego systemu. Kluczowym przedsięwzięciem jest przygotowanie hiperspektralnych systemów satelitarnych: niemieckiego EnMAP¹⁴ oraz

ma ta intensywnie rozwija instrumenty i metody na potrzeby teledetekcji środowiska, w tym teledetekcji hiperspektralnej (<http://www.neo.no/products/hyperspectral.html>).

¹⁴ Environmental Mapping and Analysis Program. Projekt niemieckiego narodowego satelity hiperspektralnego (<http://www.enmap.de>, <http://www.enmap.org>).

włoskiego PRISMA. Planuje się umieścić je na orbicie w roku 2011-12.

W Polsce dostępne są rozwiązania oferowane przez europejskie ośrodki, które realizują obecnie kilka dużych programów mających na celu integrację technologii z modułami przetwarzania danych i zastosowań aplikacyjnych. Rozwój ten jest stymulowany przez DLR (Niemcy), VITO (Belgia), INTA (Hiszpania) oraz ISA (Włochy). Jednostki te oferują pomoc w zaprojektowaniu lotu, wykonaniu zobrażeń i pomiarów terenowych, przetworzeniu danych i przygotowaniu produktów finalnych zgodnie z wymaganiami końcowego użytkownika. W wielu przypadkach koszty te pokrywane są przez UE. Mnogość zastosowań technik hiperspektralnych oraz dynamika rozwoju pociąga konieczność specjalizacji poszczególnych ośrodków naukowych oraz współdziałania w przygotowywaniu nowych rozwiązań.

Rejestracja lotniczych obrazów hiperspektralnych

Zobrazowania hiperspektralne są definiowane jako równoczesne pozyskanie obrazów w wielu bardzo wąskich, ciągłych zakresach spektralnych (Goetz i inni, 1985). Rejestracja promieniowania elektromagnetycznego przez sensory hiperspektralne odbywa się na drodze pasywnego zapisu spektrum odbitego od powierzchni terenu. Geneza badań z wykorzystaniem lotniczych systemów hiperspektralnych sięga lat 1970. (van der Meer, de Jong, 2001). Pierwsze zobrazowania rozwijane były do celów wojskowych (detekcja obiektów militarnych ukrytych wśród roślinności). Cywilne prace nad rozwojem technik hiperspektralnych rozpoczęły się dekadę później, kiedy to Geophysical Environmental Research Company rozpoczęła prace nad jednowymiarowym spektrometrem rejestrującym sygnał profilu wzdłuż linii lotu samolotem. Prace te zaowocowały stworzeniem w 1981 r. GERS (*Geophysical Environmental Research Spectroradiometer*; Kruse i inni, 1999). Był to lotniczy nieobrazujący spektrometr do wykonywania profili spektralnych w zakresie 1,96-2,5 μm , pozyskujący 86 ciągłych kanałów o szerokościach połówkowych filtrów 8,6 nm. Pole rejestracji sygnału wynosiło 20 m (GFOV) z 20-metrowymi przerwami wzdłuż linii lotu (Collins i inni, 1981). Satysfakcjonujące wyniki uzyskiwane ze spektrometru zaowocowały stworzeniem skanera AIS (*Airborne Imaging Spectrometer*). Skaner AIS-1 (*NASA Jet Propulsion Laboratory*) rejestrował obraz składający się z 32 pikseli położonych w linii (pole widzenia 3,7 stopnia), prostopadle do kierunku lotu o rozmiarach terenowych 10-15 m, w 128 ciągłych kanałach o szerokościach połówkowych 9,3 nm w zakresie 1,2-2,4 μm . Unowocześniona wersja skanera wprowadzona została w 1986 r., AIS-2 rejestrował 64 piksele o rozdzielczości 10,6 nm w zakresie 0,8-2,4 μm (Chiu, Collins, 1978).

Jednakże za pierwsze urządzenie obrazujące uważa się kanadyjski *Fluorescence Line Imager* (FLI), zwany także jako PMI (*Programmable Line Imager*). Spek-

trometr ten został opracowany przez Department of Fisheries and Oceans w 1981 r. (Kramer, 1994; van der Meer, de Jong, 2001).

W roku 1984 grupa niezależnych specjalistów NASA rozpoczęła prace nad kolejnym sensorem lotniczym AVIRIS (*Airborne Visual and Infra-Red Imaging Spectrometer*; Vane i inni, 1988). Pierwsze loty techniczne i referencyjne badania laboratoryjne rozpoczęły się w zimie i na wiosnę 1987 r., rok później program ten był już realizowany operacyjnie. Bardzo obiecujące efekty prac pozwoliły na rozwój programu do różnych celów (Proceedings of the AVIRIS Performance, 1988). Skaner ten okazał się znaczącym krokiem w stronę popularyzacji zobrazowań hiperspektralnych w USA. Po kilku modyfikacjach technicznych, sensor ten pracuje wykonując zobrazowania w zakresie 380-2500 nm (224 kanały spektralne) o rozdzielczości radiometrycznej 10 nm (kalibracja każdego kanału dokonywana jest z dokładnością 1 nm), rozdzielczość terenowa zależy od rodzaju samolotu, na którym jest instalowany skaner (przy wysokości lotu wysokości 65 000 stóp średnia wielkość piksela zawiera się w zakresie 17-20 m, a szerokość zobrazowania wynosi 10,5 km)¹.

AVIRIS, podobnie jak inne skanery lotnicze zalicza się do szerokokątnych detektorów, wynika to z szerokiego kąta rejestracji sygnału, które w tym urządzeniu wynosi 34 stopnie (przy pełnej rejestracji (677 pikseli)). Jest to tzw. całkowite pole widzenia (*total field of view*), natomiast chwilowe pole widzenia (*IFOV*) wynosi 1 mradian. Tempo skanowania terenu wynosi 12Hz, rozdzielczość spektralna – 12 bitów (tab. 1).

Obecnie skanery wielo- i hiperspektralne są konstruowane zarówno przez narodowe agencje kosmiczne, jak i małe prywatne firmy. W pracach tych przodują

¹ Dane techniczne pochodzą ze strony AVIRIS: <http://aviris.jpl.nasa.gov/html/aviris.overview.html>.



Ryc. 2. Hiperspektralne skanery lotnicze wykorzystywane przez DLR⁴: A – DAIS 7915, B – ROSIS, C – HyMap, D – ARES (źródło: Mueller, 2005)

Fig. 2. Hyperspectral airborne scanners operated by the DLR (Germany): A – DAIS 7915, B – ROSIS, C – HyMap, D – ARES (source: Mueller, 2005)

przede wszystkim Stany Zjednoczone, Australia oraz państwa Europy Zachodniej (tabela 3)². Standardem jest dostarczanie odbiorcom także kompletnych algorytmów przetwarzania danych. Część z nich jest w pełni komercyjnym oprogramowaniem dedykowanym tylko do danych hiperspektralnych (np. PARGE, ATCOR – Szwajcaria, ENVI – USA).

Z punktu widzenia europejskich sensorów hiperspektralnych, do najważniejszych ze względu na liczbę wykonanych zobrazowań należy zaliczyć DAIS 7915, Rosis, AISA, HyMap (ryc. 2), przygotowywany obecnie ARES, APEX oraz satelitalny skaner EnMap. Systemy lotnicze (w porównaniu do sensorów satelitalnych) pozyskują

jakościowo znacząco lepsze obrazy. Wynika to z krótszej drogi promieniowania pomiędzy obiektem a detektorem. W przypadku zobrazowań lotniczych stosunek sygnału do szumu (SNR) jest znacząco wyższy, umożliwiając zwiększenie rozdzielczości terenowej do 1-5 m, przy rozdzielczości spektralnej wynoszącej około 2-10 nm (np. ROSIS). Dla przykładu hiperspektralny skaner satelitalny Hyperion, który zlokalizowany jest powyżej górnej warstwy atmosfery, rejestruje 10 000 razy słabsze sygnały niż detektory lotnicze operujące na wysokości do 5 km (Kumar i inni, 2001). Rozdzielczość spektralna Hyperiona³ wynosi 220 kanałów (0,4-2,5 μm), szerokość

² Spektrometry obrazujące: Hyperion, AVIRIS – NASA, USA; ARES, DAIS 7915, Rosis – DLR, Niemcy; CASI – Natural Environment Research Council i UK Environment Agency, Wielka Brytania, AISA – Finlandia, APEX – Szwajcaria i Belgia, bądź spektrometry polowe firm Analytical Spectral Devices Inc. lub Group for Environmental Research, Earth Resources Exploration Consortium.

³ Jako ciekawostkę można podać, że średnie zapotrzebowanie Hyperiona (EnMAPu) na prąd wynosi 51 W (170 W EnMap) na orbitę, natomiast w szczytowym momencie 126 W (221 W EnMap), masa – 49 kg (150 kg EnMap).

⁴ DLR e.V. Oberpfaffenhofen – Niemiecka Agencja Kosmiczna. Jeden z najważniejszych europejskich dostawców technologii hiperspektralnej, koordynator wielu europejskich projektów, np. HySens, HyEurope, HYRESSA.

Tabela 3. Przegląd hiperspektralnych sensorów

Table 3. Overview of hyperspectral sensors

Nazwa <i>Name</i>	Pełna nazwa <i>Full name</i>	Producent <i>Manufacturer</i>	Operator <i>Operator</i>	Liczba kanałów <i>Number of bands</i>	Zakres spektralny (nm) <i>Spectral range (nm)</i>
AAHIS	Advanced Airborne Hyperspectral Imaging System	SETS Technology		288	432-832
AHS	Airborne Hyperspectral Scanner	Daedalus Enterprises, Inc.		48	433-12700
AIP	Airborne Instrument Program	Lockheed Martin	NASA, Johnson Space Center	brak danych	2000-6400
AIS-1	Airborne Imaging Spectrometer	NASA, JPL	NASA, JPL	128	900-2100, 1200-2400
AIS-2	Airborne Imaging Spectrometer	NASA, JPL	NASA, JPL	128	800-1600, 1200-2400
AISA	Airborne Imaging Spectrometer for Applications	Specim, Ltd.	Specim, Ltd., 3Di, Inc., Galileo Corp.	286	450-1000
AISA Dual	Airborne Imaging Spectrometer for Applications (sensor z połączenia systemu AISA Eagle and AISA Hawk)	Specim Ltd.		498	400-2450
AISA Thermal	Airborne Imaging Spectrometer for Applications	Specim Ltd.		84	8000-12000
AMS	Airborne Modis Simulator (zainstalowany na Daedalus AADS-1268)		NASA	50	530-15500
AMSS	Airborne Multispectral Scanner MK-II	Geoscan Pty Ltd.	Geoscan Pty Ltd.	46	500-12000
APEX	Airborne Prism Experiment	RSL/VITO	VITO	300	400-2500
ASAS	Advanced Solid State Array Spectroradiometer	NASA Laboratory for terrestrial Physics	NASA Goddard Space Flight Center	62	404-1020
ASI	Airborne Spectral Imager	Norsk Elektro Optikk AS (NEO) / Norwegian Defense Research Establishment (FFI)		brak danych	400-1700
ASTER Simulator	ASTER Simulator	GER Corp.	JAPEX Geosciences Institute, Tokio	24	760-12000
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer	NASA, JPL	NASA Ames	224	400-2450
CAESAR	CCD Airborne Experimental Scanner for Applicators in Remote Sensing	NLR		12	520-780
CASI	Compact Airborne Spectrographic Imager	Itres Research		288	430-870
CASI-2	Compact Airborne Spectrographic Imager	Itres Research		288	400-1000
CASI-3	Compact Airborne Spectrographic Imager	Itres Research		288	400-1050
CHRISS	Compact High Resolution Imaging Spectrograph Sensor	Science Applications Int. Corp. (SAIC)	SETS Technology, Inc.	40	430-860
CIS	Chinese Imaging Spectrometer	Shanghai Inst. Of Technical Physics		91	400-12500
DAIS 21115	Digital Airborne Imaging Spectrometer	GER Corp.		211	400-12000
DAIS 3715	Digital Airborne Imaging Spectrometer	GER Corp.		37	400-12000

DAIS 7915	Digital Airborne Imaging Spectrometer	GER Corp.	DLR, Niemcy	79	400-12000
EPS-A	Environmental Probe System	GER Corp.		32	400-12000
FLI / PMI	Flourocence Line Imager / Programmable Multispectral Imager	Moniteq Ltd.	Department of Fisheries and Oceans	228	430-805
FTVFHSI	Fourier Transform Visible Hyperspectral Imager	Kestrel Corp., FIT		256	440-1150
GERIS	Geophysical and Environmental Research Imaging Spectrometer	GER Corp.		63	400-2500
HIRIS	High Resolution Imaging Spectrometer	NASA	NASA EOS	192	400-2500
HSI	Hyperspectral Imager	TRW Space & Technology Division	NASA	384	400-2500
HRIS	High Resolution Imaging spectrometer	ESA	ESA POEM		450-2350
HYDICE	Hyperspectral Digital Imagery Collection Experiment	Naval Research Laboratory	ERIM	210	413-2504
HyMAP	Hyperspectral Mapper (w Stanach Zjednoczonych znany jako Probe-1)	Integrated Spectronics, Ltd.	HyVISTA/ DLR w Europie / ESSI w USA	128	400-2500+
Hyperion	Hyperion	TRW Space & Technology Division	NASA Goddard Space Flight Center	220	400-2500
HySpex	HySpex Hyperspectral Cameras (zestaw 4 modułów z zakresu VIS, SWIR)	Norsk Elektro Optikk AS (NEO)		128-256	400-2500
IISRB	Infrared Imaging Spectrometer	Bomem		1720	3500-5000
IMSS	Image Multispectral Sensing	Pacific Advanced Technology		320	2000-5000
IRIS	Infrared Imaging Spectroradiometer	ERIM		256	2000-15000
ISM	Imaging Spectroscopic Mapper	DESPA		128	800-3200
LEISA	Linear Etalon Imaging Spectral Array	NASA Goddard Space Flight Center	NASA	256	1000-2500
LIVTIRS 1	Livermore Imaging Fourier Transform Imaging Spectrometer	Lawrence Livermore		brak danych	3000-5000
LIVTIRS 2	Livermore Imaging Fourier Transform Imaging Spectrometer	Lawrence Livermore Labs		brak danych	8000-12000
MAIS	Modular Airborne Imaging Spectrometer	Shanghai Institute of Technical Physics		71	440-11800
MAMS	Multispectral Atmospheric Mapping Sensor	Daedalus Enterprise Inc.		12	VIS/NIR
MAS	MODIS Airborne Simulator	Daedalus Enterprise Inc.	NASA Ames & GSFC	50	530-14500
MERIS	Medium Resolution Imaging Spectrometer	ESA		15	400-1050
MIDIS	Multiband Identification and Discrimination Imaging Spectroradiometer	Surface Optics Corp.	JPL	256	400-30000
MIVIS	Multispectral Infrared and Visible Imaging Spectrometer	Daedalus Enterprise Inc.	CNR, Rome	102	433-12700
MODIS	Moderate Resolution Imaging Spectrometer	NASA	EOS	36	415-14240
OMIS	Operative Modular Airborne Imaging Spectrometer	Shanghai Institute of Technical Physics, Shanghai Xiantong Institute of Information Technology		128	400-12000

PROBE-1	PROBE-1	Integrated Spectronics, Ltd.	Earth Search Sciences, Inc., Australia	100-200	400-2400
ROSIS	Reflective Optics System Imaging Spectrometer	DLR, GKSS, MBB	DLR	128	450-850
SASI	Shortwave (Infrared) Airborne Spectrographic Imager	Itres Research		160	850-2450
SFSI	SWIR Full Spectrographic Imager	CCRS	CCRS	122	1200-2400
SMIFTS	Spatially Modulated Imaging Fourier Transform Spectrometer	Hawaii Institute of Geophysics		75	1000-5000
SSTI HSI	Small Satellite Technology Initiative Hyperspectral Imager	TRW Inc.	NASA	384	400-2500
TIMS	Thermal Infrared Multispectral Scanner	NASA	NASA	6	8200-12200
TRWIS III	TRW Imaging Spectrometer	TRW Inc.		384	300-2500
VIFIS	Variable Interference Filter Imaging Spectrometer	Univ. of Dundee		60	440-890
VIMS-V	Visible Infrared Mapping Spectrometer	ASI	NASA Cassini Mission	512	300-1050
WIS	Wedge Imaging Spectrometer	Hughes Santa Barbara Research Center		170	400-2500
WPHI	Wide-view Pushbroom Hyperspectral Imagery	Shanghai Institute of Technical Physics, Shanghai Xiantong Institute of Information Technology		244	394-891

Źródło: Kramer, 1994; Schaepman, 1996; Walthall, 2008, zaktualizowane.

Source: Kramer, 1994; Schaepman, 1996; Walthall, 2008, upgraded.

filtrów 10 nm, absolutna dokładność radiometryczna 6%, rozdzielczość radiometryczna 12 bitów, rozdzielczość terenowa 30 m (przy wysokości 705 km), IVOF 42,5 mikroradiana, a wielkość sceny 7,5 x 100 km.

Zainstalowanie cyfrowych skanerów na pokładach samolotu generuje wiele problemów podczas przetwarzania danych obrazowych. Powodem są wychylenia samolotu we wszystkich kierunkach i trudności z zachowaniem prostej linii lotu oraz niejednorodność atmosfery, w której odbywa się lot. W przypadku stosowania skanerów rejestrujących obraz piksel po pikselu lub linia po linii, powoduje to przesunięcia obrazu (poszczególne piksele na zobrazowaniu nie znajdują się tam, gdzie wynikałoby to z ich topologicznej lokalizacji). Defekty te są eliminowane podczas geometryzacji, któ-

ra w większości przypadków odbywa się w specjalnych pakietach oprogramowania i jest tzw. parametryczną geometryzacją.

Problemu tego nie obserwuje się na hiperspektralnych zobrazowaniach satelitarnych. Wynika to z braku obecności atmosfery i procedurę korekcji geometrycznej można przeprowadzić według standardowych algorytmów.

Podsumowując należy stwierdzić, że zobrazowania hiperspektralne są obecnie dostępne głównie za sprawą skanerów lotniczych. Algorytmy przetwarzania danych są intensywnie rozwijane, owocuje to popularyzacją danych oraz wyników, poszerzając jednocześnie grono odbiorców – zarówno naukowych, jak i komercyjnych.

Podstawy metodyczne klasyfikacji danych hiperspektralnych

W niniejszym rozdziale zaprezentowano algorytmy, które posłużyły do klasyfikacji danych DAIS 7915 obszaru Tatr Wysokich. Do przygotowania wzorca do uczenia sieci wybrano homogeniczne spektralnie poligony poszczególnych zbiorowisk roślinnych. Były to piksele, których odpowiedź spektralna pochodziła tylko od danego, analizowanego zbiorowiska roślinnego (piksele czyste spektralnie, tzw. *endmembers*). Procedura ta bazowała na pakiecie ENVI i analizie PPI (*Pixel Purity Index*). Wyniki analizy PPI zostały nałożone na mapę roślinności rzeczywistej (Kozłowska, 2006) i załadowane w pamięć odbiornika GPS Trimble GeoXT w celu ich rzeczywistej lokalizacji podczas badań terenowych. Z terenowego rozpoznania obiektów wybrano poligony, które posłużyły do uczenia sieci neuronowych.

W kolejnym kroku wytypowane poligony posłużyły do wyboru charakterystyk spektralnych spośród reprezentujących je pikseli czystych spektralnie. Uzyskane charakterystyki wykorzystano do wykonania półautomatycznej klasyfikacji SAM (*Spectral Angle Mapper*). Algorytm ten pozwolił wybrać obszary¹ zgodne spektralnie z poligonami pozyskanymi w trakcie badań terenowych do uczenia sztucznych sieci neuronowych. Po wykonaniu klasyfikacji SAM, uzyskane wyniki zostały ponownie załadowane do odbiornika GPS i w trakcie kolejnej sesji terenowej pozwoliły wybrać większą liczbę poligonów poszczególnych zbiorowisk roślinności rzeczywistej do utworzenia wzorca weryfikującego dane poklasyfikacyjne z symulatora fuzji ARTMAP.

Wprowadzenie każdego dodatkowego kanału obrazu do symulatora sztucznych sieci neuronowych powoduje zwiększenie liczby neuronów, co rozbudowuje sieć, zwiększając liczbę powiązań i komplikując możliwości przesyłania sygnałów. W efekcie wydłuża to proces klasyfikacji, dlatego istotne jest zredukowanie liczby


kanalów najmniej informacyjnych. Procedura ta wykonywana jest poprzez analizę informacyjności poszczególnych kanałów lub też dekorelację szumu zawartego w poszczególnych kanałach i analizę głównych składowych (PCA), jest to tzw. transformacja Minimum Noise Fraction (MNF). Efektem tej transformacji jest utworzenie jakościowo nowych kanałów MNF, które pozwalają wybrać najmniej skorelowane informacyjnie kanały obrazowe, ograniczając znacząco liczbę powiązań w sieci neuronowej (kompresja danych).

Do klasyfikacji danych hiperspektralnych wykorzystane zostały 2 symulatory sztucznych sieci neuronowych MLP (perceptron wielowarstwowy ze wsteczną propagacją błędów) oraz fuzji ARTMAP (FAM). Pierwszy symulator dostępny jest w darmowym pakiecie SNNS, drugi natomiast został udostępniony przez prof. Paolo Gambę (Uniwersytet w Pawii, Włochy). Właściwa klasyfikacja została wykonana w FAM, wynikało to głównie z szybszego, prostszego przygotowania danych (zarówno do klasyfikacji, jak i wizualizacji uzyskanych wyników). Symulator MLP został wykorzystany na wstępnym etapie klasyfikacji do określenia optymalnej architektury sieci (dobór liczby kanałów oraz jakość klasyfikacji względem liczby wykorzystanych danych). Zaletą symulatora MLP z pakietu SNNS jest możliwość dowolnego przerywania procesu klasyfikacji i ponownego uruchamiania wytrenowanej sieci. Ma to ogromne znaczenie w automatyzacji klasyfikacji tych samych klas na różnych zdjęciach tego samego sensora, gdyż raz wytrenowana sieć może zostać wykorzystana do klasyfikacji tej samej formy lub obiektu na różnych scenach (po uprzednim wykonaniu korekcji atmosferycznej).

Wskaźnik czystości piksela PPI (Pixel Purity Index)

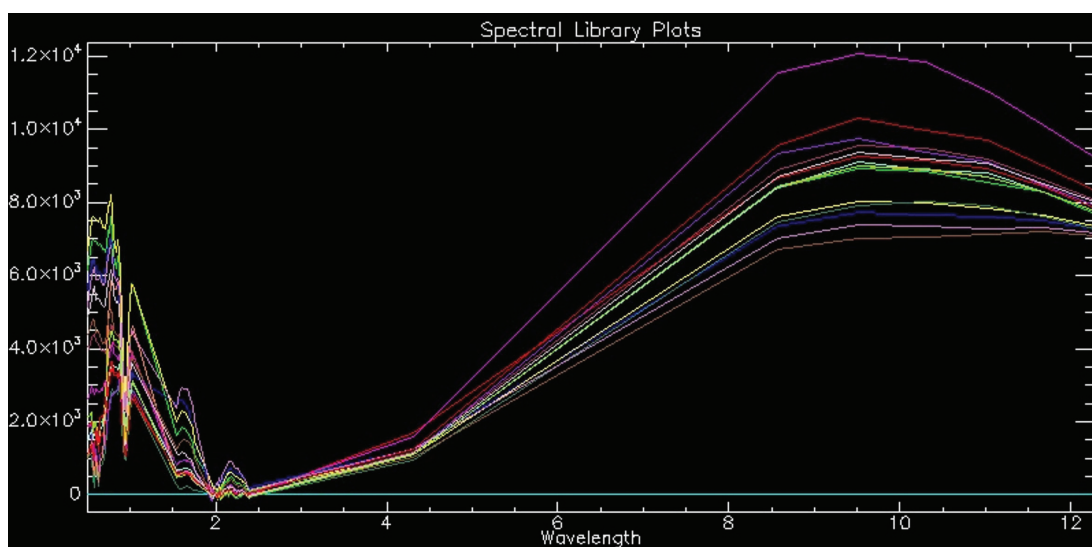
Techniki hiperspektralne pozwalają na ekstrakcję obiektów z obrazów (*feature extraction*). Jednym

¹ Piksele po transformacji PPI i weryfikacji terenowej na zgodność występowania z danym zbiorowiskiem roślinności rzeczywistej.



Ryc. 3. Rzut 3-wymiarowej przestrzeni (xyz) utworzonej z 1000 pikseli w projekcji kanałów 1, 2 i 3 MNF na płaszczyznę. Barwne piksele oznaczają piksele czyste spektralnie (tzw. *endmembers*)

Fig. 3. Projection of 3D space, which is built from 1000 pixels of MNF 1,2,3 bands. Pixels of *endmembers* are colored



Ryc. 4. Wybrane charakterystyki spektralne z pikseli czystych spektralnie pozyskane z analizy PPI (*endmembers*) z obrazu DAIS 7915 do klasyfikacji SAM


Fig. 4. Selected spectral characteristics derived from *endmembers* (PPI analysis) from DAIS 7915 images for SAM classification

z podstawowych algorytmów jest identyfikacja homogenicznych pikseli, które służą jako wzorce klasyfikacji poszczególnych obiektów (Kruse i inni, 1993; Boardman, 1994; Boardman, Kruse, 1994; Schwengerdt, 1997). Cała grupa algorytmów zajmujących się pozyskaniem takich wzorcowych pikseli i charakterystyk spektralnych nosi ogólną nazwę algorytmów ekstrakcji pikseli czystych spektralnie (EEAs²), a opracował je J.W. Boardman (Kruse i inni, 1993; Boardman, 1994).

² Endmember Extraction Algorithms.

Wskaźnik czystości piksela (PPI)³ jest obliczany w kolejnych rotacjach n -wymiarowej przestrzeni (n odpow-

³ Dzięki ogólnej dostępności algorytmów oraz kodów źródłowych transformacji PPI (w środowisku C++, IDL oraz Matlab) istnieje obecnie szereg modyfikacji PPI, do których należy zaliczyć algorytm Fast Iterative PPI (FIPPI). Wskaźnik FIPPI został zaproponowany przez C.-I. Chang, A. Plaza (2006) i należy do tzw. wirtualnej wymiarowości przestrzeni (VD – Virtual Dimensionality) (Chang, 2003; Chang, Du, 2004). Algorytm FIPPI bazuje na wykonywaniu kolejnych, niezależnych iteracji, co pozwala na szybszą oraz dokładniejszą inicjalizację procedur poszukiwania pikseli czystych spektralnie.



Ryc. 5. Fragment obrazowania DAIS 7915 Doliny Gąsienicowej po transformacji PPI. Jasne obszary przedstawiają homogeniczne spektralnie piksele

Fig. 5. A part of Gąsienicowa Valley on the DAIS 7915 after the PPI transformation. Bright polygons present homogeneous spectrally pixels

wiada liczbie kanałów) na przypadkowo generowanych wektorach. Piksele, które znajdują się w najbardziej zewnętrznych częściach wielowymiarowego histogramu, są zapisywane jako czyste spektralnie⁴ (ryc. 3; Boardman, Kruse, 1994; Zagajewski i inni, 2009). Aby przyspieszyć ten proces wykonuje się redukcję zbędnych kanałów, np. za pomocą transformacji MNF (*Minimum Noise Fraction*). Pierwsze kanały MNF (po transformacji) zawierają najmniej skorelowane informacje względem kanałów, które posłużyły do wykonania transformacji⁵. Zautomatyzowanym algorytmem analizy pikseli jest APPI (*Automatic Pixel Purity Index*), procedura opracowana na Uniwersytecie Maryland (Chaudhry, 2005). Metoda APPI polega na tym, że w sposób automatyczny inicjuje się kilka oddzielnych procedur wyłaniania pikseli czystych spektralnie. Do fazy finałowej algorytmu kierowane są tylko piksele wyłonione we wszystkich pojedynczych analizach.

Wybór pikseli metodą PPI pozwala na wyróżnienie na obrazie pól treningowych dowolnie wybranych klas, np. form pokrycia terenu czy zbiorowisk roślinnych (ryc. 4).

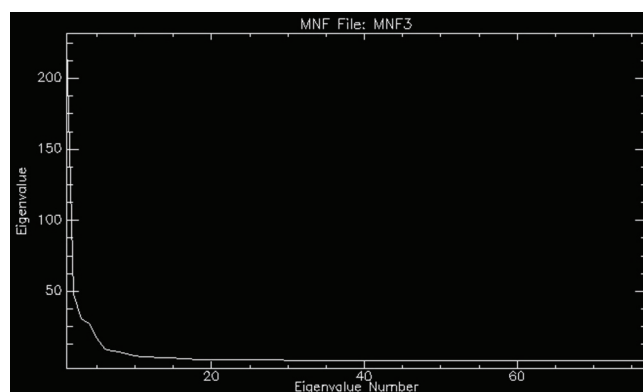
Końcowe etapy transformacji PPI pozwalają przeprowadzić jakościową analizę wyekstrahowanych pikseli (ryc. 5).

⁴ Wartość PPI zależy także od liczby wykonanych iteracji reprojekcji pikseli w n -wymiarowej przestrzeni i założonych progów położenia wektorów, na które są rzutowane piksele.

⁵ Proces MNF polega na jednoczesnej kompresji danych i eliminacji najbardziej zasumionych kanałów (analiza SNR – *Signal to Noise Ratio*).

Transformacja Minimum Noise Fraction (MNF)

Źródła transformacji MNF sięgają końca lat 1980. kiedy to zespół A.A. Greena (1988) poszukiwał alternatywnych algorytmów do analizy głównych składowych (PCA⁶) w celu redukcji 10 kanałowych danych ATM⁷, które miały posłużyć łączeniu z innymi danymi. Główna idea MNF polegała na wykonaniu podwójnej analizy głównych składowych PCA. Obecnie w pierwszym etapie analizowana jest macierz kowariancji szumu w celu jego dekorrelacji i przeskalowania, a w drugim etapie wykonywana jest klasyczna analiza PCA. Analiza oraz usunięcie szumu odbywa się za pomocą tzw. metody przesunięcia różnic (*shift difference method*). Polega ona na stworzeniu wirtualnego szumu (oscylacji sygnału wokół wybranej wartości) danego kanału i porównaniu go ze zmiennością sygnału każdego kolejnego pikseli rzeczywistego zobrazowania. Koncepcja MNF, polega na liniowej transformacji głównych składowych⁸ pod kątem analizy wskaźnika sygnał/szum. Efektem jest zestaw nowych danych, które są uporządkowane względem szumu. Do analiz wykorzystuje się liczbę kanałów MNF wskazaną przez wypoziomowanie się linii informacyjności (w niniejszym opracowaniu wykorzystanych zostało 20 pierwszych kanałów MNF, ryc. 6). Pierwsze kanały MNF są pozbawione szumu i zawierają najmniej skorelowane informacje poszczególnych kanałów (ryc. 7). Pozwala to na wykorzystanie do analiz mniejszej liczby kanałów (Olesiuk, Zagajewski, 2008) niż by miało to miejsce po zastosowaniu innych algorytmów kompresji danych (Ramachandra, Uttam, 2005). W przypadku wykorzystania symulatorów sztucznych sieci neuronowych jest to znaczące ułatwienie, gdyż ilość wprowadzanych do symulatora sygnałów redukuje czas procesu uczenia i klasyfikacji sieci.




Ryc. 6. Wykres informacyjności kolejnych kanałów MNF 5 linii DAIS 7915 (oś X – kolejne kanały MNF)

Fig. 6. Eigenvalue of the MNF transformation of the DAIS 7915 flight line no. 5

⁶ Principal Component Analysis.

⁷ Airborne Thematic Mapper.

⁸ Gdyby wartość szumu była identyczna we wszystkich kanałach spektralnych zobrazowania, transformacja MNF odpowiadałaby transformacji głównych składowych PC (Green i inni, 1988).



Ryc. 7. Fragment 5 linii zobrazowania DAIS 7915 po transformacji MNF: A – 1 kanał MNF, B – 10 kanał MNF, C – 20 kanał MNF, D – 30 kanał MNF

Fig. 7. A part of the 5th flight line of the DAIS 7915 image after MNF transformation: A – 1st MNF band, B – 10th MNF band, C – 20th MNF band, D – 30th MNF band

Klasyfikacja Spectral Angle Mapper (SAM)

Koncepcja klasyfikacji wykorzystującej cechy spektralne obiektu, zapisane w bardzo wielu kanałach tego samego piksela, pojawiła się w laboratoriach Centre for the Study of Earth from Space (CSES) Cooperative Institute for Research in Environmental Sciences (CIRES) University of Colorado na początku lat 1990. Bazowano wtedy na pierwszych hiperspektralnych zobrazowaniach

GERIS, HIRIS⁹, AIS oraz AVIRIS (Kruse i inni, 1993; Kruse, Lefkoff, 1993). Jednym z przełomowych algorytmów tego pakietu EEAs (*Endmember Extraction Algorithms*) był *Spectral Angle Mapper* (SAM)¹⁰ opra-

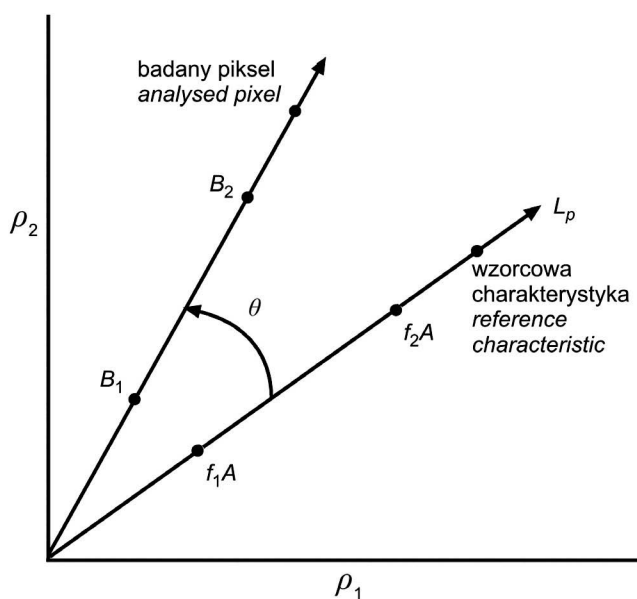
⁹ High Resolution Imaging Spectrometer.

¹⁰ Pomysł ten był rozwijany w języku programowania IDL na platformie UNIX w pakiecie Spectral Image Processing System (SIPS).

cowany przez dr J.W. Boardmana, stypendystę CIRES (Boardman, Kruse, 1994).

Klasyfikator SAM jest nadzorowaną i automatyczną metodą do bezpośredniego porównywania spektrów, pozyskanych z każdego piksela obrazu hiperspektralnego, z dowolnym wzorcem (np. z pomiarów laboratoryjnych, naziemnych) lub badanego obrazu (najczęściej z tzw. pikseli czystych spektralnie). Analizowane spektrum danego piksela (B) i referencyjna charakterystyka spektralna (A) (np. piksela czystego spektralnie lub charakterystyki z biblioteki spektralnej) są traktowane jako wektory spektralne, pomiędzy nimi istnieje kąt spektralny (θ). Na osiach x, y (ryc. 8) zaprezentowane zostały współczynniki odbicia (ρ_1, ρ_2) dla kolejnych kanałów. Spektrum A jest wzorcem do porównania charakterystyki spektralnej danego piksela (B), f reprezentuje frakcję piksela czystego spektralnie (wzorca). Odległość pomiędzy punktami f_1A-B_1 i f_2A-B_2 określa różnice spektralne w poszczególnych długościach fal danych kanałów obrazu. Błąd odległości pomiędzy kanałami spektralnymi obrazu jest mierzony wartością RMSE (Kruse i inni, 1993; van der Meer i inni, 1997).

Pierwsze klasyfikacje SAM z wykorzystaniem pikseli czystych spektralnie i grupowaniu ich w biblioteki spektralne były prowadzone w latach 1980. w Stanach Zjednoczonych. Pionierskie prace dotyczyły identyfikacji minerałów (Goetz i inni, 1985; Lang i inni, 1987; Pieters, Mustard, 1988; Kruse, 1988; Kruse, Lefkoff, 1993; Crowley, 1993; Boardman, Kruse, 1994), roślinności (Gamon i inni, 1993; Roberts i inni, 1993; Elvidge i inni, 1993), pokrywy śnieżnej i lodowców (Nolin, Dozier, 1993), gazów zawartych w atmosferze (Gao, Goetz, 1990; Carrère, Conel, 1993), wód powierzchniowych (Hamilton i inni, 1993; Carder i inni, 1993).



Ryc. 8. Porównanie charakterystyk spektralnych pozyskanych ze wzorca oraz klasyfikowanego piksela (źródło: Kruse i inni, 1993; Dennison i inni, 2004, zmienione)

Fig. 8. Comparison of spectral characteristics of an analysed pixel and a reference characteristic (source: Kruse et al., 1993; Dennison et al., 2004, modified)

Długość wektora spektralnego L_p określa się na podstawie wzoru (1), gdzie M oznacza liczbę kanałów, natomiast kąt spektralny θ pozwala obliczyć zależność (2) (Kruse i inni, 1993):

$$L_p = \sqrt{\sum_{\lambda=1}^M \rho_{\lambda}^2} \quad (1)$$

$$\theta = \cos^{-1} \left(\frac{\sum_{\lambda=1}^M \rho_{\lambda} \rho'_{\lambda}}{L_p L_{\rho'}} \right) \quad (2)$$

gdzie:

θ – kąt spektralny (błąd metryczny SAM),

L_p – długość wektora spektralnego wzorca,

$L_{\rho'}$ – długość modelowanego wektora z danego piksela,

ρ_{λ} – współczynnik odbicia dla danej długości fali charakterystyki wzorcowej,

ρ'_{λ} – współczynnik odbicia dla danej długości fali danego piksela.

Wartość kąta spektralnego θ podaje tylko różnicę pomiędzy spektrami (danego piksela i wzorca), natomiast długość wektora podaje informację o albedo spektralnym. W przypadku klasyfikacji, gdy wartość kąta spektralnego θ znajduje się poza zadaniem przez użytkownika zakresem danej klasy, dany piksel jest nieklasyfikowany (Dennison i inni, 2004).

Proces analizy podobieństwa charakterystyk spektralnych podczas klasyfikacji SAM przebiega w dwóch etapach (Kruse i inni, 1993; Schwarz, Staenz, 2001):

- określenie błędu metrycznego SAM (kąta spektralnego θ),
- zakwalifikowanie lub odrzucenie danego piksela do/z danej klasy.

W praktyce dość znaczącym problemem jest wybór obiektów wzorcowych, których charakterystyki spektralne mogłyby posłużyć do identyfikacji poszukiwanych obiektów. Znalezienie prawidłowych charakterystyk polega na stworzeniu z pomiarów referencyjnych biblioteki charakterystyk spektralnych i wykonaniu pełnej korekcji atmosferycznej obrazów lub – co jest często spotykane – pozyskaniu pikseli czystych spektralnie za pomocą wskaźnika czystości pikseli PPI (*Pixel Purity Index*).

Sztuczne sieci neuronowe (SSN)

Budowa i funkcjonowanie mózgu leżą od dawna w centrum uwagi, naukowe podstawy neurologii sięgają drugiej połowy XIX w. Głównym elementem tych zainteresowań jest zdolność człowieka do rozpoznawania i zapamiętywania obrazów i dźwięków. Ludzki mózg bez najmniejszych problemów potrafi rozpoznać te same twarze pomimo różnego oświetlenia, ekspozycji, czy procesów starzenia się. Uwaga cybernetyki koncentruje się wokół aktywności mózgu, jego sposobu analizy szczegółów obrazu (np. jak to się dzieje, że potrafimy znaleźć podobieństwo dziecka do rodzica?). Na szczególną uwagę

w cybernetycznych rozważaniach zasługuje fakt, iż mózg analizuje i porównuje całe układy, np. kolor i oprawa oczu, kształt nosa, itd.

Pierwsze badania nad stworzeniem sztucznej inteligencji¹¹ wiązały się z pracami W.S. McCullocha i W. Pittsa¹². Opracowali oni model komórki nerwowej (McCulloch, Pitts, 1943) i rozwinęli koncepcję cybernetyki¹³, która legła u podstaw sztucznych sieci neuronowych. Idea ta była rozwijana w latach 1950. przez W.S. McCullocha po przejściu do Research Laboratory of Electronics, Massachusetts Institute of Technology. Przedmiotem badań był przepływ sygnałów w mózgu żaby (Lettvin i inni, 1968). Równoległe z tymi pracami D. Hebb rozwijał koncepcję dotyczącą połączeń komórek mózgowych, zapamiętywania i uczenia mózgu, w tym aktywacji połączeń pomiędzy neuronami (tzw. uczenie Hebba lub reguła Hebba). D. Hebb zauważył, że informacja może być zapamiętywana dzięki połączeniom synaptycznym (Hebb, 1949).

Operacyjne początki sztucznych sieci neuronowych sięgają roku 1951 oraz prac M. Minsky'ego, który w Massachusetts Institute of Technology współzałożył laboratorium sztucznej inteligencji i stworzył pierwszą stochastyczną sieć neuronową SNARC (*Stochastic Neural Analog Reinforcement Calculator*)¹⁴. Program ten bazował na metodzie uczenia synaps opracowanej przez Hebba (Russell, Norvig, 2003).

¹¹ Sztuczne sieci neuronowe stanowią podzbiór tzw. sztucznej inteligencji (*Artificial Intelligence – AI*) i różnią się od innych metod przetwarzania danych tym, że w trakcie przetwarzania powstają sygnały (na podstawie danych wejściowych), które nie są prostą pochodną przetworzenia algebraicznego, lecz stanowią uogólniony, jakościowo nowy sygnał, wytworzony na podstawie procedur generalizacji wyuczonych przez algorytm przetwarzania sygnału. Uzyskane dane stanowią istotną część wyniku sieci.

¹² Jest to powszechnie znana koncepcja przedstawiająca komórkę nerwową jako komórkę biologiczną składającą się z somy z wewnątrz znajdującym się jądrem (centrum komórki) oraz licznymi wypustkami. Długie i cienkie wypustki to aksony, które stanowią wyjście impulsu nerwowego, zaś krótkie i cienkie to dendryty (wejścia impulsów); wypustki łączą poszczególne komórki w sieć. Według tego modelu sygnał w sieci neuronów przepływa w jednym kierunku (od dendrytów, przez centrum obliczeniowe jądra, aż do aksonów i poprzez synapsy do kolejnej komórki sieci). Szacuje się, że sygnał elektryczny o amplitudzie około 100 mV (od -70 mV do +30 mV) pokonuje odległość od licznych synaps dendrytów do jądra w czasie około 1 milisekundy, tam po wykonaniu przetworzeniu sygnału kierowany jest zawsze w jednym kierunku do wierzchołka aksonu (Osowski, 2006).

¹³ Było to rozwinięcie prac Alana Turinga z roku 1937, który opracował koncepcję i algorytm pojęciowy (*Turing Machine*). Ze względów technicznych nie mogła ona zostać zastosowana do automatycznej symulacji procesów logicznych. Pierwszym modelem, który mógł zostać technicznie zrealizowany, był Universal Turing Machine (*Universal Machine*). Model ten został ujęty w zapis matematyczny przez A. Churcha (tzw. teoria Church-Turing). Była to pierwsza koncepcja, która pozwalała w pełni, w sposób logiczny i matematyczny przeprowadzić procesy obliczeniowe.

¹⁴ <http://aima.cs.berkeley.edu/>

W 1957 w Cornell Aeronautical Laboratory opracowana została koncepcja perceptronu¹⁵ (Rosenblatt, 1958). Był to pierwszy tzw. klasyfikator liniowy, czyli najprostsza sieć neuronowa bazująca na modelu komórki nerwowej McCullocha i Pittsa z grupy sieci jednowarstwowych jednokierunkowych. Przepływ sygnałów realizowany był operacyjnie za pomocą rozwiązań optomechanicznych i elektronicznych. Istotą tego modelu była możliwość klasyfikacji obrazów służąca rozpoznawaniu znaków. Symulator składał się dowolnej ilości komórek wejściowych, każda z tych komórek przekazywała sygnał do komórek (neuronów) wyjścia w postaci binarnej (1, 0), czyli możliwy był przepływ sygnału do wszystkich kolejnych neuronów lub blokowanie poszczególnych komórek. Wszystkie sygnały wejścia były sumowane na wyjściu (y_i) według wzoru (3) (Osowski, 1996):

$$y_i = f\left(\sum_{j=1}^N W_{ij} x_j\right) \quad (3)$$

gdzie:

- x_j – sygnał wyjściowy neuronu,
- f – funkcja aktywacji (w tym przypadku jest to funkcja skoku jednostkowego),
- x_j – sygnały wejściowe (j odpowiada liczbie kolejnych warstw wejściowych, np. liczbie kanałów obrazu),
- N – całkowita liczba neuronów wejściowych,
- W_{ij} – współczynniki wagowe połączeń komórek (wagi synaptyczne – odpowiadają za kierunki i intensywność przepływu sygnału pomiędzy kolejnymi neuronami).

Schemat ten legł u podstaw budowy większości symulatorów sztucznych sieci neuronowych i składał się z bloku sumującego wagowe sygnały wejściowe oraz drugiego bloku, który nieliniowo generował sygnał wyjściowy. Ciągłość funkcji nieliniowych determinuje dobór wag pomiędzy poszczególnymi neuronami, czyli ma wpływ na technikę uczenia sieci. W przypadku strategii uczenia sztucznych sieci neuronowych wyróżnia się uczenie nadzorowane (*supervised learning*) i uczenie nienadzorowane (*unsupervised learning*). W pierwszym przypadku przygotowuje się zestaw danych zawierających wektory wejściowe x_i (poszczególne kanały zobrazowania) oraz pożądane wektory wyjściowe d_i (wzorce poszczególnych klas będących przedmiotem klasyfikacji). Celem sieci jest takie dopasowanie wag (połączeń pomiędzy poszczególnymi neuronami), by sygnał wyjściowy neuronu y_i był najbliższy wartości pożądanej d_i (Osowski, 2006). W przypadku gdy nie ma możliwości zapewnienia wektorów wyjściowych (brak danych referencyjnych), pozostaje zastosowanie uczenia nienadzorowanego (proceduralnie odpowiada to klasyfikacji nienadzorowanej). Dobór wag następuje według zasady konkurencyjności neuronów

¹⁵ Były to elektroniczne maszyny, konstruowane specjalnie do pierwszych sztucznych sieci neuronowych; później nazwą tą objęte zostały algorytmy tworzone na komputery.

względem siebie¹⁶ lub korelacji sygnałów uczących¹⁷) (Osowski, 2006).

W prezentacji historii rozwoju sztucznych sieci neuronowych warto cofnąć się do roku 1960 – wtedy to prof. B. Widrow wraz ze swoim studentem T. Hoffem rozwinęli model ADALINE (*ADaptive LInear Neuron*), który później został przemianowany na *Adaptive Linear Element*, by w końcu dojść do powielenia i połączenia poszczególnych modułów ADALINE, co dało pakiet MADALINE (*Many ADALINE*). Była to pierwsza operacyjna jednowarstwowa sieć neuronowa do klasyfikacji danych obrazowych i prognozowania pogody. System ten był pierwszym oferowanym komercyjnie, zorientowanym na aplikacje radarowe, sonarowe i telekomunikacyjne. Koncepcja sieci bazowała na modelu komórki McCulloch-Pitts z liniową funkcją aktywacji oraz użyciem algorytmu najmniejszych kwadratów (4) (ADALINE¹⁸):

$$y = \sum_{j=1}^N W_j x_j + \theta \quad (4)$$

gdzie:

y – neuron wyjściowy,

x – neuron wejściowy,

W – waga neuronu,

N – liczba neuronów,

θ – stała sieci.

Założenia: $x_{n+1} = 1$ oraz $w_{n+1} = \theta$

Podejścia związane z sieciami jednowarstwowymi oraz ograniczonymi możliwościami obliczeniowymi ówczesnych maszyn liczących nie przyniosły satysfakcjonujących wyników. Spotykało się to z krytyką; najgłośniejszą uwagę zaprezentował M. Minsky, wykazując liczne ograniczenia sieci jednowarstwowch oraz wielowarstwowch. Wykazał, że tego rodzaju sieci są przydatne tylko do klasyfikacji obiektów identyfikowalnych w postaci funkcji liniowej. Ponadto S. Papert wskazał, że rozbudowanie sieci do układu wielowarstwowego daje się matematycznie sprowadzić do sieci jednowarstwowej, co umożliwi klasyfikację obiektów jedynie funkcjami liniowymi (Minsky, Papert, 1969). Krytyka ta w znacznym stopniu przyczyniła się do spadku finansowania prac związanych z sieciami neuronowymi na blisko dekadę. Jednocześnie był to ostatni moment naukowych prób stworzenia sztucznego mózgu (w kolejnych latach wzrosła wiedza na temat struktury i biologicznego funkcjonowania mózgu, co zaowocowało stwierdzeniem prof. E. Pugh'a, że jeśli ludzki umysł byłoby wystarczająco prosty do zrozumienia go, to my bylibyśmy zbyt prymitywni, by to zrozumieć¹⁹).

¹⁶ Strategie WTA (*Winner Takes All*) lub WTM (*Winner Takes Most*).

¹⁷ Waga połączeń między neuronami jest wzmacniana przy stanach uaktywnienia neuronów (metody hebbowskie).

¹⁸ ADALINE opis modelu: <http://davinci.newcs.uwindsor.ca/~angom/cs574/le2.pdf>.

¹⁹ "If the human mind was simple enough to understand, we'd be too simple to understand it" http://www.quotationpage.com/quotes/Emerson_Pugh/

Odpowiedzią na krytykę M. Minsky'ego i S. Paperta była praca doktorska *The roots of backpropagation* P. Werbosa z 1974 r. (Werbos, 1994). Autor ten po raz pierwszy rozbudował koncepcję perceptronów wielowarstwowych oraz zaproponował algorytm wstecznej propagacji nauki sieci. Problem ten został doceniony i szerzej rozbudowany dopiero w 1986 r. przez J. McClellanda i D. Rumelharda (Rumelhart i inni, 1986; McClelland i inni, 1986). Metoda ta, ze względu na wykorzystanie jej w niniejszej pracy, zostanie szczegółowo omówiona w kolejnych rozdziałach.

Kolejne postępy prac nad sieciami neuronowymi przypadają na lata 1970. Do ważniejszych należą prace z zakresu matematyki, opublikowane przez S.I. Amari (1972) i dotyczące uczenia sieci z elementami progowymi. Miały one ogromne znaczenie dla kolejnych badań, ponieważ zostało udowodnione, że nie wszystkie elementy sieci muszą zostać pobudzone, by efektywnie działać. Dowiedzono, że poniżej pewnej wartości progowej część komórek nie przekazuje sygnału, powodując wygaszenie danej części klasyfikacji. Pozwala to prowadzić procesy analityczne tym częściom sieci, które są najbliższe zadanemu wzorcowi.

Innym przykładem wykorzystania symulatorów SSN mogą być osiągnięcia amerykańskich naukowców nad wykorzystaniem sieci neuronowych do, np., rozpoznawania mowy, czy sterowania robotami. Za przykłady mogą służyć prace S. Grossberga nad siecią *Avalanche* do sterowania ramieniem robota oraz rozpoznawania mowy lub J. Albus, A. Pollioneze i D. Marr z Massachusetts Institute of Technology, którzy opracowali sieć *Cerebellatron* służącą do sterowania robotami (Hines, 2009). Na uwagę zasługuje sieć *Brain State in the Box*, opracowana w roku 1977 przez zespół J. Andersona (Anderson i inni, 1977; Sevrani, Abe, 2000). Był to rodzaj sieci z pamięcią asocjacyjną (skojarzeniową) z dwustronnym dostępem BAM (*Bidirectional Associative Memory*). Służyła do klasyfikacji obiektów o cechach nielinowych. Pomimo że jej układ był bardzo prosty – składał się z bezpośrednich relacji wejście-wyjście, bez analiz w kolejnych iteracjach klasyfikacyjnych – sieć ta stanowi podstawę do tzw. sztucznych sieci rekurencyjnych (RNN), które w latach 1983-1986 za sprawą prac J. Hopfielda stały się podstawą symulatorów ze sprzężeniem zwrotnym między neuronami sieci²⁰. Do tego typu należą jeszcze sieci Hamminga, RTRN, Elmana (Mandic, Chambers, 2001).

Na przełomie lat 1970. i 1980. przełomowym projektem badawczym była wspomniana już pamięć asocjacyjna oraz stworzenie sieci rezonansowych do klasyfikacji bez nauczyciela (np. typu ART). Znacząca była tu praca T. Kohonena, J.A. Andersona, S. Grossberga i G. Carpentera (Carpenter, Grossberg, 1987). Pamięć asocjacyjna (skojarzeniowa) odpowiadała za wzajemne kojarzenie neuronów (Osowski, 2006).

²⁰ Oznacza to, że sygnały wychodzące z warstwy ukrytej bądź wyjściowej mogą zostać przesłane do warstwy wejściowej.

Początek lat 1980. to okres gwałtownego i wielokierunkowego rozwoju sieci neuronowych. Do najważniejszych prac należą wspomniane już odkrycia Kohonena – dwuwymiarowe sieci SOM (*Self Organising Maps*) z roku 1982 (Kohonen, 1990) i prace J. Hopfielda nad różnymi typami i modelami sieci autoasocjacyjnych z lat 1983-86. Kolejny znaczący krok to reguła optymalizacji globalnej (symulowane wyzarczenie). Idea ta nawiązuje do wyzarczenia ciał stałych, które podczas krzepnięcia powinny powoli się krystalizować minimalizując lokalne naprężenia, w praktyce gwarantuje to ograniczenie powstawania minimów lokalnych, czyli miejsc narażonych na pęknięcia, przed zakończeniem całego procesu krystalizacji. Analogicznie w sieciach neuronowych dąży się do ograniczenia lokalnych minimów, kończących klasyfikację, przed uzyskaniem optymalnych wyników dla całej sieci (Kirkpatrick i inni, 1983).

W drugiej połowie lat osiemdziesiątych ogromne ożywienie w rozwoju sieci spowodowała wspomniana już publikacja McClellanda i Rumelharta (Rumelhart i inni, 1986; McClelland i inni, 1986). Autorzy zaproponowali rozwiązania problemów, które legły u podstaw krytyki M. Minsky'ego i S. Paperta (1969).

Od końca lat 1980. zaczyna się powszechny dostęp do komputerów i błyskawiczny rozwój metod badawczych i aplikacyjnych z wykorzystaniem sztucznych sieci neuronowych. Dzieje się to za sprawą darmowego dostępu do symulatorów SNN oraz w wielu przypadkach udostępniane są kody źródłowe programów, co umożliwia samodzielne modyfikowanie i rozwijanie programów oraz po rozwoju internetu możliwości wsparcia technicznego, np. poprzez bardzo dobrze funkcjonujące grupy dyskusyjne.

Podsumowując należy stwierdzić, że sztuczne sieci neuronowe najsilniej rozwijane były w Stanach Zjednoczonych, do głównych ośrodków należy zaliczyć Massachusetts Institute of Technology, Cornell Aeronautical Laboratory, AT&T Bell Labs, uniwersytety (np. Stanforda, w Bostonie, Browna, Harvarda). Także naukowcy pracujący poza Stanach Zjednoczonych wnieśli ogromny wkład do tej części nauki. Do tego grona niewątpliwie należy zaliczyć prof. Teuvo Kohonena z Helsińskiej Uniwersytetu of Technology (TKK), który w latach 1982-84 był pierwszym wiceprzewodniczącym International Association for Pattern Recognition, a następnie w latach 1991-92 pierwszym przewodniczącym European Neural Network Society²¹. W wielu krajach (Japonia, Niemcy, Szwecja, Włochy) narodowe organizacje wykazują się bardzo dużą aktywnością w propagowaniu i rozwoju cybernetyki²². Polska ma także znaczący dorobek w tej dziedzinie, gdyż od początku rozwoju sztucznych sieci neuronowych Polacy zajmowali się tymi algorytmami i narzędziami (Greniewski, 1959; Lange, 1965; Gawroński, 1970; Kulikowski, 1972; Kempisty, 1973; Szostak, 1978; Morecki, Ekiel, 1979). Podobnie jak na świecie, także w Polsce od drugiej połowy lat 1980. datują się

intensywne prace nad cybernetyką, algorytmami matematycznymi i sztucznymi sieciami neuronowymi. Do pionierów należy zaliczyć m.in.: R. Tadeusiewicza²³ (Jaworowski, Tadeusiewicz, 1974; Tadeusiewicz, Flasiński, 1991; Tadeusiewicz, 1993; Tadeusiewicz i inni, 2007), St. Osowskiego (Osowski, 1996; 2006), J. Korbicza (Korbicz i inni, 1994; Korbicz, Kowal, 2007; Korbicz, 2008) oraz D. Rutkowską i L. Rutkowskiego²⁴ (Rutkowska i inni, 1997)²⁵.

Architektura sztucznych sieci neuronowych

Szacuje się, że mózg człowieka składa się z około 10¹¹ neuronów, każdy z nich pozyskuje sygnał z synapsy i poprzez dendryty (każda komórka może mieć ich do 1000) przekazuje do centrum komórki. Tam następuje sumowanie sygnałów wejściowych i porównanie z wartościami progowymi, które są charakterystyczne dla lokalizacji i funkcji neuronu (Osowski, 2006). Jedną z większych tajemnic mózgu jest sposób łączenia poszczególnych neuronów. Wiadomo (Tadeusiewicz, 2007), że poszczególne części mózgu cechują się różnymi schematami połączeń. Podobnie optymalnie dobrana struktura sieci neuronowych znacząco zwiększa przepływ informacji ułatwiając rozwiązanie problemu. Niemniej optymalny dobór sieci i jej parametrów jest trudnym zadaniem i wymaga doświadczenia oraz wykonania kilku prób pozwalających na wyłonienie najlepszego zestawu wskaźników. Próbując zoptymalizować struktury sieci neuronowych przyjmuje się w symulatorach różne sposoby połączeń poszczególnych neuronów, budując je w różne warstwy i układy. Powoduje to powstanie różnych typów sieci, w których neurony łączą się w charakterystyczny sposób dla danego typu sieci i według odpowiedniej metody doboru wag w połączeniach między neuronami. Najprostszym sposobem jest połączenie wszystkich neuronów ze wszystkimi. Owocuje to stworzeniem sieci umożliwiającej rozwiązanie szerokiego spektrum problemów, jednakże kosztem ogromnego wysiłku obliczeniowego i jest niezmiernie czasochłonne. Dlatego korzysta się z różnych architektur sieci (Osowski, 1996; 2006; Tadeusiewicz, 2007), z których najczęściej spotykane to:

- jednokierunkowe jednowarstwowe. Sieć taka składa się z neuronów ułożonych w jednej warstwie. Sygnał wejściowy dostarczany jest bezpośrednio do każdego neuronu warstwy, skąd przekazywany jest do wyjścia. Sposób doboru metody wagowania neuronów i uczenia sieci decyduje o nazwie sieci (np. sieci jednowarstwowe Kohonena, perceptron jednowarstwowy);
- jednokierunkowe wielowarstwowe. W sieci tego typu sygnał przepływa od wejścia do wyjścia poprzez wiele warstw, w tym co najmniej jedną warstwę ukrytą, która pośredniczy pomiędzy warstwą wejściową

²³ http://www.uci.agh.edu.pl/uczelnia/tad//dorobek_naukowy.php?id=nauka.

²⁴ <http://kik.pcz.pl/pracownik.php?ID=4>, <http://kik.pcz.pl/pracownik.php?ID=3>.

²⁵ <http://kik.pcz.czyst.pl/~rutkowski/publications.html>.

²¹ <http://www.e-nns.org>.

²² Opracowano na podstawie strony internetowej IEEE Computational Intelligence Society (<http://ieee-cis.org>).

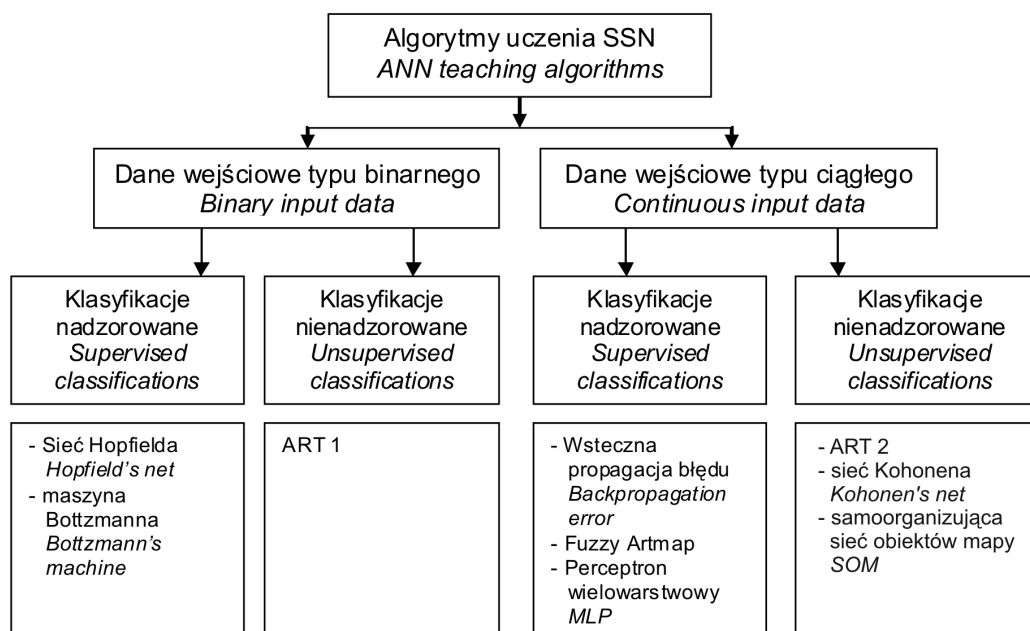
- a wyjściową. Neurony ukryte umożliwiają analizę statystyczną związków łączących poszczególne sygnały. Sieci wielowarstwowe w ujęciu matematycznym pełnią rolę aproksymacji stochastycznej funkcji wielu zmiennych, odwzorowując zmienne wejściowe w wyjściowe. Zastosowanie różnych metod przekształcania danych różnicuje sieci na kolejne grupy, np. sieci sigmoidalne, radialne (o radialnej funkcji bazowej). Specjalną grupą rozwiązań stanowią techniki wektorów podtrzymujących (SVM – *Support Vector Machine*)²⁶. Obejmują one grupę rozwiązań stosujących różne metody aktywacji neuronów oraz cechujących się specjalnym sposobem ich uczenia. Ten typ sieci został dalej przedstawiony dokładniej, gdyż wykorzystano go w niniejszej pracy;
- rekurencyjne, gdzie występuje sprzężenie zwrotne między warstwą wyjściową a wejściową. Polega to na tym, że sygnał dochodzący do wyjścia może zostać skierowany ponownie do wejścia sieci. Formowanie się sygnałów wyjściowych jest procesem dynamicznym nieliniowo i wynika z występowania jednostkowych operatorów opóźnienia. Ma to za zadanie doprowadzenie sieci do wyboru optymalnej konfiguracji (uzyskanie maksymalnego zysku przy minimalnych nakładach). W praktyce takie rozwiązania spotyka się przy stosunkowo prostych sieciach, które przez możliwość tworzenia „pętli” sygnałów potrafią dość szybko i skutecznie zaproponować optymalne rozwiązanie. Przykładem sieci rekurencyjnej jest sieć Hopfielda;
 - samoorganizujące się. Jest to przykład sieci działającej bez nauczyciela (wzorców uczących się). Systemy automatycznie tworzą pewne struktury sygnałów wejściowych, bazując na maksymalnym ograniczeniu powstawania lokalnych minimów (zaniku sygnału), gdyż uporządkowanie całej sieci może mieć miejsce w przypadku samoorganizacji sieci w każdej jej części. Odwzorowanie tych struktur prowadzi do uzyskania określonych zbiorów na wyjściu z sieci (mapowanie sygnałów). Proces uczenia sieci polega na zwiększaniu wartości poszczególnych wag na połączeniach między neuronami. Efektem jest zwiększenie sygnałów pobudzających, co doprowadza do współpracy pomiędzy poszczególnymi częściami sieci tworząc konkurencyjne oddziaływania z innymi częściami sieci. W efekcie daje to dwie możliwości samoorganizacji sieci: opartej na regule asocjacji Hebb’a oraz współzawodnictwa według reguły Kohonena;
 - rozmyte²⁷. Ten typ sieci obejmuje zestawy neuronów do analiz danych nieliniowych ciągłych (Zadeh, 1965). Jest to konkurencyjne rozwiązanie w stosunku do klasycznych sieci jednokierunkowych. Do nauki sieci wykorzystuje się metody propagacji wstecznej, samoorganizacji lub metodę tabeli przejść, która jest charakterystyczna dla tego typu sieci neuronowych. Sieć tego typu dokładnie przedstawiono w kolejnych częściach pracy, ponieważ symulator fuzzy ARTMAP, który jest kombinacją sieci rozmytej i samoorganizującej się został wykorzystany do klasyfikacji zaprezentowanych w niniejszym opracowaniu;
 - specjalizowane. Nazwą tą obejmuje się modyfikacje poszczególnych rodzajów sieci do konkretnych algorytmów i zadań. Jako przykłady mogą służyć: sieć kaskadowej korelacji Fahlmana (sieć wielowarstwowa, w której wraz z uczeniem sieci na każdym etapie dokładany jest kolejny ukryty neuron; ma to na celu wybór optymalnej struktury i wytrenowania sieci), sieć Volterra (rodzaj sieci dynamicznej do nieliniowego przetwarzania danych, które są z opóźnieniem dostarczane do sieci).
- Reasumując należy stwierdzić, że dostępność poszczególnych struktur sztucznych sieci neuronowych jest ogromna; w literaturze spotyka się ponad 50 różnych, dobrze opisanych rodzajów sieci. Fakt ten wynika z powszechnej dostępności kodów źródłowych poszczególnych symulatorów. Powoduje to, że każdy może modyfikować i dostosowywać wybraną sieć względem własnych potrzeb, które są bardzo zróżnicowane, także względem danych wejściowych. Generalnie sieci są dzielone na kilka grup (ryc. 9), uwzględniających:
- typ danych wejściowych (dane dyskretne i ciągłe),
 - metody uczenia (nadzorowane, ze wzmocnieniem oraz nienadzorowane),
 - topologie sieci (jednokierunkowe, ze sprzężeniem zwrotnym).
- Na potrzeby niniejszej pracy wykorzystano 2 rodzaje sieci:
- wielowarstwowe jednokierunkowe ze wsteczną propagacją błędów (architektura takiej sieci składa się z warstwy wejściowej, kilkudziesięciu warstw ukrytych oraz warstwy wyjściowej), bazując na symulatorze SNNS (*Stuttgart Neural Network Simulator*)²⁸,
 - rozmyte, bazując na pakiecie FuzzyARTMAP²⁹.

²⁶ S. Osowski (2006) przytacza opinię niektórych badaczy, że techniki podtrzymywania wektorów (SVM) nie należą do sztucznych sieci neuronowych. W ramach tych metod stosuje się oddzielnie proces klasyfikacji dla danych typu dyskretnego na wyjściu sieci (w którym dąży się do maksymalnego rozróżnienia poszczególnych klastrów wejściowych i wyjściowych) oraz aproksymacji (regresji) danych o ciągłych danych na wyjściu sieci. W systemie tym stosuje się system nagród (za poprawnie wykonaną czynność) oraz kar.

²⁷ Pojęcie zbiorów rozmytych zostało wprowadzone w 1965 r. przez L. Zadeha i dotyczyło próby algorytmicznego ujęcia pojęć, które z definicji są trudne do jednoznacznego określenia, np. pojęcia lingwistyczne (dużo, mało, dobrze, źle).

²⁸ Symulator SNNS jest darmowym pakietem, dostępnym ze strony <http://www.ra.cs.uni-tuebingen.de/SNNS/>

²⁹ Symulator sieci fuzzy ARTMAP został udostępniony przez prof. Paolo Gambę z Uniwersytetu w Pawii. Jednostka kierowana przez P. Gambę jest partnerem Katedry Geoinformatyki i Teledetekcji WGiSR UW w projekcie EU Hyper-i-net (www.hyperinet.eu) w kontrakcie nr 6 (zaawansowane algorytmy przetwarzania danych).



Ryc. 9. Klasyfikacja najważniejszych algorytmów uczenia sieci
Fig. 9. Classification of the most important teaching algorithms of ANNs

Zastosowanie sieci neuronowych pozwoliło przeanalizować potencjał poszczególnych rodzajów danych wejściowych do klasyfikacji, które – ze względu na dużą liczbę kanałów oraz wysoką rozdzielczość radiometryczną (15 bitów) – stawiają dość duże wyzwanie dla procesu klasyfikacji, szczególnie z powodu wielkości zbiorów i wymogów sprzętowych.

Sieci wielowarstwowe jednokierunkowe

Sieci wielowarstwowe, nazywane także perceptronem wielowarstwowym (MLP)³⁰ bazują na nieliniowych składowych i w większości wykorzystują algorytmy wstecznej propagacji błędów do ich uczenia. Stanowią one obecnie podstawowe narzędzia w praktycznym wykorzystaniu sztucznych sieci neuronowych.

Jak już wspomniano, przepływ sygnału odbywa się w jednym kierunku, od wejścia (x_i) do wyjścia (d_i) poprzez liczne warstwy ukryte (ryc. 10). Sieci wielowarstwowe oraz algorytm wstecznej propagacji błędów jest precyzyjnie udokumentowany matematycznie; stanowi to ważny element analizy procesów oraz uzyskiwanych dokładności (Żurada i inni, 1996; Osowski, 1996; 2006; Tadeusiewicz, 2007).

Sieć składa się z warstwy wejściowej (x) zawierającej klasyfikowany obraz oraz wzorce klasyfikacyjne, według których będzie uczona sieć lub odbywać się właściwa klasyfikacja (gdy sieć jest już wytrenowana i na wejściu znajdują się tylko obrazy, które mają być klasyfikowane). W i warstwach ukrytych³¹ następuje właściwa klasyfikacja obrazu (liczba warstw ukrytych jest zależna od liczby warstw wejściowych i jest definio-

wana przez użytkownika podczas tworzenia architektury sieci przed pierwszą klasyfikacją). Proces klasyfikacji odbywa się poprzez wagowanie sygnałów na wszystkich połączeniach neuronów. Wagi połączeń w warstwie ukrytej oznaczone zostały od w_1 do w_u (indeks górny 1 oznacza, że dotyczy to warstwy ukrytej). Dla warstwy wyjściowej wagi połączeń oznaczone zostały od w_1 do w_w . Indeks górny 2 oznacza, że wagi te dotyczą warstwy wyjściowej. Wyniki klasyfikacji przekazywane są do warstwy wyjściowej (d). Liczba neuronów warstwy wyjściowej jest zależna od liczby klasyfikowanych klas ($d_{1,j}, d_{2,j}, d_{3,j}, \dots, d_{i,j}$). Każdy neuron łączący kolejne neurony oznaczony został kolorami (w przypadku połączeń niewidocznych na schemacie neuronów – przerywanymi wektorami). Funkcje aktywacji neuronów (u) mają liniowe, skokowe lub sigmoidalne właściwości (Chyliński i inni, 2009).

Całość procesu uczenia sieci polega na wypracowaniu optymalnego wagowania sygnału pomiędzy poszczególnymi neuronami w warstwie ukrytej i wyjściowej (w_{ij}^1, w_w^2). „Optymalne” oznaczać powinno maksymalną zgodność pomiędzy sygnałem jakim cechuje się warstwa wyjściowa ($d_{1,j}, d_{2,j}, d_{3,j}, \dots, d_{i,j}$) oraz sygnałem warstwy wejściowej ($x_{1,1}, x_{2,1}, x_{3,1}, \dots, x_{i,1}$), czyli np. pomiędzy zadanym wzorcem a obrazem. Funkcja aktywacji neuronu warstwy ukrytej przybiera postać (5) (Osowski, 2006) i jest niezależna od sygnałów warstwy wyjściowej (6), natomiast funkcja aktywacji warstwy wyjściowej zależy od sygnałów warstw ukrytych:

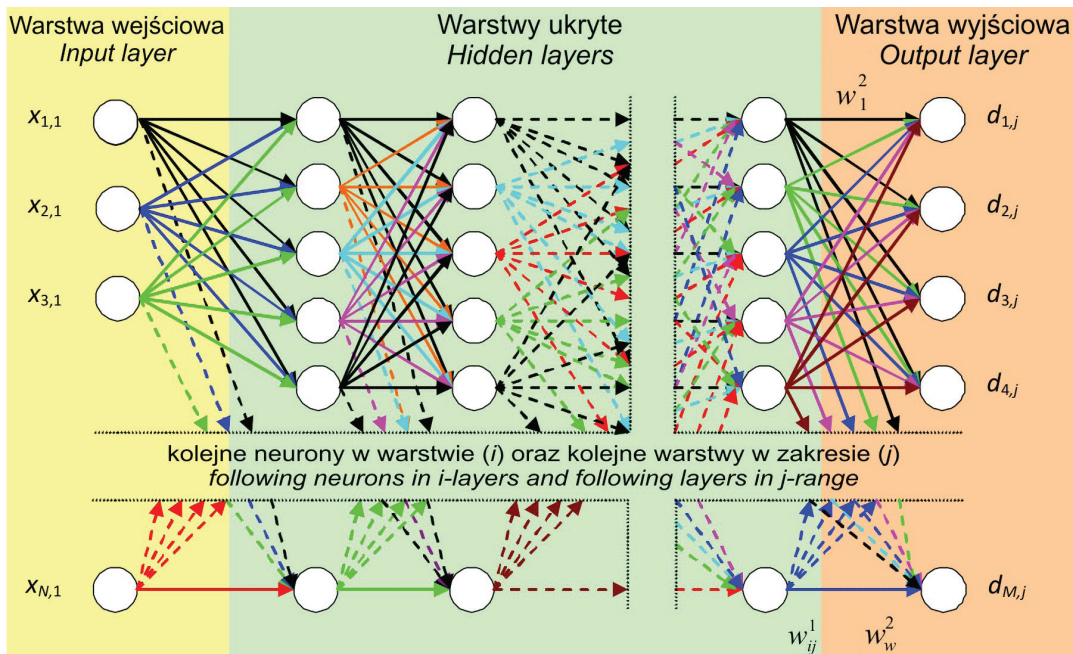
$$v_i = f \left(\sum_{j=0}^N w_{ij}^1 x_j \right) \quad (5)$$

gdzie:

N – liczba neuronów wejściowych,
 x – wektory wejściowe,
 w – wagi sygnału.

³⁰ Multi Layer Perceptron.

³¹ Warstwami ukrytymi nazywa się warstwy sieci, do których nie ma bezpośredniego dostępu (Żurada i inni, 1996).



Ryc. 10. Standardowa architektura sieci jednokierunkowej wielowarstwowej. Wektory jednostkowe warstwy wejściowej: $x_{1,1}$, $x_{2,1}$, $x_{3,1}$, ..., $x_{N,1}$; wagi połączeń: w_1 ..., w_w ; neurony wyjściowe warstwy wyjściowej ($d_{1,j}$, $d_{2,j}$, $d_{3,j}$, ..., $d_{M,j}$). Indeksami górnymi 1 oznaczone zostały wagi warstw ukrytych, indeksami górnymi 2 – warstwy wyjściowej. Indeks dolny i oznacza kolejny neuron w danej warstwie, natomiast indeks j oznacza kolejną warstwę. Objasnienia w tekście.

Fig. 10. A standard architecture of the multi-layer perceptron. Input vectors: $x_{1,1}$, $x_{2,1}$, $x_{3,1}$, ..., $x_{N,1}$; weights of connections: w_1 ..., w_w ; output vectors: $d_{1,j}$, $d_{2,j}$, $d_{3,j}$, ..., $d_{M,j}$. Upper index = 1 marks weights of hidden layers, upper index = 2 – output layer. Lower index = i marks a following neuron in a layer, and lower index = j – a following layer.

Sygnal wyjściowy neuronu d_{ij} z warstwy wyjściowej ma postać (4) (Osowski, 2006):

$$d_{ij} = f \left(\sum_{i=0}^j w_{ij}^2 v_i \right) \quad (6)$$

Podczas tworzenia sieci jednym z kluczowych momentów jest definicja liczby warstw ukrytych (N_{wu}). Zbyt mała liczba ogranicza dokładność trenowania sieci, zbyt duża natomiast przedłuża procedury uczenia. Wydaje się, że optymalnym rozwiązaniem jest empiryczny dobór liczby warstw ukrytych polegający na tym, iż w pierwszych etapach klasyfikacji dobiera się mniejszą liczbę warstw. Jako przykład może służyć wzór (7) (Chyliński i inni, 2009):

$$N_{wu} = \sqrt{N_{wwe} * N_{wwy}} \quad (7)$$

gdzie:

N_{wwe} – liczba warstw wejściowych (np. liczba kanałów obrazu do klasyfikacji),

N_{wwy} – liczba warstw wyjściowych (np. liczba klasyfikowanych klas pokrycia terenu).

Nie spotyka się większej liczby warstw ukrytych niż (8) (Kavzoglu, Mather, 2003):

$$N_{wu} = 3N_{wwe} + 1 \quad (8)$$

Fuzzy ARTMAP

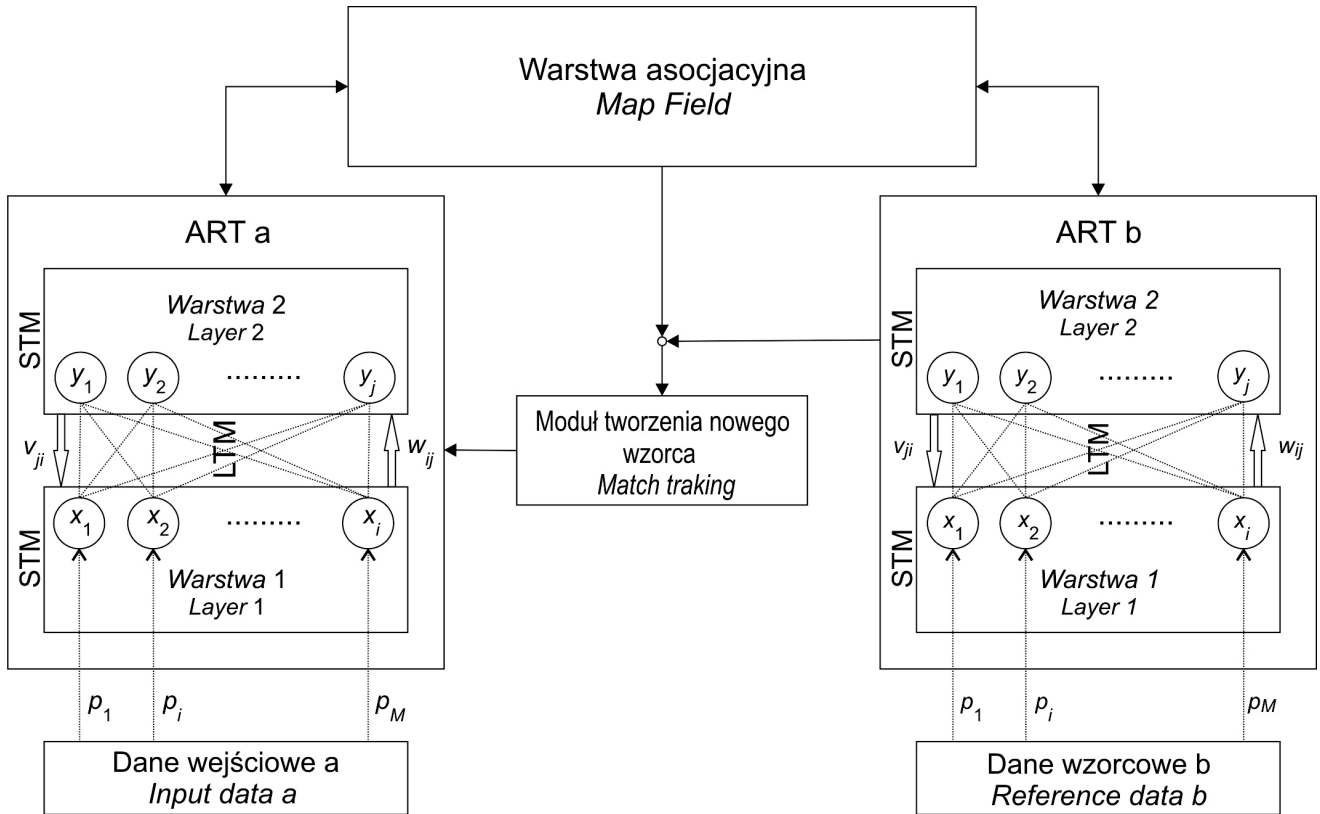
Sieci neuronowe ARTMAP oraz fuzji ARTMAP należą do grupy sieci nadzorowanych (wymagają dostarczenia wzorca do klasyfikacji) i współzawodniczących³², tj. wewnątrz sieci znajdują się dwa symulatory, które równolegle klasyfikują dane i poprzez współzawodnicztwo decyduje się, która sieć dostarczy wynik zbliżony najbardziej do wzorca.

Geneza tego typu sieci wiąże się z teorią Adaptive Resonance Theory (ART) opracowaną przez G.A. Carpentera oraz S. Grossberga (1987). Teoria ART składa się z kilku koncepcji (ART1, ART2, ART2-A, ART3)³³, opisujących sposób przetwarzania informacji przez mózg. W modelach tych zakłada się zarówno nadzorowany, jak i nienadzorowany sposób przepływu informacji, mających na celu analizę i rozpoznanie wzorców (Carpenter, Grossberg, 1990; Carpenter, 1997).

W roku 1991 zaproponowany został model ARTMAP – najbardziej zaawansowana sieć zawierająca 2 konkurujące ze sobą moduły ART, mające za zadanie uczyć

³² Równorzędny typem sieci są architektury jednokierunkowe oraz rekurencyjne, czyli ze sprzężeniem zwrotnym.

³³ Podstawowym modelem jest ART (zwany też po generalizacji ART1) i jego modyfikacją jest ART2, który do analizy wykorzystuje dane o charakterze ciągłym. Model ART 2-A jest uproszczoną kontynuacją ART2 i oferuje znacznie szybsze obliczenia. Rozwinięciem tego modelu jest ART 3, który w analizie uwzględnia złożone modele zachodzące na złączu poszczególnych neuronów (symuluje funkcjonowanie neuroprzekaznika).



Ryc. 11. Schemat funkcjonalny sieci (fuzzy) ARTMAP. ARTa – moduł odpowiadający za przetwarzanie danych wejściowych do klasyfikacji; ARTb – moduł odpowiadający za końcowe etapy klasyfikacji; dane wejściowe a – obrazy będące przedmiotem klasyfikacji; dane wzorcowe b – dane referencyjne służące uczeniu sieci; p_M – neurony wejść (odpowiadają one poszczególnym kanałom obrazowania i wzorców wykorzystanych do uczenia sieci); STM³⁴ – pamięć krótkotrwała; LTM – pamięć długotrwała; warstwa 1³⁵ – warstwa porównująca; warstwa 2 – warstwa rozpoznająca; x_i – neurony warstwy 1; y_j – neurony warstwy 2; w_{ij} – wagi połączeń neuronów klasyfikujące obraz wynikowy; v_{ji} – wagi połączeń neuronów sprawdzających poprawność klasyfikacji; warstwa asocjacyjna – odpowiada za identyfikację klasyfikowanych jednostek w module ARTa ze wzorcem przetwarzanym w module ARTb; moduł tworzenia nowego wzorca³⁶ (opracowano na podstawie Carpenter, Grossberg, 2003; Dagher, 2006; Rocki, 2007; Trianni, 2007)

Fig. 11. Processing chain of the (fuzzy) ARTMAP simulator. ARTa – input processing module; ARTb – output processing module; p_M – input neurons; STM – short-term memory; LTM – long-term memory; layer 1 – comparison layer; layer 2 – recognising layer; x_i – neurons of layer 1; y_j – neurons of layer 2; w_{ij} – weights of connections of output image classification module; v_{ji} – weights of proofing neurons; match tracking – module of signal comparison between input and reference units (sources: Carpenter, Grossberg, 2003; Dagher 2006; Rocki, 2007; Trianni, 2007)

³⁴ STM – Short Term Memory odpowiada za szczegółowe rozpoznanie i dopasowanie sygnałów; LTM – Long Term Memory – za tworzenie i aktualizacje wag połączeń pomiędzy warstwami.

³⁵ Warstwa 1 – pobiera dane wejściowe w postaci wektora sygnału i na podstawie funkcji wyboru odszukuje w warstwie 2 wzorec najbardziej odpowiadający wektorowi wejściowemu z warstwy 1. Po odnalezieniu odpowiednich wektorów następuje klasyfikacja, a po jej zakończeniu odbywa się porównanie przez moduł kasujący z zadaniem na wstępie współczynnikiem czujności ρ (prawdopodobieństwa) (ang. *vigilance*). Im wyższy współczynnik czujności ρ , tym system rozpoznaje więcej obiektów (tworzy więcej klastrów, które w efekcie dokładniej odpowiadają wzorcom), przy obniżeniu jego wartości uzyskane wyniki są bardziej zgeneralizowane. W przypadku gdy uzyskana wartość sygnału jest zgodna z zadaniem współczynnikiem ρ , następuje trening sieci. W przypadku braku jakiegokolwiek neuronu, którego sygnał spełniłby warunki narzucone przez współczynnik ρ , tworzony jest nowy neuron, który reprezentuje nową klasę. Trening sieci spełnia taką samą rolę jak

w sposób nadzorowany i klasyfikować dane w czasie rzeczywistym (Carpenter i inni, 1991). Ważne w tym modelu było to, że podczas treningu do obu modułów ART dopływały sygnały i poszczególne moduły ART mogły indywidualnie zmieniać swoją architekturę w odpowiedzi na napływające sygnały (ryc. 11).

Różnica pomiędzy ARTMAP i fuzzy ARTMAP polega na tym, że ta pierwsza przyjmuje wartości binarne, natomiast druga dane o wartościach ciągłych.

w sieciach wielowarstwowych: ma zoptymalizować połączenia neuronów, czyli zaadaptować wagi do danej klasyfikacji. Proces ten odbywa się w pamięci długotrwałej i bazuje na dwóch metodach: szybkiej (algebraiczne dopasowanie sygnału) oraz wolnej, symulującej procesy neurologiczne (w przypadku sieci stosuje się równania różniczkowe) (Rocki, 2007).

³⁶ W przypadku gdy między danymi generowanymi przez ARTa i danymi wejściowymi do sieci ARTb nie znajduje się odpowiednich sygnałów tworzona jest nowa kategoria.

Ważnym elementem systemów ART jest możliwość pracy na danych typu ciągłego, co pozwala analizować dane w sposób „rozmyty” (ang. *fuzzy*), czyli taki, w którym brakuje wyraźnych granic pomiędzy analizowanymi jednostkami (np. analiza pojęć cicho i głośno, ciepło – zimno) (Zadeh, 1965, 1972). Wersje *fuzzy* istnieją zarówno dla pojedynczych modeli ART (tzw. *fuzzy ART*), jak tandemów *fuzzy ART* pracujących w postaci ARTMAP (tzw. *fuzzy ARTMAP* lub FAM) (Carpenter i inni, 1991, 1992). Sieci neuronowe bazujące na zestawach „rozmytych” charakteryzuje występowanie wartości pośrednich pomiędzy wartościami całkowitymi (0, 1 – typowymi dla obrazów)³⁷. Zastosowanie sieci *fuzzy ART* znacząco ogranicza liczbę pomyłek i błędów powstałych podczas analiz na każdym poziomie rozpoznania, analizy i klasyfikacji danych. Dzieje się to za sprawą dużej elastyczności systemu³⁸, automatycznie generowanej zmiennej proggu uczenia³⁹, maksymalnego wykorzystania pamięci komputera oraz możliwości skalowania⁴⁰. Dużą zaletą sieci tego typu jest tworzenie list rankingowych możliwych przynależności klasyfikowanego obiektu, gdyż moduł ARTa klasyfikuje dane wedle zasad klasyfikacji nienadzorowanej, polegającej na grupowaniu wektorów p_M w klastry według zadanego parametru współczynnika czujności ρ ⁴¹ (Carpenter i inni, 1992, 1995). W efekcie

³⁷ Podobna sytuacja miała miejsce w przypadku sieci wielowarstwowej SNNS ze wsteczną propagacją błędów – tam poszczególnym wartościom jasności obrazu dopisane zostały wartości wyrażone w liczbach rzeczywistych z zakresu $\langle 0, 1 \rangle$.

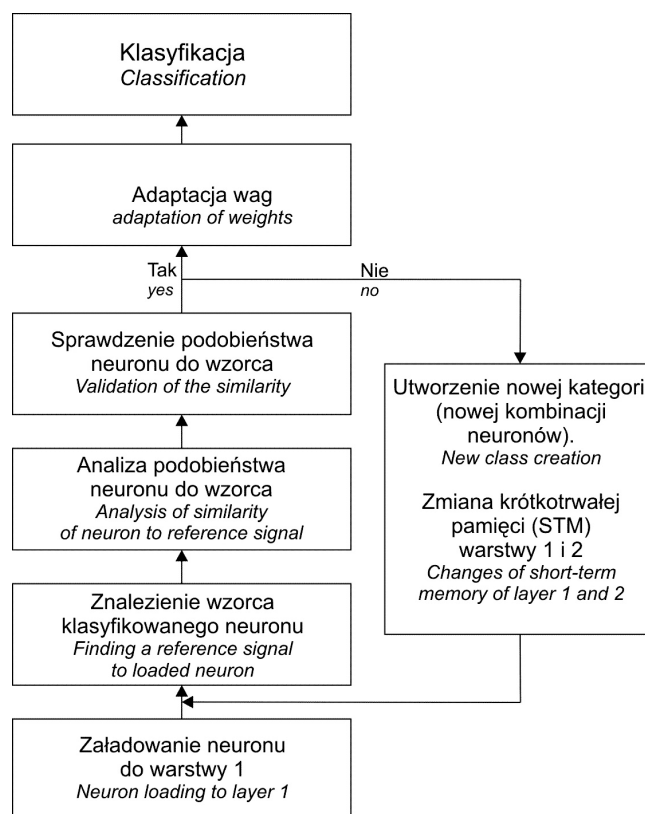
³⁸ Sieci typu ART mogą zmieniać strukturę względem dopływających sygnałów wejściowych, cechują się dwoma systemami pamięci (długo- i krótkotrwałej), odpowiadającej pamięci człowieka. W pierwszym przypadku zachowują się ogólne informacje, które potrafią szybko odtworzyć ogólne informacje o obiekcie. Pamięć krótkotrwała zawiera bardzo wiele szczegółowych danych, które znacząco obciążają system, ale dostarczają bardzo dokładne informacje. W przypadku wstępnych procedur uczenia sieci wykorzystuje się długotrwałą pamięć, która naprowadza system na prawidłowe wartości wag połączeń neuronów, a szczegółowe ulepszenia systemu wykonuje się w pamięci krótkotrwałej. Cecha ta powoduje, że w krótkim czasie modele ART cechuje dużo większa efektywność uczenia w porównaniu do sieci wielowarstwowych ze wsteczną propagacją błędów, gdyż system powinien pamiętać wyuczone już wzorce.

³⁹ W przypadku sieci wielowarstwowych ze wsteczną propagacją błędów parametr uczenia jest stały dla całego procesu klasyfikacji.

⁴⁰ Możliwość podziału wielowymiarowych danych na mniejsze części, co znacząco zwiększa efektywność obróbki i klasyfikacji danych.

⁴¹ Współczynnik czujności ρ powinien cechować się możliwie niewielką wartością, co pozwoli na szczegółowe wydzielenie klas w sieci ARTa. Jednakże zbyt szczegółowe wyróżnienie klastrów w ARTa może spowodować, że w sprzężeniu zwrotnym z siecią referencyjną ARTb, gdzie zapisane są wzorce nadzorujące klasyfikacje w ARTMAP, warstwa asocjacyjna nie znajdzie prawidłowego sygnału zwrotnego i dane klastry nie zostaną prawidłowo zaklasyfikowane do tego, czego życzyłyby sobie operator sieci. Zbyt duża wartość współczynnika ρ może spowodować zbytnią generalizację klasyfikowanej mapy, dlatego dobór współczynnika powinien się odbyć empirycznie.

powoduje to automatyczne tworzenie nowych neuronów. Proces ten odbywa się w ten sposób, że w pierwszym przypadku sprawdzana jest pamięć długotrwała (LTM), jeśli ona nie wykaże obecności znanego sygnału lub poziom sygnału nie będzie akceptowalny przez zadany parametr wartości progowej współczynnika czujności ρ ⁴², to powstają nowe klasy (Rocki, 2007). W przypadku nowo uczonej sieci ARTa proces ten polega na tym, że po załadowaniu pierwszego neuronu x_1 tworzony jest pierwszy wzorzec referencyjny y_1 , jeśli po załadowaniu kolejnego neuronu x_2 podobieństwo tego sygnału znajdzie się w zakresie zdefiniowanym współczynnikiem czujności ρ , neuron zaklasyfikowany zostanie do zdefiniowanej klasy y_1 , jeśli nie, to do y_2 (ryc. 12, Carpenter i inni, 1992).



Ryc. 12. Najważniejsze etapy klasyfikacji obrazów z wykorzystaniem symulatora fuzzy ARTMAP (źródło: Rocki, 2007, zmodyfikowane)

Fig. 12. The main stages of a fuzzy ARTMAP image classification (source: Rocki, 2007, modified)

Pierwsze etapy klasyfikacji z wykorzystaniem symulatora fuzzy ARTMAP są zbliżone do klasyfikacji z wykorzystaniem symulatora SNNS i polegają na przygotowaniu danych wejściowych oraz wytrenowaniu sieci. Różnica polega na tym, że symulator fuzzy ARTMAP akceptuje dane zapisane w formacie środowiska ENVI, natomiast SNNS wymaga przygotowania zbiorów liczb

⁴² Sprzyja temu rozmycie wartości wejściowych, co jest istotne w przypadku heterogenicznych danych teledetekcyjnych (duży udział mikseli, reprezentujących różne formy pokrycia terenu).

rzeczywistych zapisanych w formacie ASCII. Różnica dotyczy jedynie formatu zapisu danych, co z jakościowego punktu widzenia klasyfikacji nie odgrywa żadnej roli, jest to tylko znaczące ułatwienie dla osoby klasyfikującej, gdyż format ENVI jest jednym z podstawowych, w których się zapisuje dane teledetekcyjne i nie wymaga żadnych dodatkowych procedur.

Po wyborze kanałów do klasyfikacji należy przygotować warstwę wzorcową, np. form pokrycia terenu. Symulator fuzzy ARTMAP – podobnie jak SNNS – wymaga, by była to warstwa rastrowa z identyczną liczbą pikseli (kolumn oraz wierszy) jak dane obrazowe będące przedmiotem klasyfikacji. Akceptowalnym formatem danych wzorcowych jest plik *.bmp. Na tym etapie przygotowania danych różnica pomiędzy omawianymi symulatorami jest istotna, ponieważ fuzzy ARTMAP wykonuje w trakcie całej procedury klasyfikacji także ocenę dokładności, która jest podawana w postaci macierzy błędów, współczynnika kappa oraz dokładności całkowitej, natomiast symulator SNNS wymaga oddzielnej procedury określającej dokładność wykonanej klasyfikacji. Symulator SNNS oferuje natomiast możliwość bieżącego śledzenia aktualnego błędu klasyfikacji (co pozwala modyfikować dane i parametry klasyfikacji, zaś w fuzzy ARTMAP należy czekać do końca klasyfikacji). Ogromną zaletą podejścia zastosowanego w symulatorze SNNS jest to, że sieć można wytrenować na dowolnym zestawie danych, a klasyfikację wykonać na geograficznie niezwiązanych ze sobą terenach⁴³.

Po przygotowaniu zestawu klasyfikacyjnego (dane obrazowe, wzorzec oraz obraz referencyjny do określenia dokładności klasyfikacji) kolejny etap obejmuje ustalenie parametrów klasyfikacji. Są to: β_a oraz β_b (współczynniki szybkości uczenia sieci ARTa i ARTb), ρ_a ; ρ_b (próg czułości (prawdopodobieństwa)⁴⁴ sieci ARTa i ARTb) oraz parametru wyboru α (*choice parametr*)⁴⁵.

Reasumując: przygotowanie danych do klasyfikacji fuzzy ARTMAP jest szybsze i pozwala na wizualizację danych na każdym etapie klasyfikacji, co umożliwia eliminację przypadkowych błędów (np. przypadkowej podmiany kanału), jednakże w symulatorze SNNS powstałe błędy – czy generalnie mówiąc, jakość klasyfikacji – można analizować w dowolnym momencie klasyfikacji poprzez analizę wartości SSE. Końcowe wyniki symulatora SNNS wymagają analizy i podjęcia decyzji, który poziom prawdopodobieństwa wystąpienia danego obiektu jest satysfakcjonujący dla użytkownika. Daje to użytkownikowi większą elastyczność pracy i zwiększa szansę wyboru właściwych wyników. System fuzzy ARTMAP przedstawia końcowe wyniki w postaci binarnej

(0, 1), co znacząco upraszcza procedurę, szczególnie gdy klasyfikowana jest znacząca liczba wydzielen. Istotnym ułatwieniem symulatora fuzzy ARTMAP jest podanie końcowych wyników dokładności klasyfikacji (w przypadku SNNS należy wykonać tę czynność dodatkowo). Znaczącą zaletą klasyfikacji SNNS jest możliwość przerywania klasyfikacji w dowolnym momencie i zmieniania parametrów, co w przypadku fuzzy ARTMAP jest niedopuszczalne.

Zastosowanie logiki rozmytej eliminuje sytuacje, w których sygnał wektora wejściowego odpowiadałby 2 różnym wzorcom (stopień przynależności sygnału do dwu klas byłby identyczny). Dzieje się to za sprawą decyzyjności (0, 1) sygnału wyjściowego względem zadanego wektora wejściowego, czyli jednoznacznego zaklasyfikowania wektora do jednej klasy, a nie jak ma to miejsce w innych typach sieci, określenie prawdopodobieństwa przynależności do każdej klasy. Takie postępowanie eliminuje nakładające się poligony z poszczególnych wydzielen⁴⁶.

Uczenie sieci metodą wstecznej propagacji błędów

Po stworzeniu architektury sieci gotowej do klasyfikacji pierwszym krokiem jest jej wytrenowanie, czyli określenie metody doboru współczynników wagowych na połączeniu pomiędzy poszczególnymi neuronami. Istnieją trzy metody uczenia sieci: nadzorowana (do sieci wprowadzany jest wzorzec, który wskazuje jakie wartości są żądane na wyjściu), ze wzmocnieniem (systemowi podaje się ocenę jakości dopasowania wag) oraz nienadzorowana (na wyjściu nie podaje się liczby klas wyjściowych, a sieć tworzy dowolną liczbę asocjacji/klastrów pikseli).

Obecnie jednym z najbardziej efektywnych algorytmów jest metoda wstecznej propagacji błędów, która polega na opracowaniu funkcji celu $E(w)$ ⁴⁷, mającej za zadanie minimalizację różnic pomiędzy aktualnymi wartościami sygnałów (x) przepływających przez połączenia neuronów (synapsy) a zadanymi we wzorcu klasyfikacyjnym (d)⁴⁸ (propagowanie przesyłania błędów uczenia sieci powstałych na wyjściu do warstwy wejściowej)⁴⁹

⁴⁶ Ma to także negatywne skutki, gdyż w przypadku klasyfikacji gatunków, sieć fuzzy ARTMAP nie pozwala na stworzenie poligonu, który składałby się z różnych gatunków, jeśli nie były one zdefiniowane we wzorcu. Sieć SNNS oraz ARTMAP pozwalają na stworzenie takiej mapy z niezależnych wzorców, np. występowania kosówki, borówczysk i muraw. W sieciach SNNS i ARTMAP można utworzyć kompleks tych trzech klas, natomiast w fuzzy ARTMAP są tworzone oddzielne, nienakładające się poligony.

⁴⁷ Najczęściej funkcja celu jest definiowana jako suma kwadratów różnic między neuronami wzorcowymi a aktualną wartością sygnału (Osowski, 2006).

⁴⁸ Uczenie sieci polega na określeniu wag poszczególnych połączeń neuronów (we wszystkich warstwach sieci) w taki sposób, by wektory wejściowe x na wyjściu y uzyskiwały wartości maksymalnie zbliżone do wzorców d (Werbos, 1994, Żurada i inni, 1996).

⁴⁹ Istnieje szereg metod określających dokładność dopasowania, a tym samym uzyskiwany błąd uczenia sieci.

⁴³ Symulator fuzzy ARTMAP wymaga, by wzorzec znajdował się na terenie geograficznie powiązany z obrazem, który jest w danej procedurze klasyfikowany.

⁴⁴ Parametr ten jest modyfikowany przez sieć ARTa. Efektem tego procesu jest dynamiczna zmiana liczby kategorii wyjściowych do warstwy asocjacyjnej.

⁴⁵ Parametr ten determinuje wykasowanie, zapętlenie bądź przesłanie sygnałów neuronów pochodzących z ARTa i ARTb.

(Werbos, 1994; Kavzoglu, Mather, 2003; Osowski, 2006). Funkcję celu definiuje się za pomocą wzoru (9):

$$E(w) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^j - d_k^j)^2 \quad (9)$$

gdzie:

- $j = 1, 2, 3, \dots, p$ – numer kolejnych próbek uczących (wzorcowych),
- $k = 1, 2, 3, \dots, M$ – numer kolejnych wartości wyjściowych,
- y – wartość wyjściowa,
- d – wartość zadana (wzorcową), która jest klasyfikowana.

Uczenie sieci przebiega według następującego algorytmu (Żurada i inni, 1996; Osowski, 2006):

- analiza wartości neuronów wejściowych x ,
- obliczenie wartości sygnałów wyjściowych warstwy ukrytej w^1 ,
- obliczenie wartości sygnałów warstwy wyjściowej y_i . Dla wielu neuronów odbywa się to według wzoru (10) (Osowski, 2006),
- obliczenie aktualnej wartości funkcji celu ($E(w)$). W kolejnych iteracjach klasyfikacji wartość ($E(w)$) powinna maleć. Ciągłość procesu pozwala na zastosowanie gradientowych algorytmów optymalizacji.

$$y_k = f\left(\sum_{i=0}^K w_{ki}^2 f\left(\sum_{j=0}^N w_{ij}^1 x_j\right)\right) \quad (10)$$

gdzie:

- ¹ – indeks górny 1 mają warstwy ukryte,
- ² – indeks górny 2 mają warstwy wyjściowe,
- K – końcowa liczba neuronów warstwy ukrytej,
- M – końcowa liczba neuronów warstwy wyjściowej,
- N – końcowa liczba neuronów wejściowych,
- x – neurony warstwy wejściowej,
- y – neurony warstwy wyjściowej,
- d – neurony warstwy zadanej (wzorcowej),
- w – wagi połączeń pomiędzy neuronami,
- i, j – kolejne neurony.

Gradientowe metody optymalizacji należą do najsukteczniejszych rozwiązań podczas uczenia sieci (Żurada i inni, 1996). Proces ten odbywa się według wzoru (11) (Osowski, 2006):

$$w(k+1) = w(k) + \eta p(w) \quad (11)$$

gdzie:

- w – wagi połączeń pomiędzy neuronami,

k – neurony warstwy ukrytej,

η – współczynnik uczenia,

$p(w)$ – kierunek minimalizacji w przestrzeni wielowymiarowej w .

Współczynnik uczenia (η) dobierany jest empirycznie. Zbyt duża jego wartość (np. 5) może doprowadzić do przeregulowania sieci i dużego końcowego błędu klasyfikacji, gdyż wywołuje znaczące oscylacje. Natomiast zbyt mała wartość współczynnika (np. 0, 1) eliminuje oscylacje, powodując jednakże powolny spadek błędu uczenia (*Sum Square Error*) i znacząco wydłużając proces uczenia. Aby osiągnąć optymalny współczynnik uczenia (zadany poziom błędu), należy wykonać kilka prób klasyfikacji na niewielkiej liczbie iteracji.

Wyznaczenie kierunku minimalizacji $p(w)$ opiera się na analizie wszystkich wag danej iteracji, co pozwala na określenie gradientu wag i wyznaczenie ich wektora⁵⁰. Proces ten nazywa się algorytmem wstecznej propagacji.

Najważniejsze etapy tej procedury to (Osowski, 2006):

- analiza sieci. Zakłada się, że sygnały przepływają od wejścia do wyjścia, pozwala to uzyskać wartość chwilową sygnału wyjścia warstwy ukrytej i wyjściowej z sygnałów wejścia (równym sygnałom neuronów wejścia x),
- utworzenie sieci propagacji wstecznej. Etap ten jest inicjowany po uzyskaniu sygnałów wyjścia i polega na odwróceniu kierunku przepływu sygnałów. Podczas odwrócenia następuje porównanie sygnału, który ma być kierowany ku wejściu z sygnałem warstw zadanych (wzorcowych). W tym etapie następuje zastąpienie funkcji aktywacji przez ich pochodne (m oznacza liczbę warstw sieci) (12) (Osowski, 2006); pozwala to obliczyć różnice pomiędzy wzorcem a wartością aktualną sygnału podczas analizy wstecznego przepływu sygnału:

$$\frac{df(u_i^1)}{du_i^1}, \frac{df(u_i^2)}{du_i^2}, \dots, \frac{df(u_i^m)}{du_i^m} \quad (12)$$

- modyfikacje wag przepływu sygnału przez synapsy sieci (uczenie sieci). Odbywa się to zgodnie z przedstawioną powyżej procedurą (przepływ sygnału od wejścia ku wyjściu i odwrotnie – propagacja wsteczna). Proces ten zachodzi w sposób ciągły, zostanie zatrzymany po wykonaniu zadanej liczby iteracji lub osiągnięciu zaprogramowanej przez użytkownika wartości błędu ε (SSE⁵¹). Podstawy teoretyczne i matematyczne zapisy tych procesów są dokładnie opisane w literaturze (Werbos, 1994; Osowski, 1996, 2006; Żurada i inni, 1996).

Najpowszechniej stosowane mierniki to: średni błąd kwadratowy (*mean squared error*), suma błędów kwadratowych (*sum squared error*) i średni błąd bezwzględny (*mean absolute error*).

⁵⁰ Proces ten nie dotyczy warstwy wyjściowej.

⁵¹ *Sum Squared Error*.

Wstępne przetwarzanie danych hiperspektralnych Tatr Wysokich

Dane pozyskane bezpośrednio przez skaner lotniczy mają liczne zniekształcenia wynikające z deformacji geometrycznych wywołanych przez ruch samolotu w atmosferze (rejestracja obrazu odbywa się piksel po pikselu i linia po linii) oraz zakłóceń i szumów spowodowanych wpływem atmosfery oraz samego detektora na rejestrowany sygnał. Wszystkie te błędy muszą zostać wyeliminowane podczas wstępnego przetwarzania sygnału.

Dane w trakcie zobrazowania są zapisywane na taśmie magnetycznej w formacie RAW (poziom 0). Pierwszy etap przetwarzania danych polega na ich zgraniu na dysk twardy komputera i konwersji do formatu BSQ; format ten zostaje automatycznie zarchiwizowany na taśmie ADSM. Następuje przejście zobrazowania w celu eliminacji błędów w zapisie. W następnym kroku eliminowane są fragmenty obrazu z nakładającymi się obrazami tego samego zakresu spektrum¹. Następnie przeprowadzana jest analiza szumu generowanego przez układy elektroniczne skanera (*dark current*). Po tym procesie dane obrazowe są kalibrowane przez zastosowanie współczynników kalibracyjnych pozyskanych dla danego detektora podczas kalibracji instrumentu (odniesieniem jest wzorzec czerni – *dark current* – detektora). Końcowym etapem korekcji sensora jest wygenerowanie raportu po kalibracji radiometrycznej wraz z plikami obrazu przetworzonymi do poziomu 1. Integralną częścią raportu są wygenerowane obrazy typu *quicklook*. Służą one prezentacji na stronach www w formacie HTML oraz generalnej wizualizacji jakości danych (np. zachmurzenie, pokrycie terenu). Na każdym etapie korekcji sensora wykonywane są analizy jakości danych. Końcowy raport z wstępnego przetwarzania wraz z danymi obrazowymi (poziom 1) oraz danymi INS (*Inertial Navi-*

gation System) jest dostarczany do klienta (Holzwarth i inni, 2003).

Kolejne etapy przetwarzania obrazów hiperspektralnych obejmują korekcję geometryczną i atmosferyczną (ryc. 13). W zdecydowanej większości przypadków procedurę tę wykonuje zamawiający zobrazowanie, w specjalistycznych pakietach do przetwarzania danych hiperspektralnych (np. ENVI) lub też specjalistycznych programach, np. PARGE lub ATCOR.

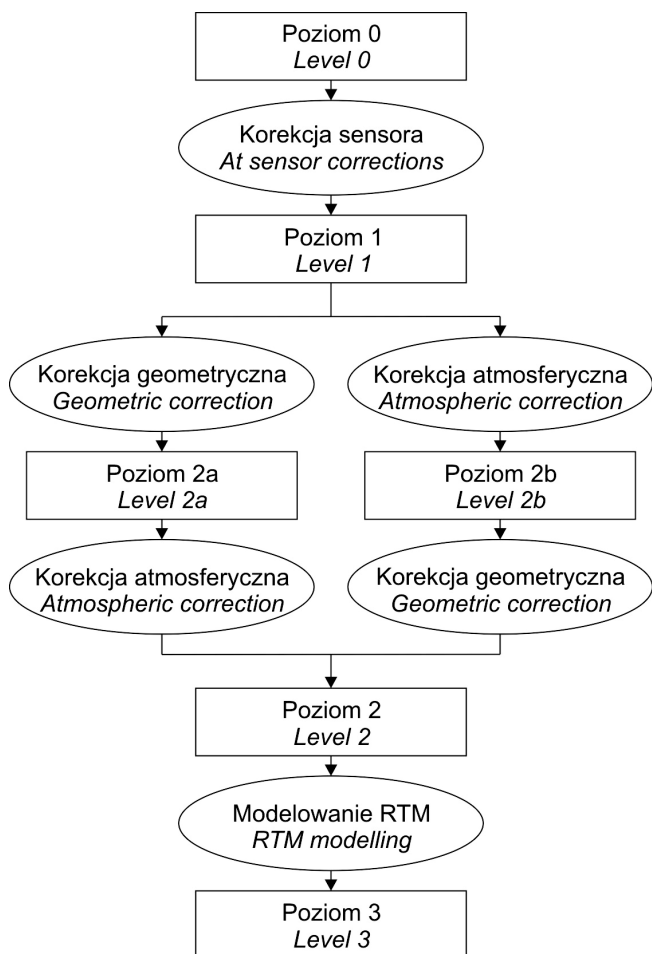
Dane DAIS 7915 wykorzystane w niniejszej pracy zostały skorygowane geometrycznie i atmosferycznie przez autora niniejszej pracy oraz M. Sobczaka podczas pobytu naukowego w DLR Oberpfafenhoffen w styczniu i lutym 2003 r. Do tego celu wykorzystane zostały pakiety ATCOR4 oraz PARGE². Pakiet PARGE (*PARAmetric GEocoding*) został stworzony do parametrycznej geometryzacji cyfrowych danych lotniczych, pozyskanych z detektorów rejestrujących piksel po pikselu lub też linia po linii. Pakiet ATCOR (*ATMospheric CORrection*) służy do korekcji atmosferycznej, normalizacji topograficznej i empirycznego modelowania BRDF³, czyli dwukierunkowości odbicia promieni słonecznych (geometrii słońce–obiekt–detektor)⁴.

² Oprogramowanie to zostało przygotowane przez pracowników RSL (dr Daniel Schlaepfer) oraz DLR (dr Rudolf Richter); dostępnego w firmie ReSe (www.rese.ch). Pakiet ATCORa występuje powszechnie w trzech wersjach: ATCOR2 do korekcji danych satelitarnych bez uwzględnienia NMT, ATCOR3 do korekcji danych satelitarnych z uwzględnieniem NMT oraz ATCOR4 do korekcji obrazów pozyskanych przez detektory szerokokątne (lotnicze).

³ BRDF – *Bidirectional Reflectance Distribution Function* – funkcja dwukierunkowego rozkładu odbicia.

⁴ Warunek ten wymagał takiego doboru punktu początkowego i końcowego, by azymut padania promieni słonecznych pokrywał się z azymutem lotu samolotu. Z tego względu pilotom dostarczono kilkanaście wersji linii nalotu uwzględniających dokładny czas (godzinę z dokładnością do minuty) rozpoczęcia zobrazowania danej linii nalotu, wysokość i azymut Słońca oraz punkt rozpoczęcia i zakończenia zobrazowania każdej linii.

¹ Skanery obrazujące składają się z kilku niezależnych detektorów (np. obrazujących w zakresie VIS, VIS-NIR, SWIR), każdy z detektorów pokrywa niewielką część spektrum zobrazowywanego przez inny skaner. W trakcie wstępnego przetwarzania obrazów należy usunąć pokrywające się przedziały spektrum.



Ryc. 13. Procedura przetwarzania hiperspektralnych, obrazowych danych lotniczych (źródło: Strobl i inni, 1996; Habermeyer i inni, 2003, zmodyfikowane)

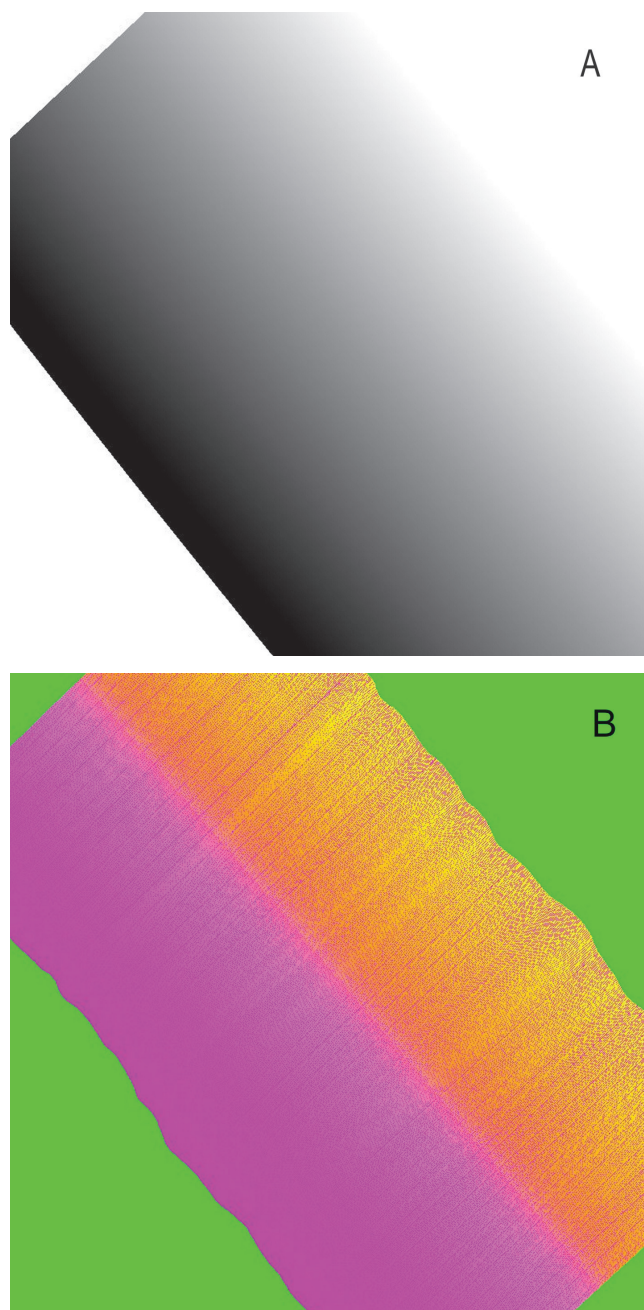
Fig. 13. Procedure of an airborne hyperspectral data processing (source: Strobl et al., 1996; Habermeyer et al., 2003, modified)

W efekcie nalotu nad obszar Tatr Wysokich zobrazowaniem zostały pokryte po 4 pasy DAIS 7915 oraz Rosis. Z powodu problemów technicznych nalot na linie nr 1 oraz 3 został powtórzony i w końcowej wersji zobrazowania funkcjonują one jako linia zobrazowania nr 5 i 6. Na poszczególnych pasach zobrazowania widać dobrą jakość obrazu, dzięki m.in. brakowi zachmurzenia (ryc. 15).

Korekcja geometryczna obrazów hiperspektralnych

Parametryczna geometryzacja bazuje na analizie położenia każdego piksela. Procedura wymaga informacji, które są zapisywane podczas lotu samolotu przez wewnętrzny system nawigacji INS. System ten rejestruje położenie samolotu w czasie rzeczywistym (wychylenia we wszystkich płaszczyznach ω , φ , κ) oraz różnicowy system pozycjonowania (DGPS), który podaje dokładne położenie samolotu w płaszczyznach x , y , z . Informacje te są uzupełniane dokładnym Numerycznym Modelem Terenu (Schläpfer, Richter, 2002). Na tej pod-

stawie tworzy się plik pozycjonowania każdego piksela. W pierwszym kroku następuje automatyczne wygenerowanie, pliku tzw. *scan angle file* (*.sca), w którym liczba kolumn odpowiada liczbie pikseli rejestrowanych w linii detektora (w przypadku DAIS 7915 jest to 512), natomiast liczba wierszy odpowiada rzeczywistej długości linii zobrazowania. Różnicami fototonu przedstawione zostają różnice kąta między położeniem danego piksela, skanerem a rzutem linii lotu samolotu na powierzchnię



Ryc. 14. Plik pozycjonowania każdego piksela obrazu *.sca: A – wygenerowany automatycznie, B – po korekcji rzeczywistego lotu samolotu. Kompozycja barwna R (zmiany wysokości), G (kąt skanowania), B (azymut)

Fig. 14. Scan angle file (*.sca): A – generated automatically, B – after geometric correction according to the real flight parameters. RGB composition presents R (changes of altitudes), G (scan angle), B (azimuth)

terenu. W kolejnym kroku plik ten jest geometryzowany do docelowego układu współrzędnych, co pozwala na włączenie go do systemu zawierającego dane z rzeczywistego lotu samolotu. W efekcie uzyskuje się rzeczywisty obraz pozycjonowania samolotu. Granica pomiędzy barwami różową i pomarańczową a zieloną byłaby prostą, gdyby samolot nie wychylał się od założonej linii lotu w żadnym kierunku (ryc. 14).

Po zakończeniu tego etapu następuje tradycyjna geometryzacja obrazów przy użyciu punktów pomierzonych w terenie za pomocą GPS lub zidentyfikowanych na innych wysokorozdzielczych danych (wielkość błędu geometryzacji nie może być wyższa niż połowa wielkości piksela).

Na potrzeby geometryzacji danych DAIS7915 wykorzystano punkty GPS pomierzone w terenie za pomocą odbiornika DGPS udostępnionego przez TPN oraz Numeryczny Model Terenu opracowany z poziomich map topograficznych w skalach 1:10 000. Docelowym układem współrzędnych jest UTM (*Universal Transverse Mercator*) z elipsoidą WGS84. Poprawność obliczonych współrzędnych była kontrolowana przez porównanie ze zgeometryzowaną mapą topograficzną w skali 1:10 000 oraz pomierzonymi w terenie wybranymi punktami kontrolnymi, zapewniając dokładność pomiaru poniżej 1 metra.

Do przepróbkowania pikseli (*resampling*) wykorzystano metodę najbliższego sąsiada (*Nearest Neighbour*), która zapewnia zachowanie oryginalnych wartości pikseli (ryc. 15).⁵

Korekcja atmosferyczna obrazów hiperspektralnych

O konieczności przeprowadzenia korekcji atmosferycznej świadczy duża absorpcja promieniowania w atmosferze, szczególnie w widzialnym zakresie widma elektromagnetycznego (ryc. 16). Powoduje to duże fluktuacje jaskrawości pikseli (DN^6) poszczególnych kanałów różnych pasów zobrazowań, gdy każda linia nalotu została wykonana o innej porze dnia i przy innym kącie padania promieni słonecznych. Rycina 17 przedstawia przykładową różnicę w rejestracji sygnału przez detektor polowy i lotniczy. Zastosowanie automatycznych algorytmów klasyfikacji obiektów wg cech spektralnych wymagało doprowadzenia odpowiedzi spektralnych tych samych obiektów, zobrazowanych na różnych obszarach, do porównywalnych wartości spektralnych⁷.

⁵ Wyniki klasyfikacji wraz ze współrzędnymi geograficznymi zaprezentowano na rycinach 28-35.

⁶ DN – *Digital Number* (jasność danego piksela).

⁷ W celu realizacji tego zadania konieczna była precyzyjna rejestracja odpowiedzi spektralnych wybranych obiektów (jasnych i ciemnych spektralnie) z tzw. poligonów kalibracyjnych (Zagajewski, 2009). Jako materiał referencyjny pozyskane były także spektra z pomiaru spektrometrem słonecznym, czyli wielospektralnego spektrometrem rejestrującym widmo Słońca (Klińska, 2004).

W niniejszych pracach korekcja atmosferyczna została wykonana wraz z normalizacją topograficzną, która pozwala wyeliminować wpływ rzeźby (duże zróżnicowanie oświetlenia stoków zorientowanych ku padającym promieniom słońca oraz pozostających w cieniu). Elementem dodatkowym, aczkolwiek bardzo ważnym ze względu na lokalizację obszarów testowych w środowiskach górskich, było wykonanie empirycznej korekcji BRDF, czyli korekcji wpływu kierunku padania i odbicia promieni słonecznych, orografii terenu oraz pozycji detektora (Richter, 2004).


Korekcja atmosferyczna bazowała na kodach RTC (*Radiative Transfer Codes*) i modelu stanu atmosfery obszarów górskich wbudowanym do programu ATCOR⁸. Na dane wejściowe do korekcji składały się charakterystyki spektralne najważniejszych obiektów występujących na badanym terenie. Pomierzone one zostały w trakcie zobrazowania przy udziale niemieckich specjalistów (Andreas Mueller oraz Martin Habermeyer) i przy użyciu spektrometru hiperspektralnego GER3700 z DLR. Weryfikacja jakości korekcji atmosferycznej polegała na porównaniu spektrów referencyjnych (nie były one wykorzystane do korekcji) z wygenerowanymi z obrazu po jego korekcji. Na każdy pas zobrazowania wykorzystano 8-9 terenowych pomiarów spektrometrycznych, zarejestrowanych przez naziemne spektrometry hiperspektralne.

Proceduralnie korekcja atmosferyczna składała się z następujących etapów:

- wykonanie pomiarów spektrometrycznych wybranych obiektów w terenie (w czasie trwania zobrazowania lotniczego) za pomocą spektrometru hiperspektralnego GER3700. Każdy pomiar udokumentowany został precyzyjnym pomiarem GPS (o dokładności <1 m),
- konwersja rozdzielczości spektralnej pomiaru terenowego (760 kanałów) do rozdzielczości spektralnej skanera DAIS 7915⁹ (ryc. 18);
- załadowanie do programu ATCOR: skorygowanych geometrycznie obrazów DAIS 7915, spektrów pomierzonych w terenie (wraz z precyzyjną lokalizacją pomiaru), Numerycznego Modelu Terenu, informacji o dniu oraz godzinie wykonania zobrazowania (do obliczenia azymutu oraz kąta padania promieni słonecznych), podstawowych informacji o ciśnieniu atmosferycznym oraz temperaturze termodynamicznej i radiometrycznej wybranych obiektów. Parametry te pozwoliły na dopasowanie RTC oraz modelu atmosfery obszarów górskich zawar-

⁸ Opisuje on najbardziej typowe stany atmosfery występujące nad obszarami górskimi. Model ten bazuje na modelach transferu promieniowania przez atmosferę w zależności od zadanych parametrów (*Radiative Transfer Codes*, RTC). Niezbędnym elementem do korekcji atmosferycznej był także Numeryczny Model Terenu (Jakomulska, Sobczak, 2002; Richter, Schläpfer, 2002; Schläpfer, Richter, 2002).

⁹ Skaner DAIS 7915 w zakresie 450-2450 nm wykonuje zobrazowanie w 72 kanałach, pozostałe 7 kanałów przypada na zakres 3-5 μm (jeden kanał) oraz 8,7-12,3 μm – 6 kanałów.



Ryc. 15. Kompozycje RGB 22,12,1 (869, 693, 496 nm) poszczególnych linii zobrażeń DAIS 7915 Tatr Wysokich⁵: A – druga, B – czwarta, C – piąta, D – szósta

Fig. 15. RGB 22,12,1 (869, 693, 496 nm) compositions of the DAIS 7915 imagery of paths no.: A – 2nd, B – 4th, C – 5th, D – 6th

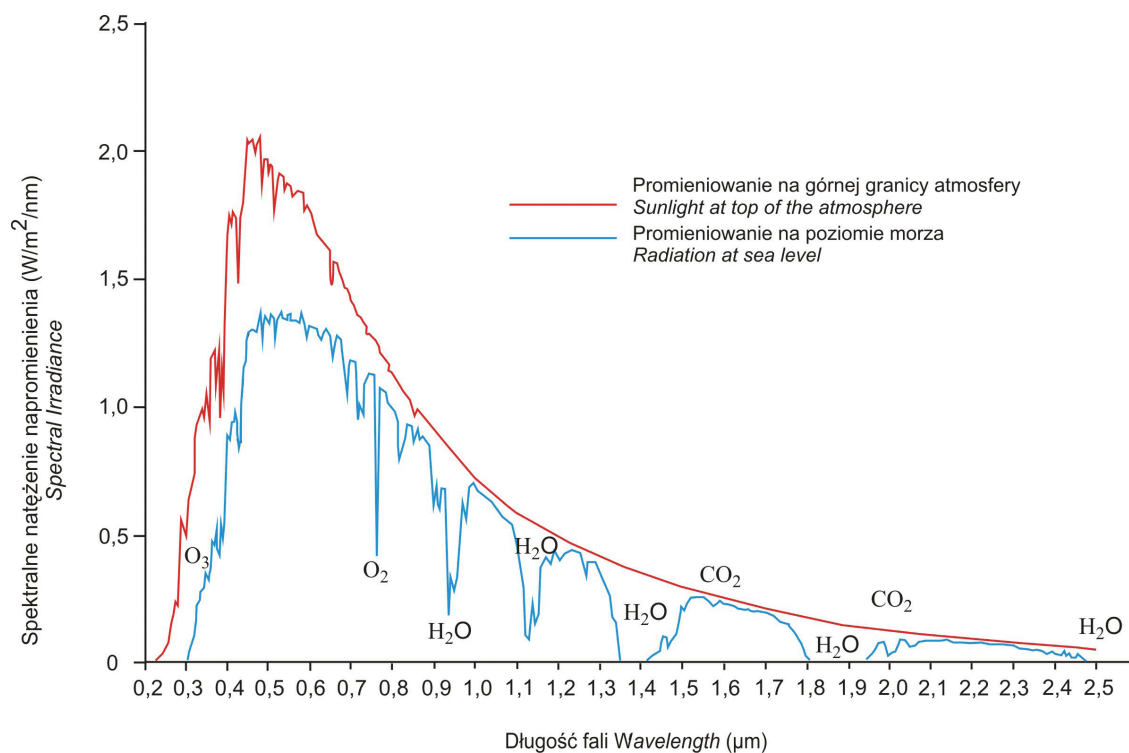
tych w ATCOR do warunków panujących podczas zobrażenia;

- wykonanie modelowania spektrów pozyskanych z pomiarów naziemnych i spektrów z odpowiadających im przestrzennie pikseli (ryc. 19)¹⁰;

¹⁰ Bazując na zaawansowanej bazie danych dotyczącej szacowania transferu promieniowania przez atmosferę MODTRAN, przystąpiono do modelowania składu atmosfery

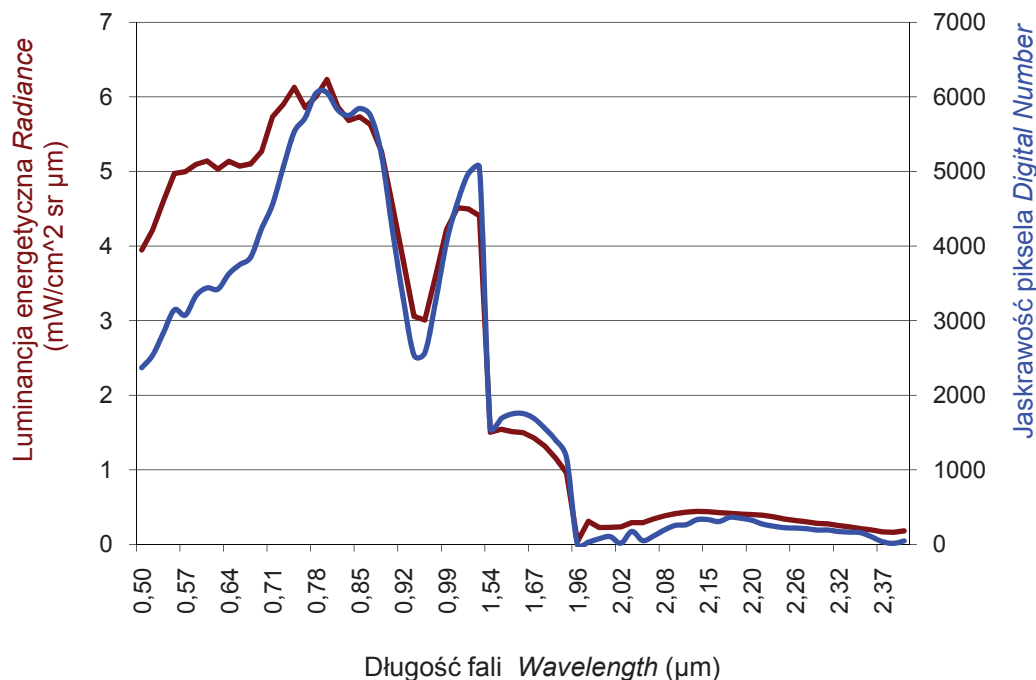
- porównanie uzyskanych wyników (ryc. 20).

i eliminacji jej wpływu na rejestrowany przez sensor obraz. Proces ten polegał na możliwie dokładnym określeniu parametrów meteorologicznych. Dane referencyjne pozyskano z automatycznych stacji pomiarowych zainstalowanych na Stacji Terenowej IGiPZ PAN na Hali Gąsienicowej (dodatkowo wykorzystywane były dane IGiPZ PAN pozyskane lokalnie z przenośnych stacji pomiarowych Hobo).



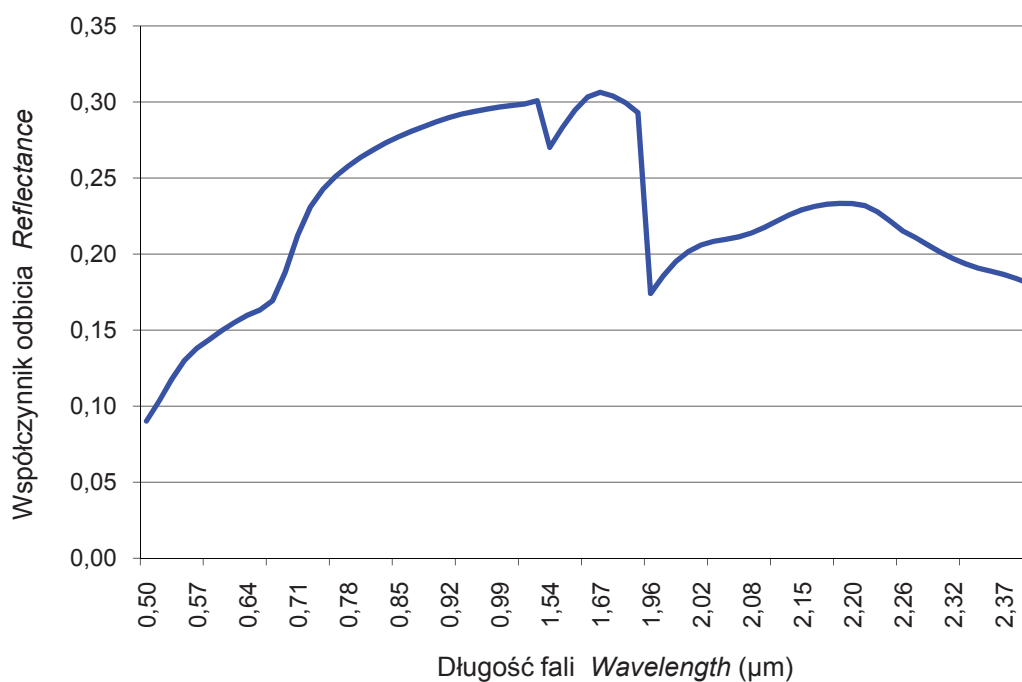
Ryc. 16. Natężenie napromienienia rejestrowanego na górnej warstwie atmosfery oraz na poziomie morza (źródło: Glossary, 2000, zmodyfikowane)

Fig. 16. Spectral irradiance at top of atmosphere and at sea level (source: Glossary, 2000, modified)




Ryc. 17. Porównanie jaskrawości piksela i luminancji energetycznej poligonu kalibracyjnego pomierzonego w terenie przed wykonaniem korekcji atmosferycznej

Fig. 17. Comparison of pixel's digital number acquired from airborne level (before atmospheric correction) and field measured radiance



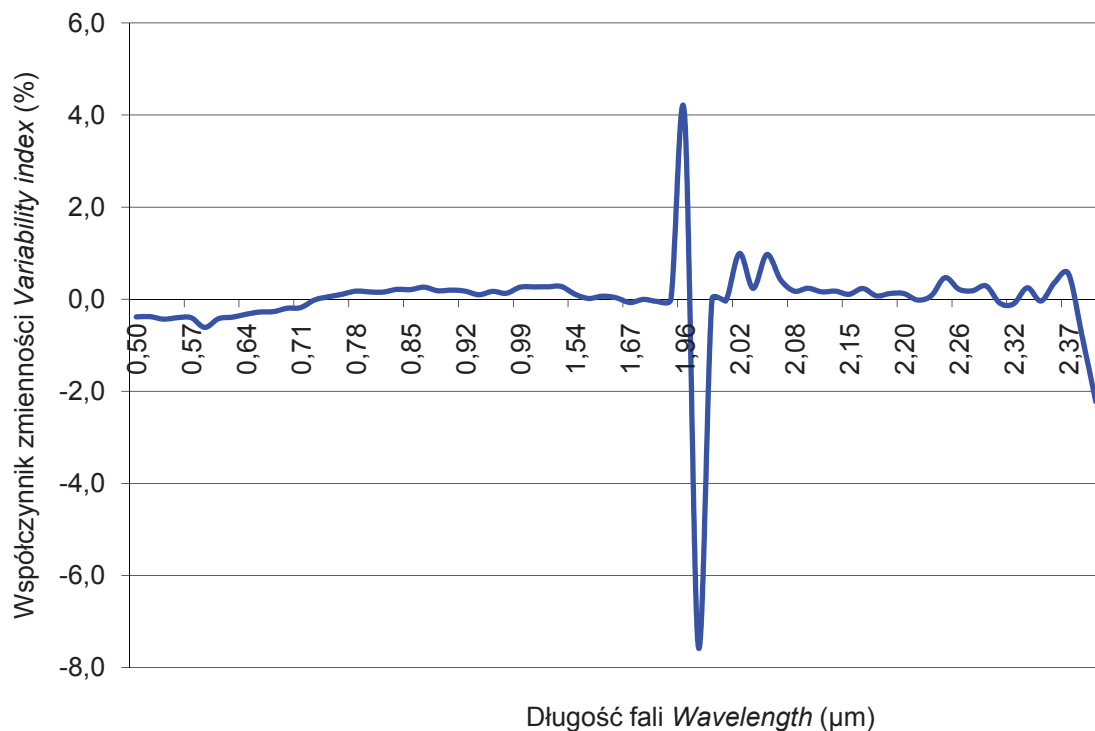
Ryc. 18. Krzywa odbicia spektralnego wybranego poligonu kalibracyjnego pomierzonego w terenie po przetworzeniu do rozdzielczości skanera DAIS 7915

Fig. 18. Field measured spectral characteristic of an atmospheric calibration target after a processing to the spectral resolution of the DAIS 7915 scanner



Ryc. 19. Porównanie charakterystyki spektralnej z pomiaru naziemnego oraz zobrazowania po korekcji atmosferycznej

Fig. 19. Comparison of the field and airborne acquired spectral characteristic after the atmospheric correction



Ryc. 20. Współczynnik zmienności charakterystyk pomierzonych w terenie i z obrazu po korekcji atmosferycznej
 Fig. 20. Variability index of field and airborne acquired spectral characteristics after the atmospheric correction

Reasumując należy stwierdzić, że uzyskane wyniki korekcji atmosferycznej są satysfakcjonujące, gdyż charakterystyki spektralne uzyskiwane z różnych pasów zobrazowań po korekcji wahają się o kilka procent

względem pomierzonych w terenie. Na taki wynik niewątpliwie ogromny wpływ miała bardzo dobra pogoda – duża przezroczystość atmosfery i brak jakichkolwiek chmur.

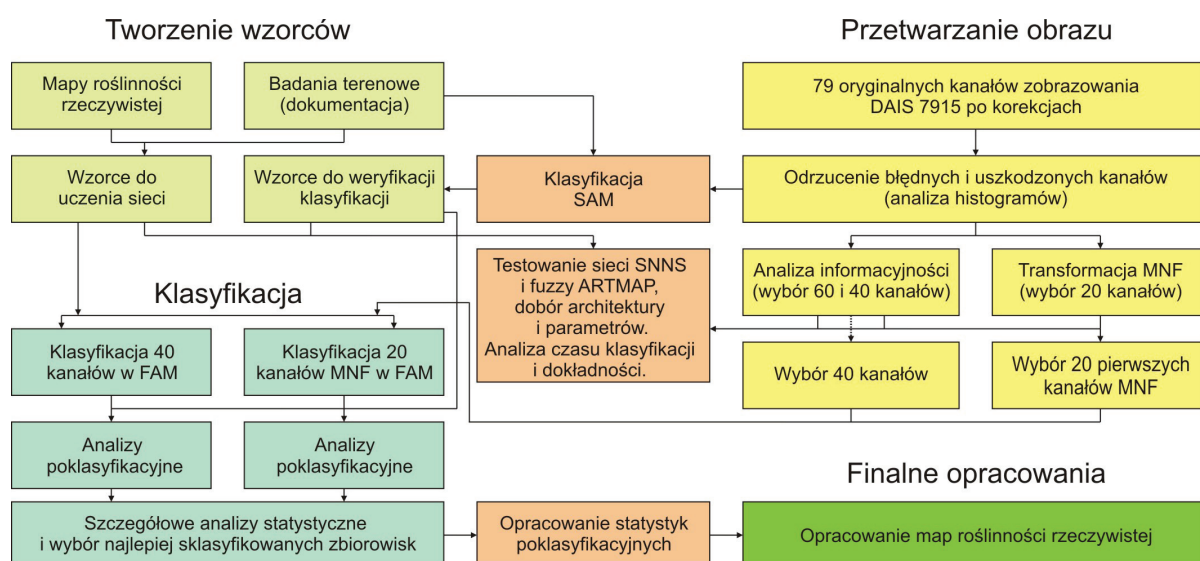
Procedura klasyfikacji danych hiperspektralnych

Wykorzystanie sztucznych sieci neuronowych do klasyfikacji wymaga: przygotowania wzorców do klasyfikacji i weryfikacji danych poklasyfikacyjnych, przetworzenia obrazów wg wymogów symulatora, wykonania wstępnej klasyfikacji w celu doboru optymalnej architektury i parametrów symulatora, sprawdzenia jakości wytrenowania sieci, wykonania właściwej klasyfikacji, przetworzenia danych do postaci binarnej i geometryzacji obrazu oraz analizy statystycznej dokładności klasyfikacji (ryc. 21).

Tworzenie wzorców do klasyfikacji i weryfikacji poklasyfikacyjnej

Jednym z najważniejszych etapów klasyfikacji jest prawidłowe przygotowanie wzorców do klasyfikacji oraz

niezależnych danych do oceny dokładności uzyskanych wyników. Najbardziej wiarygodnymi danymi są te, które bazują na rozpoznaniu terenowym i reprezentują statystycznie wiarygodną próbę. Ze względu na to, że na badanym terenie występuje duża różnorodność poligonów reprezentujących różne zbiorowiska roślinne i towarzyszące im obiekty (np. ścieżki, ściany skalne i głazy) dłożono wszelkich starań, by wzorce były reprezentatywne dla danego zbiorowiska, a ich powierzchnia nie była mniejsza niż 3-5-krotność wielkości piksela (80-200 m²). Na obszarze Doliny Gąsienicowej w latach 2002-2008 wykonano serie badań terenowych, w trakcie których pomierzono charakterystyki spektralne, wykonano pomiary biometryczne oraz zdjęcia fitosocjologiczne, a także kartowano wybrane poligony roślinności. Część tych pomiarów posłużyła do stworze-



Ryc. 21. Schemat przygotowania i klasyfikacji danych z wykorzystaniem symulatora sztucznych sieci neuronowych

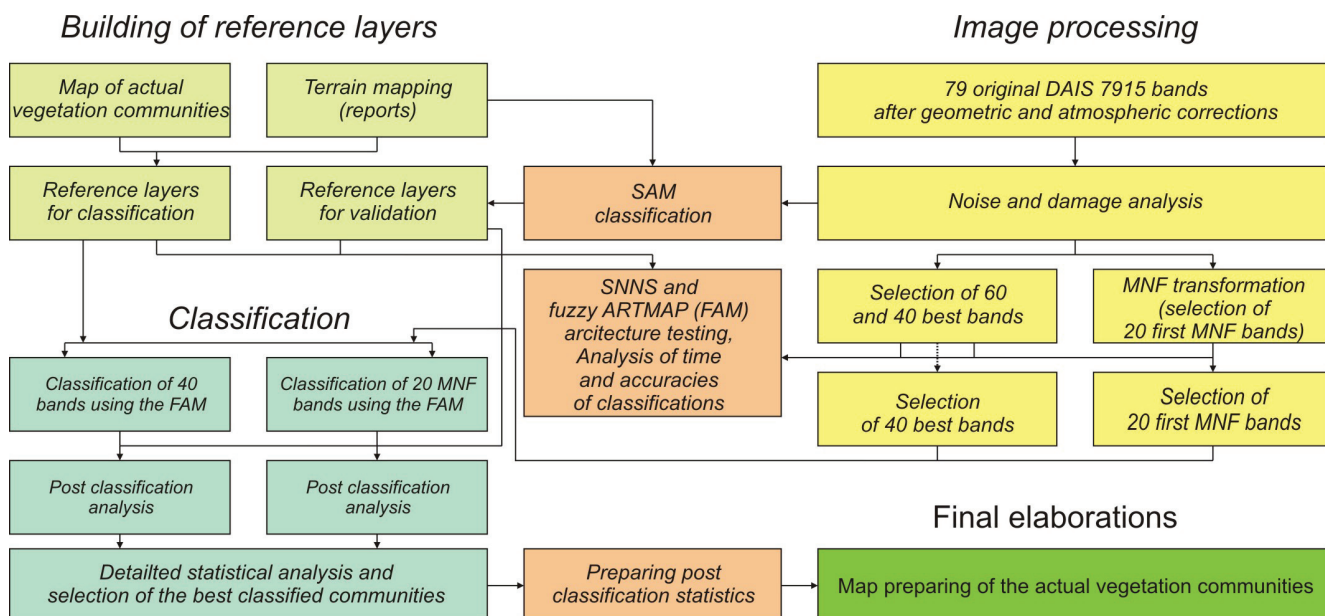


Fig. 21. Schema of data preparing, processing and ANN classifications

nia wzorców do uczenia sieci (ryc. 22a; Kozłowska i inni, 2006; Zagajewski i inni, 2005; 2006).

Na przygotowaną mapę wzorców do uczenia sieci nałożono mapę pikseli czystych spektralnie pozyskanych z transformacji PPI (ryc. 5). Pozwoliło to na pobranie charakterystyk spektralnych poszczególnych typów układów przestrzennych zbiorowisk roślinnych do klasyfikacji Spectral Angle Mapper (SAM). Półautomatyczna klasyfikacja SAM przebiegała według następującego algorytmu:

- stworzenie wzorców spektralnych (charakterystyk spektralnych pozyskanych z obrazu, z pikseli czystych spektralnie) do klasyfikacji;
- klasyfikacja;
- terenowa weryfikacja danych poklasyfikacyjnych – wg wyznaczonych profili na badanym terenie (głównie Doliny Gąsienicowej);
- wybór poligonów do wzorca oceny dokładności poklasyfikacyjnej (poligony, które zostały pozytywnie zweryfikowane podczas badań terenowych).

Uzyskane wyniki zostały zaprezentowane na rycinie 22b.

Wybór poligonów oparty był na badaniach terenowych, w trakcie których posiłkowano się mapą roślinności rzeczywistej (Kozłowska i inni, 2006) oraz wynikami klasyfikacji SAM. W wyniku tych prac zebrana została statystycznie znacząca próba pikseli do klasyfikacji i weryfikacji poklasyfikacyjnej (tab. 4).

Wybór i przygotowanie kanałów DAIS 7915 do klasyfikacji


Pierwszym etapem w przygotowaniu danych do klasyfikacji jest odrzucenie zaszumionych, błędnych i najmniej informacyjnych kanałów. Procedura ta została wykonana w ICM UW w pakiecie Support Vec-

tor Machine (SVM, Nowotka i inni, 2010). Podstawą była analiza informacyjności poszczególnych kanałów. Równolegle zastosowano 2 algorytmy: wyboru najważniejszych kanałów oraz kolejności odrzucania najmniej informacyjnego kanału danej iteracji (w każdej kolejnej iteracji odrzucany był najmniej informacyjnie cenny kanał)¹¹. W pierwszym przypadku analizowano permutację wartości między klasyfikowanymi obiektami; polegało to na tym, iż generowana była klasyfikacja danych DAIS 7915 dla wszystkich 72 kanałów (odrzuconych zostało 7 kanałów podczerwieni termalnej) i analizowano zmiany dokładności klasyfikacji przed i po usunięciu danego kanału (Guyon i inni, 2002). Rycina 23 przedstawia wyniki wyboru najważniejszych kanałów przeprowadzonego na dziesięciu powtórzeniach losowo wybranych pikseli każdego kanału (wysokość słupków na ryc. 23 pokazuje rozrzut z poszczególnych powtórzeń analizy).

W przypadku algorytmu odrzucającego najmniej informacyjne kanały, w każdej kolejnej iteracji klasyfikacji eliminowany był jeden, najmniej istotny. Analizę wykonano dziesięciokrotnie, za każdym razem losowo wybierając piksele każdego kanału. Ich wynikiem był wykres przedstawiający, do której iteracji dotrwał dany kanał, co pozwoliło na określenie jego ważności (ryc. 24). W tym przypadku także rozrzut wyników uzyskanych z 10 powtórzeń przedstawiono w postaci słupków (im wyższy słupek, tym większy rozrzut wyników).

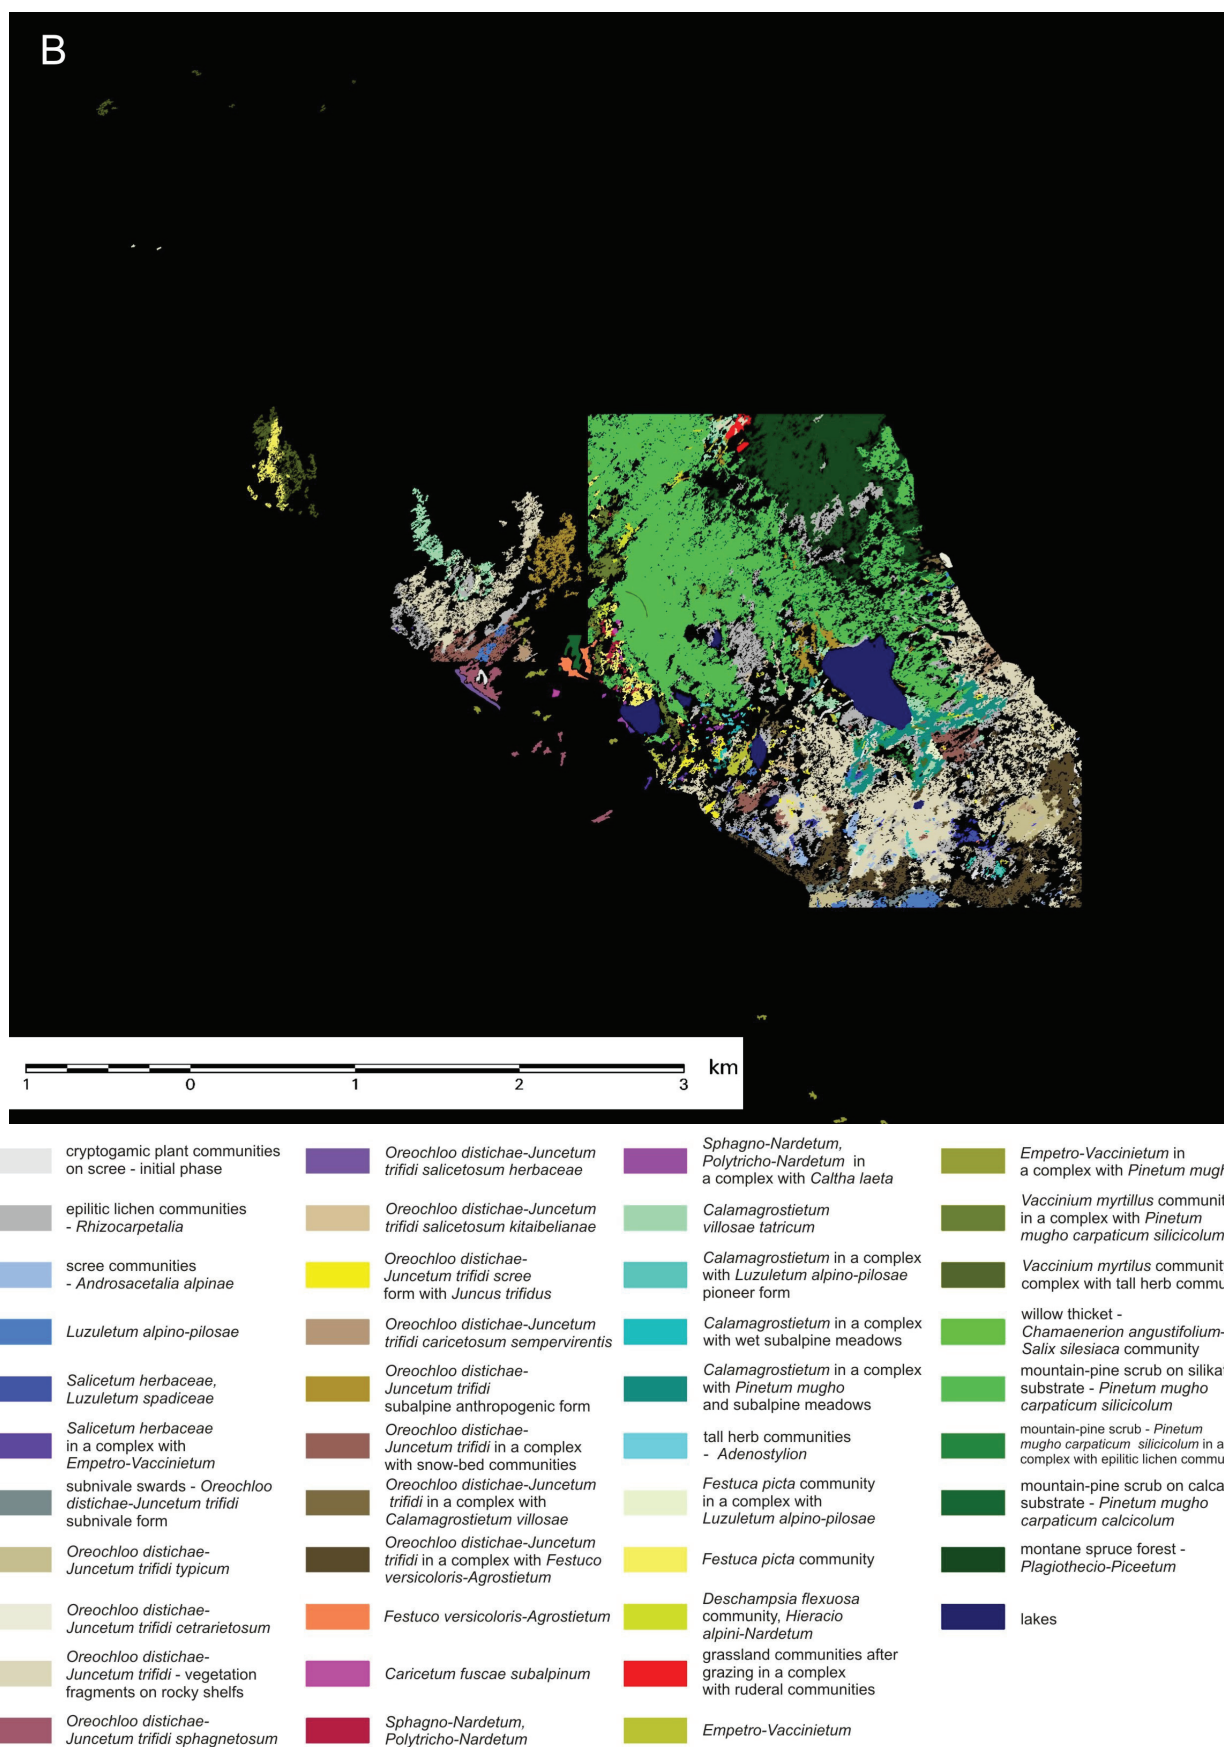
Powyższe analizy wykazały, że najbardziej informacyjne i przydatne do klasyfikacji kanały zobrazowania DAIS 7915 obszaru Tatr Wysokich to: 26, 1, 10, 38, 13, 32, 40, 25, 31, 2, 14, 11, 30, 27, 3, 46, 24, 16, 28, 54, 39, 42, 12, 9, 29, 8, 36, 69, 20, 35, 21, 4, 44, 22, 34, 23, 68, 70, 37, 5, 67, 15, 61, 58, 63, 17, 6, 49, 66,

¹¹ Wykorzystano zmodyfikowaną metodę RBF (Recursive Backward Feature Elimination, Guyon i inni, 2002; Nowotka i inni, 2010).



1 0 1 2 km

- | | | | | | | | |
|---|--|---|--|---|---|---|---|
|  | pionierskie zbiorowiska roślin zarodnikowych |  | murawa alpejska wyleżyskowa |  | wilgotne psiary w kompleksie z ziołoroślami |  | wysokogórskie borówczyska bażynowe z zaroślami kosodrzewiny |
|  | zbiorowiska porostów naskalnych |  | murawa alpejska z wierzbą Kitaibela |  | traworośle trzcinnikowe |  | zbiorowiska borówki czernicy z zaroślami kosodrzewiny |
|  | pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach |  | murawa alpejska postać piargowa z sitem skucią |  | traworośle trzcinnikowe postać pionierska |  | zbiorowiska borówki czernicy z traworoślami i ziołoroślami |
|  | wilgotne traworośla kosmatkowe |  | murawa alpejska z turzycą zawsze zieloną |  | traworośle trzcinnikowe z wilgotnymi murawami |  | zbiorowiska zaroślowe wierzby śląskiej i malin |
|  | wyleżyska w piętrze alpejskim |  | murawa alpejska postać subalpejska |  | traworośle trzcinnikowe z zaroślami kosodrzewiny i murawami subalpejskimi |  | zarośla kosodrzewiny na podłożu bezwęglanowym |
|  | wyleżyska w piętrze subalpejskim |  | murawa alpejska z wyleżyskami |  | ziołorośla |  | kępy kosodrzewiny na ścianach skalnych |
|  | murawa subniwalna |  | murawa alpejska z traworoślami |  | wilgotne murawy z wyleżyskami i ziołoroślami |  | zarośla kosodrzewiny na podłożu węglanowym |
|  | murawa alpejska typowa |  | murawa alpejska na podłożu granitowym i mylonitach |  | murawy powypasowe świeże i suche |  | bór górmoreglowy |
|  | murawa alpejska porostowa |  | murawa alpejska na podłożu węglanowym |  | murawy powypasowe wilgotne |  | woda |
|  | murawy alpejskie na półkach skalnych |  | torfowisko przejściowe |  | murawy powypasowe silnie zantropogenizowane | | |
|  | murawa alpejska torfowcowa |  | wilgotne psiary |  | wysokogórskie borówczyska bażynowe | | |



Ryc. 22. Poligony kluczowe do: A – uczenia sieci, B – weryfikacji dokładności poklasyfikacyjnej. Ze względu na wymagania symulatora FAM dane zostały zapisane w formacie *.bmp w 8-bitowej przestrzeni barw. Czarnym fototonem zaznaczono obszary będące przedmiotem klasyfikacji

Fig. 22. Key polygons for: A – nets teaching, B – validation of post classification images. According to technical requirements of the FAM files were saved as 8-bit with a standard 256 colors table. Black areas were classification objects

Tabela 4. Liczba pikseli poszczególnych zbiorowisk roślinnych wykorzystanych jako wzorce do uczenia sieci i weryfikacji poklasyfikacyjnej poszczególnych typów wydzielen (ryc. 22)

Table 4. Quality assessment of pixels number dedicated to teaching and post classification validation (Fig. 22)


Nr etykiety Label id	Klasy Classes	Uczenie Teaching (piksele/ pixels)	Weryfikacja Validation (piksele/ pixels)	% pikseli (uczenie/ weryfikacja) % of pixels (teaching/ validation)
1	pionierskie zbiorowiska roślin zarodnikowych <i>cryptogamic plant communities on scree – initial phase</i>	2661	3930	67,7
2	zbiorowiska porostów naskalnych <i>epilitic lichen communities – Rhizocarpetalia</i>	11762	43634	27,0
3	pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach <i>scree communities – Androsacetalia alpinae</i>	4228	12783	33,1
4	wilgotne traworośla kosmatkowe <i>Luzuletum alpino-pilosae</i>	5043	8804	57,3
5	wyleżyska w piętrze alpejskim <i>Salicetum herbaceae, Luzuletum spadiceae</i>	729	2262	32,2
6	wyleżyska w piętrze subalpejskim <i>Salicetum herbaceae in a complex with Empetro-Vaccinietum</i>	219	687	31,9
7	murawa subniwalna <i>subnivale swards – Oreochloo distichae-Juncetum trifidi subnivale form</i>	1876	2727	68,8
8	murawa alpejska typowa <i>Oreochloo distichae-Juncetum trifidi typicum</i>	6554	11624	56,4
9	murawa alpejska porostowa <i>Oreochloo distichae-Juncetum trifidi cetrarietosum</i>	483	1459	33,1
10	fragmenty muraw alpejskich na półkach skalnych <i>Oreochloo distichae-Juncetum trifidi – vegetation fragments on rocky shelves</i>	873	47501	1,8
11	murawa alpejska torfowcowa <i>Oreochloo distichae-Juncetum trifidi sphagnetosum</i>	689	3867	17,8
12	murawa alpejska wyleżyskowa <i>Oreochloo distichae-Juncetum trifidi salicetosum herbaceae</i>	426	896	47,5
13	murawa alpejska z wierzwą Kitaibela <i>Oreochloo distichae-Juncetum trifidi salicetosum kitaibeliana</i>	622	1807	34,4
14	murawa alpejska postać piargowa z sitem skuciną <i>Oreochloo distichae-Juncetum trifidi scree form with Juncus trifidus</i>	3997	9865	40,5
15	murawa alpejska z turzycą zawsze zieloną <i>Oreochloo distichae-Juncetum trifidi caricetosum sempervirentis</i>	2358	3740	63,0
16	murawa alpejska postać subalpejska <i>Oreochloo distichae-Juncetum trifidi subalpine anthropogenic form</i>	4943	9297	53,2
17	murawa alpejska w kompleksie z wyleżyskami <i>Oreochloo distichae-Juncetum trifidi in a complex with snow-bed communities</i>	4498	10128	44,4
18	murawa alpejska w kompleksie z traworoślami <i>Oreochloo distichae-Juncetum trifidi in a complex with Calamagrostietum villosae</i>	1875	2926	64,1
19	kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach <i>Oreochloo distichae-Juncetum trifidi in a complex with Festuco versicoloris-Agrostietum</i>	1921	21250	9,0
20	murawa alpejska na podłożu węglanowym <i>Festuco versicoloris-Agrostietum</i>	1155	1945	59,4
21	torfowisko przejściowe <i>Caricetum fuscae subalpinum</i>	304	830	36,6
22	wilgotne psiary <i>Sphagno-Nardetum, Polytricho-Nardetum</i>	837	1249	67,0
23	wilgotne psiary w kompleksie z zioloroślami <i>Sphagno-Nardetum, Polytricho-Nardetum in a complex with Caltha laeta community</i>	387	1030	37,6
24	traworośle trzcinnikowe <i>Calamagrostietum villosae tatricum</i>	6201	8976	69,1

25	traworośle trzcinnikowe postać pionierska <i>Calamagrostietum in a complex with Luzuletum alpino-pilosae pioneer form</i>	1675	3479	48,1
26	traworośle trzcinnikowe w kompleksie z wilgotnymi murawami <i>Calamagrostietum in a complex with wet subalpine meadows</i>	324	915	35,4
27	traworośle trzcinnikowe w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi <i>Calamagrostietum in a complex with Pinetum mugho and subalpine meadows</i>	1405	13113	10,7
28	Ziolorośla <i>tall herb communities – Adenostylion</i>	1128	1933	58,4
29	wilgotne murawy w kompleksie z wyleżyskami i zioloroślami <i>Festuca picta community in a complex with Luzuletum alpino-pilosae</i>	982	2126	46,2
30	murawy powypasowe świeże i suche <i>Festuca picta community</i>	2193	3868	56,7
31	murawy powypasowe wilgotne <i>Deschampsia flexuosa community, Hieracio alpini-Nardetum</i>	1907	2891	66,0
32	murawy powypasowe, fragmenty silnie zantropogenizowane <i>grassland communities after grazing in a complex with ruderal communities</i>	305	1089	28,0
33	wysokogórskie borówczyska bażynowe <i>Empetro-Vaccinietum</i>	3012	4383	68,7
34	wysokogórskie borówczyska bażynowe w kompleksie z zaroślami kosodrzewiny <i>Empetro-Vaccinietum in a complex with Pinetum mugho</i>	363	1385	26,2
35	zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny <i>Vaccinium myrtillus community in a complex with Pinetum mugho carpaticum silicicolum</i>	5878	8401	70,0
36	zbiorowiska borówki czernicy w kompleksie z traworoślami i zioloroślami <i>Vaccinium myrtillus community in a complex with tall herb communities</i>	3279	6335	51,8
37	zbiorowiska zaroślowe wierzby śląskiej i malin <i>willow thicket – Chamaenerion angustifolium-Salix silesiaca community</i>	1039	2170	47,9
38	zarośla kosodrzewiny na podłożu bezwęglanowym <i>mountain-pine scrub on silikat substrate – Pinetum mugho carpaticum silicicolum</i>	3568	109604	3,3
39	kępy kosodrzewiny na ścianach skalnych <i>mountain-pine scrub – Pinetum mugho carpaticum silicicolum in a complex with epilithic lichen communities</i>	986	1487	66,3
40	zarośla kosodrzewiny na podłożu węglanowym <i>mountain-pine scrub on calcareous substrate – Pinetum mugho carpaticum calcicolum</i>	365	1920	19,0
41	bór górnoreglowy <i>montane spruce forest – Plagiothecio-Piceetum</i>	2219	48370	4,6
42	woda <i>water</i>	1940	26454	7,3


71, 19, 43, 65, 18, 7, 48, 62, 33, 64, 50, 52, 51, 53, 57, 59, 55, 56, 72, 60, 45, 41, 47. Do dalszych analiz wybrano 60 pierwszych z powyższej listy spośród 72 dostępnych z zakresu 496-4135 nm. Kanały te zostały wykorzystane do wykonania transformacji MNF (redukcja szumów oraz analiza głównych składowych). Pozwoliło to stworzyć jakościowo nowe, zdekorrelowane informacyjnie kanały¹².

¹² Do klasyfikacji sieciami neuronowymi wykorzystanych zostało 20 pierwszych kanałów MNF. Ograniczenie liczby kanałów pozwala znacząco skrócić czas uczenia i klasyfikacji sieci.


Dysponując danymi o informacyjności kanałów można było dobrać optymalną liczbę kanałów do klasyfikacji. Zbyt duża liczba kanałów powoduje znaczące wydłużenie czasu trwania klasyfikacji, czyniąc dane rozwiązanie mało aplikacyjnym. Do określenia struktury danych wejścia wykorzystano symulator SNNS, który poprzez podawany zsumowany kwadratowy błąd klasyfikacji SSE (*Sum Squared Error*) pozwala na bieżąco analizować dokładność wykonywanej klasyfikacji. Procedura wyboru klasyfikacji polegała na utworzeniu kilku zestawów danych zawierających kanały MNF oraz oryginalnych kanałów (po korekcji geometrycznej i atmosferycznej).



Ryc. 23. Ważność poszczególnych kanałów zobrażenia DAIS 7915 obszaru Tatr Wysokich. Jednostki arbitralne (Nowotka i inni, 2010)
 Fig. 23. DAIS 7915 bands' importance of the High Tatras. Arbitrary units (Nowotka i inni, 2010)



Ryc. 24. Analiza przydatności poszczególnych kanałów zobrażenia DAIS 7915 obszaru Tatr do klasyfikacji. Pogrubiona linia wewnątrz każdego wieloboku oznacza wartość najczęściej występującą przy eliminacji danego kanału (Nowotka i inni, 2010)
 Fig. 24. Analysis of a classification usefulness of the DAIS 7915 bands of the High Tatras. A bold line inside of the blocks show a number of mostly rejection's iteration (Nowotka i inni, 2010)



Ryc. 25. Schemat funkcjonalny okna teksturalnego 3x3 piksele
 Fig. 25. Functional schema of a textural window 3x3 pixels

Dodatkowym elementem było wykorzystanie okna teksturalnego składającego się z macierzy 3x3, 5x5 oraz 7x7 pikseli¹³. Zabieg ten umożliwia analizę wpływu wielkości otoczenia klasyfikowanego piksela. Koncepcja działania okna teksturalnego 3x3 piksele polega na tym, że podczas klasyfikacji analizowane jest sąsiedztwo klasyfikowanego piksela filtrująca macierzą, a na wyjściu generowany jest obraz mniejszy niż w obrazie wejściowym o 2 piksele w każdej linii oraz o 2 piksele w każdej kolumnie. W przypadku okna teksturalnego 5x5 pikseli obraz wyjściowy będzie pomniejszony o 4 piksele w każdym kierunku, natomiast w przypadku 7x7 o 6 pikseli (ryc. 25; Krówczyńska, 2004).

Na potrzeby niniejszej pracy przetestowano zestawy danych zawierających 5, 10, 15 i 20 kanałów MNF oraz 40, 50 i 60 oryginalnych kanałów, dodatkowo zastosowane zostały okna teksturalne 3x3, 5x5 i 7x7 pikseli. Uczenie sieci zostało wykonane dla 18 warstw wzorcowych na zestawie 949 000 pikseli wejściowych. Testowanie sieci odbyło się na zestawach danych po transformacji MNF (mnf5, mnf10, mnf15 oraz mnf20, gdzie liczba oznacza liczbę kanałów MNF wykorzystanych do klasyfikacji). Równoległe z klasyfikacją danych skompresowanych prowadzona była klasyfikacja danych oryginalnych (hy40, hy50 oraz hy60, gdzie cyfry oznaczają liczbę kanałów DAIS 7915 po korekcji geometrycznej i atmosferycznej wykorzystanych do klasyfikacji). Dodatkowo, każdy zestaw analizowany był z wykorzystaniem okna teksturalnego składającego się z 3x3, 5x5 i 7x7 pikseli (odpowiednio x3, x5 oraz x7). Na rycinie 26 przedstawiono wyniki klasyfikacji, zgodnie z przedstawionymi oznaczeniami zamieszczona obok legenda oznacza rodzaj danych (mnf – dane po transformacji MNF, hy – oryginalne dane), liczbę kanałów oraz rodzaj użytego okna teksturalnego. Na przykład hy60x5 oznacza, że do klasyfikacji zostało wykorzystanych 60 oryginalnych kanałów DAIS i zastosowano okno teksturalne 5x5 pikseli.

Zgodnie z oczekiwaniami, zestawy niewielkiej ilości danych zawierające kilka-kilkanaście kanałów bardzo szybko trenowały sieć, ale poziom błędów był wysoki

(ryc. 26). Zwiększenie liczby kanałów do kilkudziesięciu zdecydowanie zmniejszyło błędy wytrenowania sieci, ale ze względu na rozbudowanie liczby neuronów wejściowych oraz ukrytych budujących sieć¹⁴ zwiększała się wielkość sieci, co zdecydowanie wydłużało procedurę uczenia sieci (sieć składająca się z 60 oryginalnych kanałów z oknem teksturalnym 7x7 pikseli klasyfikowana była ponad 4,5 miesiąca! na stacji roboczej DELL Precision Workstation z procesorem czterordzeniowym po 2,3 GHz każdy rdzeń oraz 8GB pamięci RAM).

Uwzględniając możliwości operacyjnego stosowania sieci oraz poziom uzyskiwanych dokładności, optymalnym rozwiązaniem jest stosowanie sieci neuronowych składających się z około 40 oryginalnych kanałów lub też 20 pierwszych kanałów MNF. Podobne wyniki osiągnęli także inni badacze (ryc. 27; Pal, Mather, 2006).


Wykorzystanie 40 kanałów danych DAIS 7915 oraz zestawu uczącego składającego się z 400 pikseli pozwala uzyskać całkowite wyniki klasyfikacji na poziomie 90%, a zastosowanie mniejszej liczby pikseli lub mniejszej liczby kanałów obniża uzyskiwane dokładności klasyfikacji (ryc. 27). Zwiększenie liczby kanałów nie powoduje natomiast znaczącej poprawy wyników (Pal, Mather, 2006). Ten ostatni pogląd nie znalazł potwierdzenia w niniejszych badaniach (ryc. 26), możliwe, że wynikało to z faktu, iż próby uczące były znacznie większe niż wspomniane 400 pikseli (tab. 4).

Reasumując: proces przygotowywania danych do klasyfikacji składał się z trzech głównych części: eliminacji najmniej informacyjnych kanałów; transformacji MNF oraz wyboru 40 oryginalnych kanałów spektralnych do klasyfikacji.

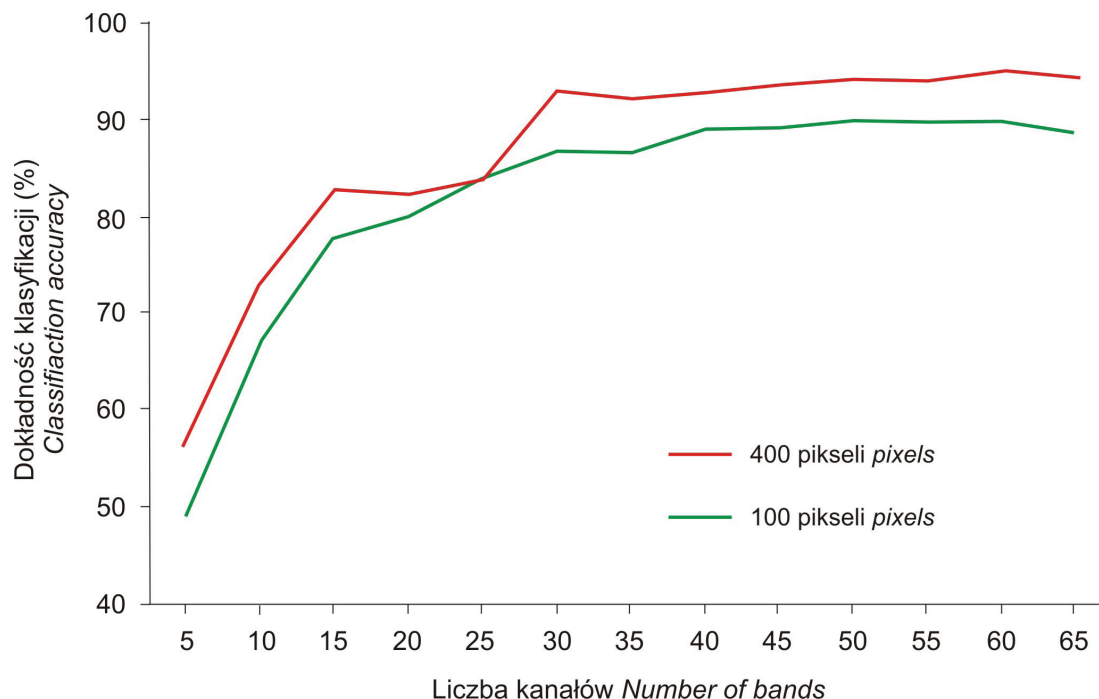
Analiza błędów uczenia sieci wykazała, że najlepsze efekty daje zastosowanie możliwie dużej liczby kanałów spektralnych i dużego zestawu uczącego (ryciny 26 i 27). Proces klasyfikacji jest długotrwały, dlatego operacyjnie uzasadnione jest zastosowanie algorytmów kompresji danych. Jednakże jak wykazały testy (ryc. 26), dokładność wytrenowania sieci jest mniejsza, ale czas krótszy (kilka pierwszych kanałów MNF pozwala

¹³ Wielkość macierzy jest definiowana podczas tworzenia pliku wsadowego (*.pat).

¹⁴ Liczba warstw ukrytych wynosiła $2n+1$, gdzie n oznacza liczbę kanałów wejściowych.



Ryc. 26. Analiza zsumowanego błędu kwadratowego (SSE) uczenia sieci MLP ze wsteczną propagacją błędów z pakietu SNNS na przykładzie poligonu kluczowego Wiatrówki (zlewnia Bystrzanki w Beskidzie Niskim, niepublikowane)
 Fig. 26. Analysis of the Sum Squared Error of the MLP (learning algorithm: back propagation of errors) of the SNNS software. Testing sets consist of 18 classes (949,000 pixels) and original DAIS 7915 bands (hy..) or MNF transformed bands (mnf...). Textural windows 3x3, 5x5 or 7x7 pixels were applied. An example of a research area of the Wiatrówki key polygon (Bystrzanka catchment, the Low Beskid) unpublished)



Ryc. 27. Dokładność klasyfikacji danych DAIS 7915 o rozdzielczości terenowej 5 m dla 8 form pokrycia terenu z wykorzystaniem sztucznych sieci neuronowych dla zestawów uczących składających się ze 100 i 400 pikseli dla każdej formy pokrycia terenu (źródło: Pal, Mather, 2006, zmodyfikowane)
 Fig. 27. Classification accuracies of 8 land cover forms on the DAIS 7915 images using an ANN. Teaching sets consist of 100 and 400 pixels (source: Pal, Mather, 2006, modified)

wytrenować sieci już po około 750 iteracjach (co zajmuje 1-2 godziny), a kolejne iteracje nie przynoszą poprawy jakości wytrenowania sieci. W przypadku zastosowania kilkudziesięciu oryginalnych kanałów sieć uczyła się w każdej kolejnej iteracji (proces został arbitralnie zakończony po 5000 iteracji¹⁵).

Do dalszych analiz wybrane zostały dwa zestawy danych składających się z 40 oryginalnych kanałów oraz 20 MNF. Ponadto starano się, by wzorce poszczególnych zbiorów roślinnych były większe niż 400 pikseli (tabela 4).

Końcowym etapem przygotowań danych do klasyfikacji było techniczne dostosowanie wzorców i danych obrazowych do klasyfikacji w symulatorze fuzzy ARTMAP. Proces ten składał się z następujących etapów:

- zapisanie wektorowych danych wzorcowych w postaci rastrowej o identycznej rozdzielczości jak dane DAIS 7915 (3 m). Dane rastrowe powinny być zapisane z tablicą barw 8 bitów w formacie *.bmp;
- ustalenie identycznych rozmiarów wzorców i danych obrazowych (taka sama liczba wierszy i kolumn);
- zapisanie każdego kanału obrazu w postaci oddzielnego pliku formatu ENVI.

Klasyfikacja i procedury poklasyfikacyjne

Do końcowych klasyfikacji wykorzystany został symulator fuzzy ARTMAP¹⁶. Wynikało to z możliwości prowadzenia równoległych procesów (na komputerach wielordzeniowych), prostego przygotowania danych (pełna kompatybilność z programem ENVI) oraz automatycznego podawania wyników klasyfikacji (macierz błędów, dokładność całkowita i wskaźnik kappa).

Klasyfikacja w symulatorze fuzzy ARTMAP odbywa się według następujących procedur (Carpenter i inni, 1992; Dagher, 2006; Rocki, 2007).

1. Wybór współczynnika czujności ρ ¹⁷. Jego wartość musi się zawrzeć w zakresie $\langle 0,1 \rangle$, dla każdego j -tego oraz dla każdego i -tego neuronu $v_{ji} = 1$, natomiast $w_{ij} = \frac{1}{1+M}$; opisy symboli dostępne w podrozdziale Fuzzy ARTMAP (s. 33);

¹⁵ Dla części zestawów proces był kontynuowany do 10 000 iteracji, jednakże w tych przypadkach efekty nie były znacząco lepsze, a proces uczenia przedłużał się o kolejne tygodnie.

¹⁶ Opracowany przez Katedrę Elektroniki Uniwersytetu w Pawii (Trianni, 2007). FAM tworzy neurony wejściowe na podstawie plików poszczególnych kanałów obrazu zapisanych w formacie ENVI. Plik w formacie *.bmp stanowi podstawę wektora sygnału referencyjnego oraz weryfikującego dokładność klasyfikacji.

¹⁷ W praktyce należy określić wartość współczynników czujności dla modułu ARTa, ARTb (w symulatorze należy podać wartości „ro1” oraz „ro2”). Muszą się one zawrzeć w zakresie $(0,1)$. Wartości zbliżone do 1 generują większe prawdopodobieństwo zgodności sygnałów w warstwie asocjacyjnej. Obniżenie parametru ρ zwiększa prawdopodobieństwo wygenerowania nowej klasy, gdyż warstwa asocjacyjna sygnałów pochodzących z ARTa oraz ARTb może uznać, że oba sygnały są zbyt różne, by łączyć daną klasę z zadaniem wzorcem.

2. Załadowanie danych (wektorów) wejściowych p_1, p_2, \dots, p_M do warstwy 1 i ich aktywacja wraz wektorami uzupełniającymi $p_1^c, p_2^c, \dots, p_M^c$ (c – complementary)¹⁸. Normalizacja wektorów wejściowych polegająca na uzupełnieniu danej wartości sygnału p_i do 1 (13):

$$p_i^c = 1 - p_i \quad (13)$$

3. Wybór zwycięskiego neuronu y_k z warstwy 2. Odbywa się na podstawie funkcji wyboru (*choice function*) $T_j(X)$ i polega na obliczeniu wartości sygnału wszystkich neuronów znajdujących się w warstwie 2 (y_j) oraz wyborze tego, którego wartość sygnału będzie największa (y_k)¹⁹ (14):

$$y_j = T_j(X) = \sum_{i=1}^M \text{MIN}(x_i, w_{ij}) \quad (14)$$

gdzie:

- y_j – j -ty neuron z warstwy 2,
- M – liczba neuronów wejściowych do warstwy 1 (liczba klasyfikowanych kanałów obrazu),
- MIN – operator ze zbiorów rozmytych, odpowiada on iloczynowi wartości na zbiorach klasycznych, np. iloczyn (wartości x, y) odpowiada $\text{MIN}(x*y \rightarrow \text{MIN}(\mu(x), \mu(y)))$,
- x_i – kolejne i -te neurony w warstwie 1 (przetwarzane za pomocą pamięci STM),
- w_{ij} – wagi połączeń neuronów klasyfikujące obraz wynikowy.

4. Obliczenie podobieństwa mierzonego współczynnikiem czujności ρ danego wektora wejściowego x_i (klasyfikowanego obrazu) do wzorca y_k (wzorec klasyfikacji) za pomocą funkcji porównania (*match function*, $l(k)$) (15):

$$l(k) = \frac{\sum_{i=1}^M \text{MIN}(x_i, v_{ki})}{\sum_{i=1}^M x_i} \quad (15)$$

¹⁸ Znormalizowany sygnał wejścia składa się z 2 neuronów, np. jeśli sygnał wejścia drugiego neuronu p_2 wynosi 0,2, to uzupełniający (komplementarny) sygnał drugiego neuronu p_2^c uzyska wartość 0,8 (1–0,2). Zabieg normalizacji dwukrotnie zwiększa liczbę neuronów klasyfikujących dane, jednakże znacząco minimalizuje to prawdopodobieństwo powstania błędów klasyfikacji i maksymalizuje prawdopodobieństwo uogólnienia uzyskanego wyniku, co w efekcie przeciwdziała nadmiernemu zwiększaniu się liczby klas, gdyż równolegle jest analizowana zarówno składnia obecności danego sygnału, jak i brak tego samego sygnału. Koncepcja ta opiera się na teorii symetryczności w zbiorach rozmytych, gdzie operatory MIN oraz MAX pełnią uzupełniające funkcje (Carpenter i inni, 1992).

¹⁹ Sygnał, który nie zostanie wybrany jest kasowany przez moduł wyboru. Operator ma wpływ na wartość progową tego sygnału poprzez parametr wyboru (α). Wartość ta decyduje o tworzeniu pętli przepływu sygnału, tj. dobór zbyt dużej wartości α powoduje wygenerowanie nowych sygnałów. Autorzy programu podają, że parametr ten powinien być zbliżony do zera, np. $\alpha = 0,001$ (Carpenter i inni, 1992).

gdzie:

v_{ki} – różnica wartości wagi połączenia sprawdzającego pomiędzy wartością sygnału i -tego neuronu wejściowego (x_i) a wartością sygnału wzorcowego (y_k) z warstwy 2. Jest to odległość x_i od kategorii y_k .

Proces ten odbywa się wewnątrz warstwy asocjacyjnej, gdy wartość współczynnika:

$\rho \geq l(k)$ – powstaje nowa klasa dla wektora wejściowego i powtarza się cały cykl,

$\rho < l(k)$ – sieć przechodzi do kolejnego etapu klasyfikacji.

5. Korekcja wartości wag połączeń pomiędzy warstwą klasyfikowaną a wzorcową (v_{ki} , w_{ik}). W pierwszej kolejności następuje obliczenie nowych wartości wag sprawdzających \hat{v}_{ki} oraz klasyfikujących \hat{w}_{ik} dla każdego i -tego neuronu, według następujących wzorów (16, 17):

$$\hat{v}_{ki} = \beta \text{MIN}(v_{ki}, x_i) + (1 - \beta)v_{ki} \quad (16)$$

$$\hat{w}_{ik} = \frac{\hat{v}_{ki}}{0,5 + \sum_{i=1}^M \text{MIN}(\hat{v}_{ki}, x_i)} \quad (17)$$

gdzie:

β definiuje szybkość uczenia i zawiera się w zbiorze liczb $\langle 0, 1 \rangle$. Dla wartości 0 nie występuje uczenie sieci.

Po korekcji nowe wagi zastępują uprzednie wartości, jakie były zapisane w pamięci LTM ($v_{ki} = \hat{v}_{ki}$ oraz $w_{ik} = \hat{w}_{ik}$).

6. Klasyfikacja siecią (fuzzy) ARTMAP. Po ustaleniu wag między sieciami ARTa i b, zapisanymi poprzez połączenia w warstwie asocjacyjnej, sieć ARTb pozostaje nieaktywna (współczynnik szybkości uczenia sieci wynosi 0 oraz próg czujności wynosi też 0). Wyjściem sieci staje się warstwa asocjacyjna.

W sieci ARTb obowiązują dokładnie takie same procedury jak w ARTa, czyli następuje modyfikacja sygnałów neuronów wzorcowych ($x_1^b, x_2^b, \dots, x_i^b$) z warstwy 1 modułu ARTb, wprowadzonych do warstwy 2 ($y_1^b, y_2^b, \dots, y_i^b$) modułu ARTb. Zabieg ten pozwala na dużą elastyczność sieci i eliminację poligonów niezbyt dokładnie odpowiadających wprowadzonemu wzorcowi. Ma to znaczenie w wykorzystywaniu sieci rozmytych w klasyfikacji danych teledetekcyjnych, które w większości przypadków są miksami różnych sygnałów pochodzących od różnych obiektów, czy też niezbyt dokładnie stworzonych wzorców form pokrycia terenu, np. braku eliminacji pojedynczych pikseli odpowiadających innej klasie (np. pojedynczych drzew z pastwiska, czy nieużytków, gdyż spektralnie sygnał jaki dają drzewa powinien zostać zaklasyfikowany do grupy, np. las liściasty lub iglasty).

Drugą, bardzo istotną cechą fuzzy ARTMAP jest możliwość klasyfikacji różnych danych i klas generowanych przez ARTa, według tego samego wzorca, który jest generowany przez ARTb.

W przypadku wykonania adaptacji w sieciach ARTa i ARTb następuje sprzężenie zwrotne pomiędzy war-

stwami 2 w warstwie asocjacyjnej (*Map Field*, ryc. 11). Warstwa ta odpowiada za łączenie poszczególnych klastrów wyodrębnionych w ARTa i ARTb²⁰. W przypadku relacji wektora y_i^a z warstwy 2 ARTa z dwoma wektorami y_i^b, y_j^b z warstwy 2 ARTb końcowym wynikiem klasyfikacji będzie rozdzielenie wektora y_i^a na 2 oddzielne klasy, zgodne ze wzorcem y_i^b, y_j^b z warstwy 2 ARTb.

Produktem końcowym klasyfikacji jest obraz w postaci pliku *.bmp oraz zestaw tabel dokładności klasyfikacji. Pierwszym elementem procedury poklasyfikacyjnej jest analiza uzyskanych wyników, wygenerowanych jako dodatkowy plik do obrazu poklasyfikacyjnego. Jeśli są one satysfakcjonujące należy wykonać konwersję pliku do, np. pliku *.tif, a następnie przeprowadzić geometryzację uzyskanego obrazu. Ze względu na to, że uzyskany plik z obrazem poklasyfikacyjnym ma identyczną topologię jak dane wejściowe do klasyfikacji (identyczna liczba wierszy i kolumn), geometryzacja obrazu odbywa się na podstawie danych wejściowych (kanały obrazu zapisane są w formacie ENVI i zawierają pełną informację o odwzorowaniu i projekcji).

W przypadku niezadowolających wyników klasyfikacji należy zmodyfikować parametry klasyfikacji, bądź też wzorce lub dane wejściowe.

W ramach niniejszej pracy uzyskane obrazy poklasyfikacyjne były wektoryzowane do standardu ArcGIS, a następnie wszystkie poligony, których powierzchnia była mniejsza niż 30 m² (co odpowiada 3 pikselom – 3x3m) były usuwane za pomocą komendy *eliminate*. Kończącym etapem procedury poklasyfikacyjnej było określenie dokładności wyników klasyfikacji. Cel ten był realizowany poprzez zrastrowanie wektora (po usunięciu poligonów poniżej 30 m²) i porównaniu rastra do mapy wzorcowej do weryfikacji danych poklasyfikacyjnych. Wykorzystano tu standardową procedurę zawartą w programie ENVI, obejmującą macierz błędów, która określa sposób zaklasyfikowania poszczególnych pikseli do danych klas. Oblicza się z nich następujące dokładności:

- całkowitą – stosunek pikseli poprawnie zaklasyfikowanych do danej klasy względem wszystkich zaklasyfikowanych pikseli;
- użytkownika dla danego typu układów przestrzennych roślinności – liczba pikseli zaklasyfikowanych poprawnie w stosunku do wszystkich pikseli danej klasy;
- producenta dla danego typu układów przestrzennych roślinności – ilość pikseli zaklasyfikowanych do danego typu w stosunku do liczby pikseli, które powinny być w tym typie (względem zadanego wzorca); jest to miara odniesienia do wzorca;

²⁰ Liczba kategorii wyodrębnionych w ARTa i ARTb może być różna, ściśle zależna od współczynnika czujności ρ , ponadto w trakcie trenowania sieci następują modyfikacje wartości i liczby wydzielen. Fakt ten powoduje fluktuacje wielkości i aktywności warstwy asocjacyjnej. Wielkość warstwy jest definiowana poprzez iloczyn wektorów y_M^a oraz y_M^b , gdzie indeksy ^{a, b} oznaczają moduły ARTa i ARTb, natomiast y_M – liczbę wektorów warstwy 2, które są połączone z warstwą asocjacyjną.

- błąd przeszacowania i niedoszacowania dla danego typu układów przestrzennych roślinności.

Wszystkie powyższe miary podane zostały w procentach oraz wartościach bezwzględnych liczby pikseli. Dodatkowym wskaźnikiem jest współczynnik kappa – definiuje on proporcjonalną redukcję błędów powstałych

w klasyfikacji w stosunku do błędów klasyfikacji realizowanej przypadkowo, czyli informuje, o ile wykonana klasyfikacja jest lepsza od przypadkowej.

Kończącą częścią opracowania była redakcja map poklasyfikacyjnych, która objęła standardowe procedury (przygotowanie legendy, podziałki i siatki kilometrowej).

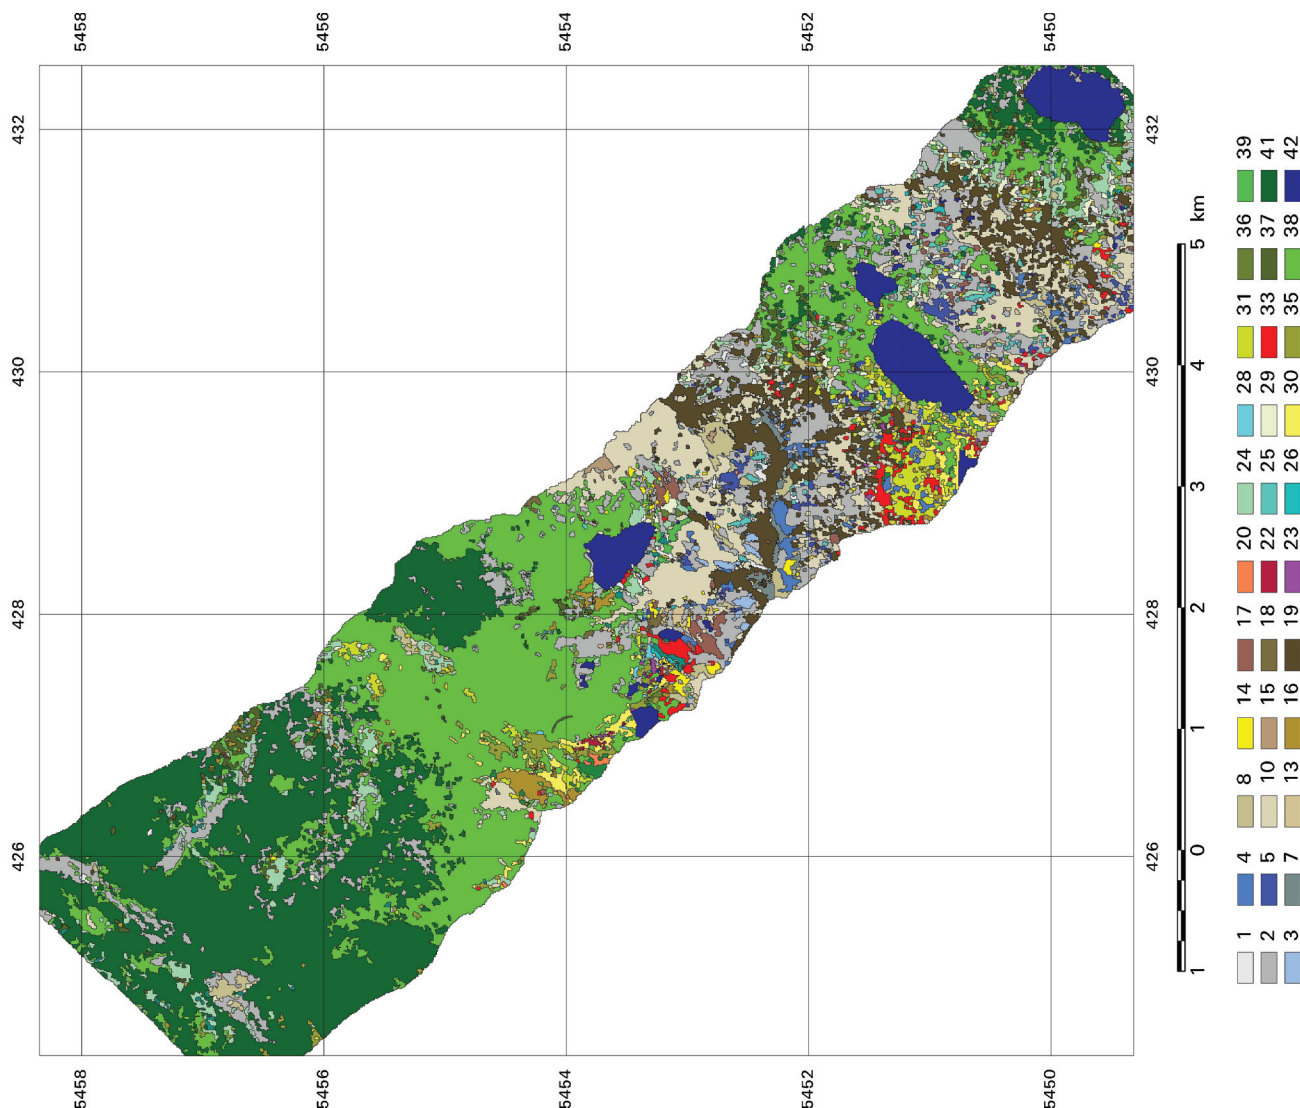
Wyniki klasyfikacji roślinności Tatr Wysokich

W wyniku klasyfikacji symulatorem fuzzy ARTMAP czterech linii zobrazowania DAIS 7915 otrzymano serię obrazów prezentowanych na rycinach 28-35. Ryciny 28-34 przedstawiają wyniki klasyfikacji uzyskane z 5000 iteracji²¹ dla poszczególnych linii (odpowiednio 6, 5, 4 oraz 2). Rycina 35 zawiera natomiast wyniki dotyczące centralnej części Tatr Wysokich uzyskane po 10 000 iteracji. Dla każdego pasa zobrazowania (wyłączając czwartą – ryc. 32) wykonano klasyfikacje na dwóch zestawach danych, pierwszy z nich składał się z 40 kanałów po korekcji geometrycznej i atmosferycznej (ryc. 28, 30, 32, 33, 35) oraz 20 pierwszych kanałów MNF (ryciny 29, 31, 34). Uzupełnieniem rycin są tabele dokładności klasyfikacji. Tabele 5-20 przedstawiają macierze błędów; wyrażają one procent zaklasyfikowanych pikseli do danej klasy (tab. 5, 7, 9, 11, 13, 15, 17, 19) oraz bezwzględną liczbę pikseli (tab. 6, 8, 10, 12, 14, 16, 18, 20). Dane statystyczne pozyskane z 5000 iteracji prezentują tabele 5-18, natomiast z 10 000 powtórzeń – tabele 19-20. Wyniki statystyczne zawarte w tabelach 5-18 bazują na analizie niespełna 400 000 pikseli, natomiast centralna część obszaru badań – na ponad 600 000 pikseli (tab. 19-20). Uzupełnieniem tych szczegółowych wyników jest tabela 21, która zawiera informacje o dokładności producenta i użytkownika oraz przeszacowaniu i niedoszacowaniu klasyfikacji (tab. 21).

Macierz błędów jest głównym sposobem jakościowej oceny wyników klasyfikacji. Pozwala ona na analizę,

które klasy zostały zakwalifikowane do jakiego wydzielenia. W programie ENVI, który był wykorzystany do tworzenia macierzy błędów, wyniki referencyjne (kolejne wydzielenia wzorca do oceny błędów) zapisywane są w kolejnych kolumnach, natomiast wyniki poszczególnych wydzieleni pochodzące z klasyfikacji – w kolejnych wierszach. Idealna sytuacja, czyli 100% zgodność wyniku klasyfikacji z wzorcem byłaby wtedy, gdyby wyniki kolejnych kolumn wzorca pokryły się z wynikami klasyfikacji (zaprezentowanymi w kolejnych wierszach). Efektem takiego stanu byłyby wartości 100 (%) na przecięciu kolejnych wierszy i odpowiadających im kolumn (danej klasy). W zdecydowanej większości przypadków część pikseli jest błędnie klasyfikowana do innych klas; w macierzy błędów przedstawione jest to wartością liczby pikseli lub zgodnością procentową danej klasy ze wzorca i klasyfikacji. Jeśli wartości podane na przecięciu odpowiadających sobie kolumn i wierszy są różne niż 100 (%), to poprzez analizę cyfr w danej kolumnie można analizować, ile procent lub pikseli zostało błędnie zaklasyfikowanych względem zadanego wzorca (w tym przypadku suma wartości danej kolumny powinna równać się 100%). Wartości w poszczególnych wierszach nie muszą się sumować do 100%, gdyż dane wydzielenie może być przeszacowane lub niedoszacowane względem wzorca. W praktyce, macierz błędów pozwala na ilościową identyfikację, które klasy zostały błędnie zaklasyfikowane i w jakim stopniu na rzecz jakiego wydzielenia. Ponadto macierz błędów wyrażona w procentach pozwala na szybką analizę uzyskanych dokładności klasyfikacji, jednakże z analitycznego punktu widzenia bogatszego materiału dostarcza macierz błędów zawierająca bezwzględną liczbę pikseli (umożliwia to oszacowanie wielkości statystycznej próbki).

²¹ W stosunku do oryginalnych obrazów poklasyfikacyjnych wyeliminowano poligony, których powierzchnia była mniejsza niż 30 m². Ponadto prezentowane mapy zostały po klasyfikacji zgeometryzowane (UTM 34, WGS84), zwektoryzowane i nałożono na nie siatkę kilometrową.

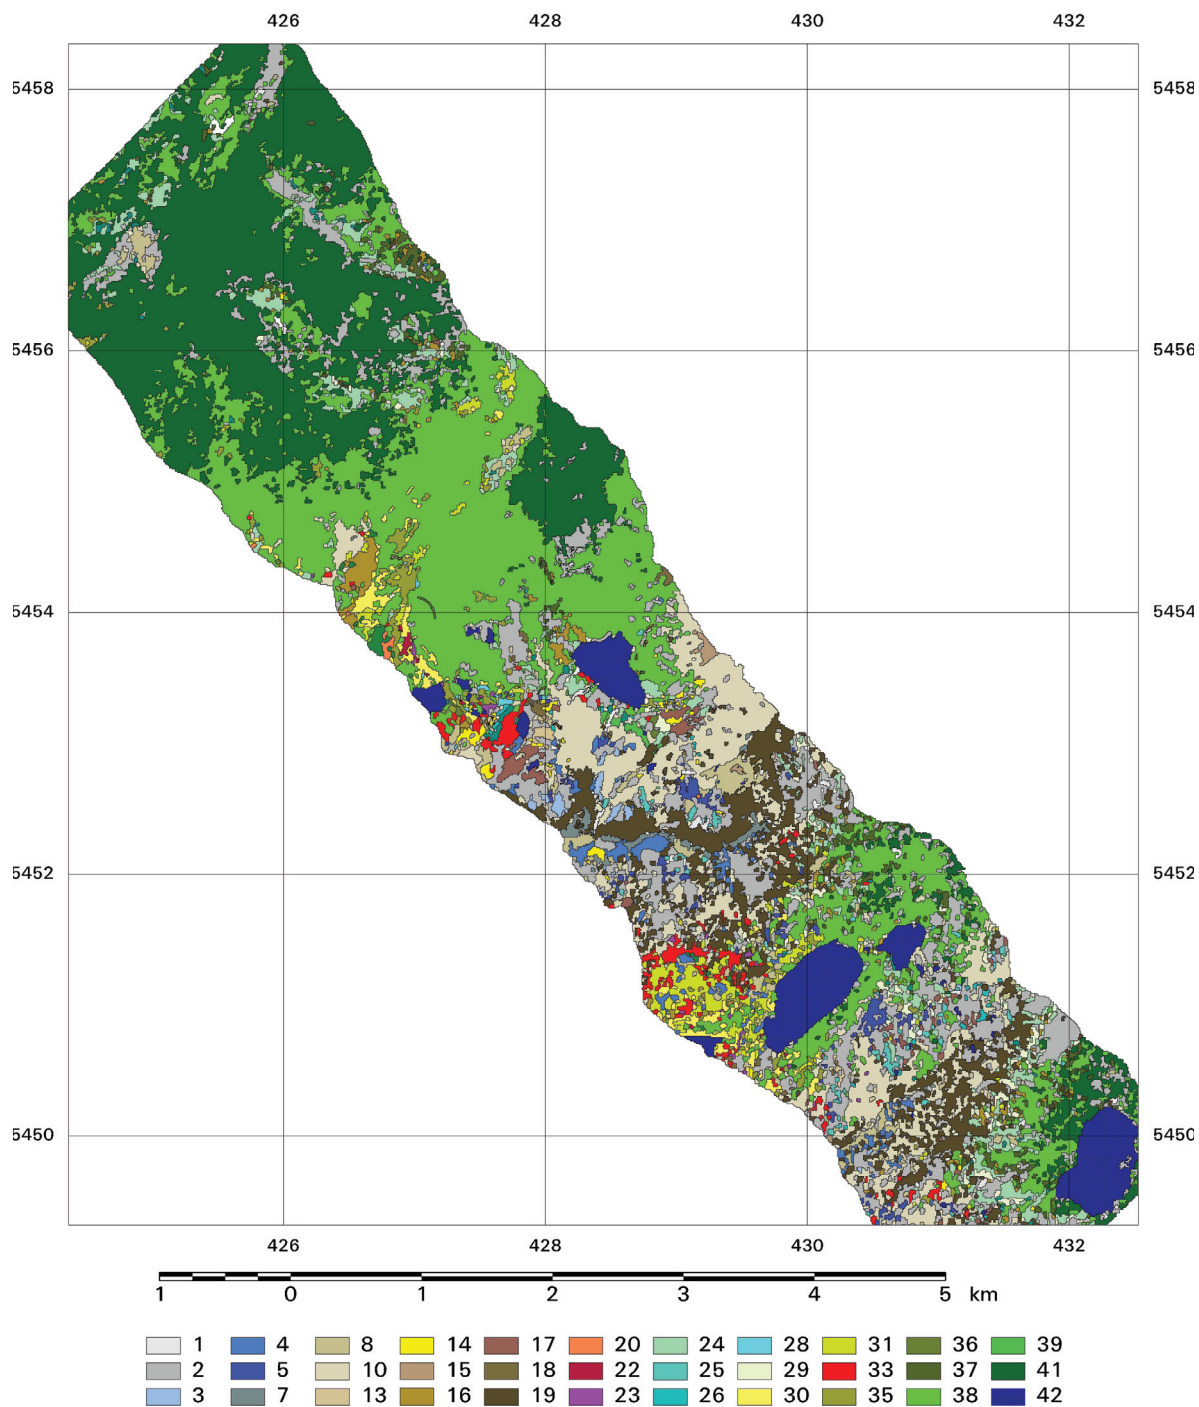


Ryc. 28. Wynik klasyfikacji 40 oryginalnych kanałów 6 linii zobraowania DAIS 7915 (po 5000 iteracji). Macierz błędów zob. tabele 5 i 6. Sklasyfikowane jednostki: 1 pionierskie zbiorowiska roślin zarodnikowych; 2 zbiorowiska porostów naskalnych; 3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; 4 wilgotne traworośla kosmatkowe; 5 wyleżyńska w piętrze alpejskim; 7 murawa subniwalna; 8 murawa alpejska typowa; 10 fragmenty muraw alpejskich na półkach skalnych; 13 murawa alpejska z wierzbą Kitaibela; 14 murawa alpejska postać piargowa z siem skucina; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyškami; 18 murawa alpejska w kompleksie z traworoślami; 19 kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach; 20 murawa alpejska na podłożu węglanowym; 22 wilgotne psiały; 23 wilgotne psiały w kompleksie z ziołoroślami; 24 traworośle trzcinnikowe; 25 traworośle trzcinnikowe postać pionierska; 26 traworośle trzcinnikowe w kompleksie z wilgotnymi murawami; 28 ziołorośla; 29 wilgotne murawy w kompleksie z wyleżyškami i ziołoroślami; 30 murawy powypasowe świeże i suche; 31 murawy powypasowe wilgotne; 33 wysokogórskie borowczyńska bażynowe; 35 zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 39 kępy kosodrzewiny na ścianach skalnych; 41 bór górnoeglowy; 42 woda

Fig. 28. Results of the forty-band DAIS 7915 set classification of the flight line No. 6 (after 5000 iterations). Error matrices see tables 5 and 6. Classified units: 1 cryptogamic plant communities on scree – initial phase; 2 epilittic lichen communities – Rhizocarpetalia; 3 scree communities – Androsacetalia alpinae; 4 Luzuletum alpinum-pilosae; 5 Salicetum herbaceae, Luzuletum spadiceae; 7 subnivale swards – Oreochloa distichae-Juncetum trifidi subnivale form; 8 Oreochloa distichae-Juncetum trifidi typicum; 10 Oreochloa distichae-Juncetum trifidi – vegetation fragments on rocky shelves; 13 Oreochloa distichae-Juncetum trifidi salicetosum kitaibelianae; 14 Oreochloa distichae-Juncetum trifidi scree form with Juncus trifidus; 15 Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis; 16 Oreochloa distichae-Juncetum trifidi subalpine anthropogenic form; 17 Oreochloa distichae-Juncetum trifidi in a complex with snow-bed communities; 18 Oreochloa distichae-Juncetum trifidi in a complex with Calamagrostietum villosae; 19 Oreochloa distichae-Juncetum trifidi in a complex with Festuco versicoloris-Agrostietum; 20 Festuco versicoloris-Agrostietum; 22 Sphagno-Nardetum, Polytricho-Nardetum; 23 Sphagno-Nardetum, Polytricho-Nardetum in a complex with Calthia laeta community; 24 Calamagrostietum villosae tatricum; 25 Calamagrostietum in a complex with Luzuletum alpinum-pilosae pioneer form; 26 Calamagrostietum in a complex with wet subalpine meadows; 28 tall herb communities – Adenostylium; 29 Festuca picta community in a complex with Luzuletum alpinum-pilosae; 30 Festuca picta community; 31 Deschampsia flexuosa community, Hieracio alpini-Nardetum; 33 Empetro-Vaccinietum; 35 Vaccinium myrtillus community in a complex with Pinetum mugho carpaticum silvicolium; 36 Vaccinium myrtillus community in a complex with tall herb communities; 37 willow thicket – Chamaenerion angustifolium-Salix silesiaca community; 38 mountain-pine scrub on siltak substrate – Pinetum mugho carpaticum silvicolium; 39 mountain-pine scrub – Pinetum mugho carpaticum silvicolium in a complex with epilittic lichen communities; 41 montane spruce forest – Plagiothecio-Piceetum; 42 water

Tabela 6. Macierz błędów (liczba pikseli) klasyfikacji 40 kanałów 6 linii zobrazowania DAIS 7915 Tatr
 Table 6. Error matrix (number of pixels) of forty-band DAIS 7915 set classification of the flight line No. 6

#1	#2	#3	#4	#5	#7	#8	#10	#13	#14	#15	#16	#17	#18	#19	#20	#22	#23	#24	#25	#26	#28	#29	#30	#31	#33	#35	#36	#37	#38	#39	#41	#42	Razem Total	
#1	2393	251	11	0	0	8	16	238	0	0	0	2	1	0	132	0	0	29	27	0	0	1	0	0	0	0	0	0	0	64	4	0	11	3188
#2	45	27817	6	25	52	43	362	3975	54	155	13	76	254	48	536	0	0	136	15	8	0	1	0	6	2	6	24	17	2043	72	1402	246	37439	
#3	7	384	1893	0	1	0	0	1083	0	0	0	0	4	0	68	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	3448	
#4	13	169	4	3253	1	49	112	1064	14	0	0	0	18	9	60	0	0	0	0	0	0	0	0	0	10	0	0	0	5	0	0	0	4781	
#5	0	528	1	0	2009	0	34	175	0	0	0	0	0	28	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2786	
#7	75	61	5	30	0	2116	75	348	0	0	0	0	0	501	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3211	
#8	7	568	0	12	22	12	8098	1651	12	0	53	24	0	255	0	0	0	83	0	0	0	0	0	0	17	0	0	0	17	0	0	3	10834	
#10	53	928	49	6	4	3	74	47453	21	73	5	109	122	0	1726	9	0	8	1	37	0	0	0	0	0	0	0	0	394	90	0	72	51237	
#13	0	183	0	2	0	0	6	343	1593	42	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	2	0	0	0	2181		
#14	4	295	0	8	0	0	13	297	28	1833	25	0	272	5	0	0	0	29	0	0	0	0	0	0	0	0	0	54	0	0	3	2866		
#15	0	18	0	0	0	0	0	54	67	1	0	796	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19	2	0	0	957		
#16	6	36	0	0	0	0	0	0	0	0	0	6459	0	0	0	0	39	0	0	0	0	0	0	3	0	0	0	36	259	0	0	6845		
#17	0	241	0	0	0	22	0	574	0	17	0	23	4371	0	19	0	0	4	0	0	0	1	0	0	8	0	0	0	0	0	0	17	5297	
#18	0	311	0	0	0	0	0	14	6	14	0	3	1027	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	0	0	1396		
#19	63	518	1	0	0	79	170	4762	0	0	0	115	0	18892	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24603		
#20	0	0	0	2	12	0	0	0	0	0	0	0	0	0	311	0	0	0	0	0	0	0	0	19	20	0	0	0	0	0	0	365		
#22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	798	3	0	0	0	0	0	108	1	0	0	0	79	0	0	0	989		
#23	0	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16	557	0	0	6	0	20	0	0	5	0	78	0	0	11	712		
#24	3	419	0	0	0	0	9	237	0	14	0	352	58	19	34	0	0	4628	0	0	0	15	0	1	1	100	0	2	366	16	0	34	6308	
#25	16	142	1	0	0	0	2	472	0	2	0	0	0	21	0	0	0	1389	0	0	0	0	0	0	0	0	0	1	0	0	0	2046		
#26	0	73	0	0	0	0	0	194	2	14	0	0	0	0	0	0	0	0	0	609	0	0	0	0	5	0	0	5	0	0	0	902		
#28	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	10	598	0	4	0	0	35	9	0	92	0	0	752		
#29	1	84	0	0	0	0	0	22	0	0	0	46	79	0	7	0	0	80	0	0	0	1001	0	0	0	8	0	22	0	0	4	1354		
#30	0	3	0	0	0	0	0	0	0	5	0	375	0	0	0	80	16	0	0	0	60	0	2405	58	0	128	16	0	1017	0	0	4191		
#31	0	0	0	0	0	0	0	11	0	0	0	267	0	0	0	3	2	11	0	0	11	0	2	1616	0	131	0	221	0	0	0	2275		
#33	0	241	0	0	0	1	0	246	4	6	0	46	19	57	3	0	3	40	0	6	0	2	0	2318	18	0	0	8	0	0	35	3053		
#35	0	211	0	0	0	0	0	58	1	4	0	41	0	0	0	7	9	231	0	19	3	155	119	0	4620	8	0	908	0	0	20	6414		
#36	0	111	0	0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	32	747	0	106	0	0	0	1014		
#37	0	6	0	0	0	0	0	0	0	0	0	38	0	0	0	0	0	71	0	0	0	0	0	0	0	0	1083	444	0	0	1642			
#38	35	1236	0	2	0	0	11	938	1	51	14	595	52	3	0	1	28	2	234	0	15	13	0	270	90	6	347	168	32	155359	5820	98	165421	
#39	0	0	0	0	0	0	0	414	0	0	0	0	0	9	6	0	0	8	0	0	0	0	0	0	0	0	0	6	1172	0	0	1615		
#41	0	509	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20	0	443	0	31437	0	32409		
#42	5	89	0	0	0	0	0	156	0	0	0	25	0	0	0	0	0	6	0	0	0	0	10	0	23	1	0	87	19	0	22106	22527		
Razem Total	2726	35453	1971	3340	2101	2333	9058	64786	1737	2230	906	8478	5368	1196	22274	327	932	594	5640	1450	679	713	1024	2976	1891	2412	5451	992	1170	162120	1375	386359	22696	415058




Ryc. 29. Wyniki klasyfikacji 20 kanałów MNF 6 linii zobrazowania DAIS 7915 (po 5000 iteracji). Macierz błędów zob. tabele 7 i 8. Objaśnienia jak na ryc. 28

Fig. 29. Results of the twenty-MNF-band DAIS 7915 set classification of the flight line No. 6 (after 5000 iterations). Error matrices see tables 7 and 8. Classified units correspond with the fig. 28

Tabela 8. Macierz błędów (liczba pikseli) klasyfikacji 20 kanałów MNF 6 linii zobrazowania DAIS 7915 Tatr
 Table 8. Error matrix (number of pixels) of twenty-MNF-band DAIS 7915 set classification of the flight line No. 6

#1	#2	#3	#4	#5	#7	#8	#10	#13	#14	#15	#16	#17	#18	#19	#20	#22	#23	#24	#25	#26	#28	#29	#30	#31	#33	#35	#36	#37	#38	#39	#41	#42	Razem Total	
2406	251	11	0	0	8	16	238	0	13	0	5	1	0	132	0	0	0	29	62	0	0	5	0	0	0	0	0	0	64	4	0	11	3256	
45	27884	49	25	52	43	362	3964	151	310	51	258	392	48	540	0	0	0	146	28	8	0	7	0	44	2	6	39	74	2049	72	1402	226	38277	
7	384	1788	0	1	0	0	1078	0	0	0	0	4	0	68	0	0	0	0	15	0	0	0	0	0	0	0	0	0	0	0	0	0	3345	
13	169	13	3255	1	49	112	1068	14	0	0	0	21	9	60	6	0	0	0	0	0	0	0	0	0	10	0	0	0	5	0	0	0	4805	
0	528	1	0	2009	0	34	175	0	0	0	0	0	28	11	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2787	
75	61	10	30	0	2116	75	348	0	0	0	0	77	0	511	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3303	
7	569	0	12	22	12	8098	1681	12	0	53	24	0	0	255	0	0	0	134	0	0	0	0	0	0	17	0	0	0	17	0	0	3	10916	
53	918	75	6	4	3	74	47506	79	147	82	114	263	0	1726	37	0	0	8	7	121	9	0	0	0	0	0	0	0	394	90	0	72	51788	
0	167	0	2	0	0	6	318	1395	122	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	2	0	0	0	2022	
0	292	0	8	0	0	13	282	45	1208	25	0	323	4	0	0	0	0	29	0	0	0	0	0	0	0	0	0	0	50	0	0	3	2282	
0	14	0	0	0	0	54	64	1	0	611	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	744	
0	12	0	0	0	0	0	0	0	0	0	5459	0	0	0	0	0	0	35	0	0	0	0	0	0	0	0	0	15	245	0	0	0	5766	
0	239	0	0	0	22	0	520	0	69	0	23	3697	0	0	0	0	0	0	0	0	0	23	0	0	5	0	0	0	0	0	0	17	4615	
0	311	0	0	0	0	0	14	6	54	0	0	3	1028	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	0	0	1437	
63	514	7	0	0	79	157	4774	0	0	0	0	283	0	18863	0	0	0	3	0	0	0	15	0	0	0	0	0	0	0	0	0	0	24758	
0	0	0	0	12	0	0	0	0	0	0	0	0	0	0	202	0	0	0	0	0	0	0	0	0	19	0	0	0	0	0	0	1	234	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	690	3	0	0	0	0	0	0	0	0	0	0	0	76	0	0	0	918	
0	19	0	0	0	0	0	0	0	35	0	0	0	0	0	0	8	496	0	0	0	4	0	80	0	0	0	5	0	78	0	0	11	736	
3	419	0	0	0	0	9	220	0	18	0	407	68	19	34	0	0	0	4393	0	0	0	15	0	1	1	100	0	6	350	16	0	34	6113	
12	140	17	0	0	0	2	474	21	2	0	0	0	0	21	0	0	0	0	1328	0	0	0	0	0	0	0	0	0	1	0	0	0	2018	
0	73	0	0	0	0	0	184	2	14	0	0	0	0	0	0	0	0	0	0	489	0	0	0	0	0	0	0	0	5	0	0	0	767	
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	10	459	0	4	0	0	0	35	10	78	0	0	0	600	
1	84	0	0	0	0	22	0	0	0	0	49	63	0	0	0	0	0	91	0	0	0	940	0	0	0	6	0	0	22	0	0	3	1281	
0	3	0	0	0	0	0	0	0	5	0	831	0	0	0	16	144	6	0	0	0	60	2225	58	0	131	76	0	1006	0	0	28	4589		
0	0	0	0	0	0	0	11	0	29	0	265	0	0	0	0	55	9	11	0	0	11	0	2	1318	0	131	0	140	0	0	0	1982		
0	241	0	0	0	1	0	246	4	6	0	85	56	57	3	0	0	5	40	0	7	10	0	2	0	2329	18	0	8	0	0	35	3153		
0	211	0	0	0	0	0	58	1	0	0	69	13	0	0	58	7	51	321	0	0	97	13	194	154	0	4671	48	0	921	0	0	20	6907	
0	110	0	0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	631	0	102	0	0	0	861	
0	4	0	0	0	0	0	0	0	0	0	58	0	0	0	0	0	0	67	0	0	0	0	0	0	0	0	740	356	0	0	0	1225		
36	1137	0	2	0	0	11	938	1	170	42	708	104	3	0	1	28	22	295	0	28	49	0	308	316	6	347	168	335	155590	0	5778	98	166521	
0	0	0	0	0	0	0	414	0	17	0	0	0	0	9	6	0	0	8	0	0	0	0	0	0	0	0	0	6	1174	0	0	1634		
0	509	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20	443	0	31437	0	32409		
5	89	0	0	0	0	0	156	0	0	0	40	0	0	0	0	0	0	6	0	0	14	4	10	0	23	1	0	87	19	0	22134	22588		
Razem Total	2726	35354	1971	3340	2101	2333	9045	64747	1732	2219	864	8395	5368	1196	22233	327	932	594	5616	1450	663	713	1024	2974	1891	2412	5451	992	1170	162116	1375	38617	22696	414637

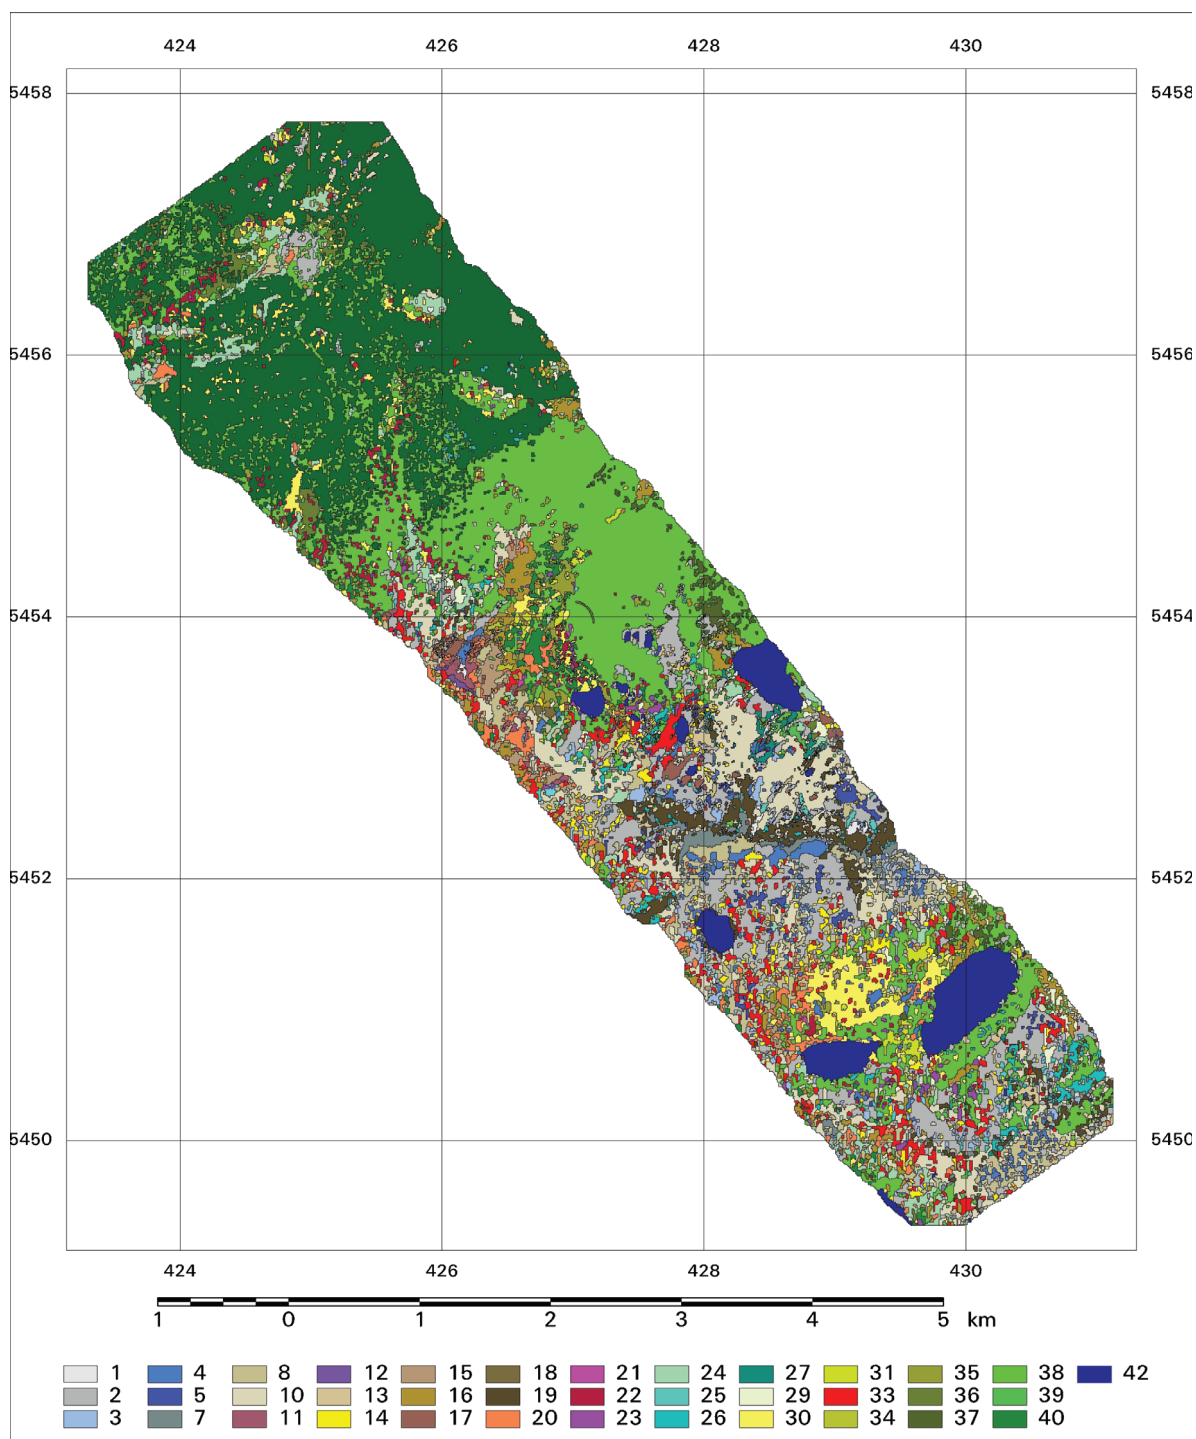


Ryc. 30. Wynik klasyfikacji 40 oryginalnych kanałów 5 linii DAIS 7915 po 5000 iteracji. Macierz błędów zob. tabele 9 i 10. Sklasyfikowane jednostki: 1 pionierskie zbiorowiska roślin zarodnikowych; 2 zbiorowiska porostów naskalnych; 3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; 4 wilgotne trawosłone kosmatkowe; 5 wyleżyńska w piętrze alpejskim; 7 murawa subniwalna; 8 murawa alpejska typowa; 10 fragmenty muraw alpejskich na półkach skalnych; 11 murawa alpejska torfowcowa; 12 murawa alpejska wyleżyškowa; 13 murawa alpejska z wierzbą *Kitaibela*; 14 murawa alpejska postać piargowa z sitem skuciana; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyškami; 18 murawa alpejska w kompleksie z trawosłami; 19 kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach; 20 murawa alpejska na podłożu węglanowym; 21 torfowisko przejściowe; 22 wilgotne psiały; 23 wilgotne psiały w kompleksie z ziólorosłami; 24 trawosłone trzcinnikowe; 25 trawosłone trzcinnikowe postać pionierska; 26 trawosłone trzcinnikowe w kompleksie z wilgotnymi murawami; 27 trawosłone trzcinnikowe w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi; 29 wilgotne murawy w kompleksie z wyleżyškami i ziólorosłami; 30 murawy powypasowe świeże i suche; 31 murawy powypasowe wilgotne; 33 wysokogórskie borowczyńska bażynowe; 34 wysokogórskie borowczyńska bażynowe w kompleksie z zaroślami kosodrzewiny; 35 zbiorowiska borówki czarnej w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czarnej w kompleksie z trawosłami i ziólorosłami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 39 kępy kosodrzewiny na ścianach skalnych; 40 zarośla kosodrzewiny na podłożu węglanowym; 42 woda

Fig. 30. Results of the forty-band DAIS 7915 set classification of the flight line No. 5 (after 5000 iterations). Error matrices see tables 9 and 10. Classified units: 1 cryptogamic plant communities on scree – initial phase; 2 epilithic lichen communities – *Rhizocarpetalia*; 3 scree communities – *Androsacetalia alpinae*; 4 *Luzuletum alpino-pilosae*; 5 *Salicetum herbaceae*, *Luzuletum spadiceae*; 7 subnivale swards – *Oreochloa distichae-Juncetum trifidi subnivale* form; 8 *Oreochloa distichae-Juncetum trifidi typicum*; 10 *Oreochloa distichae-Juncetum trifidi* – vegetation fragments on rocky shelves; 11 *Oreochloa distichae-Juncetum trifidi sphagnetosum*; 12 *Oreochloa distichae-Juncetum trifidi salicetosum herbaceae*; 13 *Oreochloa distichae-Juncetum trifidi salicetosum kitaibeliana*; 14 *Oreochloa distichae-Juncetum trifidi scree* form with *Juncus trifidus*; 15 *Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis*; 16 *Oreochloa distichae-Juncetum trifidi subalpine anthropogenic* form; 17 *Oreochloa distichae-Juncetum trifidi* in a complex with snow-bed communities; 18 *Oreochloa distichae-Juncetum trifidi* in a complex with *Calamagrostietum villosae*; 19 *Oreochloa distichae-Juncetum trifidi* in a complex with *Festuco versicoloris-Agrostietum*; 20 *Festuco versicoloris-Agrostietum*; 21 *Caricetum fuscac subalpinum*; 22 *Sphagno-Nardetum*, *Polytricho-Nardetum*; 23 *Sphagno-Nardetum*, *Polytricho-Nardetum* in a complex with *Calluna laeta* community; 24 *Calamagrostietum villosae latricum*; 25 *Calamagrostietum* in a complex with *Luzuletum alpino-pilosae* pioneer form; 26 *Calamagrostietum* in a complex with wet subalpine meadows; 27 *Calamagrostietum* in a complex with *Pinetum mugho* and subalpine meadows; 29 *Festuca picta* community in a complex with *Luzuletum alpino-pilosae*; 30 *Festuca picta* community; 31 *Deschampsia flexuosa* community, *Hieractio alpini-Nardetum*; 33 *Empetro-Vaccinietum*; 34 *Empetro-Vaccinietum* in a complex with *Pinetum mugho*; 35 *Vaccinium myrtillus* community in a complex with *Pinetum mugho* and subalpine meadows; 36 *Vaccinium myrtillus* community in a complex with tall herb communities; 37 willow thicket – *Chaenarion angustifolium-Salix silesiaca* community; 38 mountain-pine scrub on silicatic substrate – *Pinetum mugho carpaticum silicaticum*; 39 mountain-pine scrub – *Pinetum mugho carpaticum silicaticum* in a complex with epilithic lichen communities; 40 mountain-pine scrub on calcareous substrate – *Pinetum mugho carpaticum calcicolum*; 42 water

Tabela 10. Macierz błędów (liczba pikseli) klasyfikacji 40 kanałów 5 linii zobrazowania DAIS 7915
 Table 10. Error matrix (number of pixels) of forty-band DAIS 7915 set classification of the flight line No. 5

#1	#2	#3	#4	#5	#7	#8	#10	#11	#12	#13	#14	#15	#16	#17	#18	#19	#20	#21	#22	#23	#24	#25	#26	#27	#29	#30	#31	#33	#34	#35	#36	#37	#38	#39	#40	#42	Razem Total	
2265	90	9	4	0	7	0	181	17	0	0	0	0	0	9	0	142	0	0	0	0	10	36	0	52	0	0	0	0	0	0	0	0	0	0	0	0	5	2827
31	24230	106	40	31	1	84	1474	0	22	155	39	76	433	137	264	13	0	0	0	4	466	24	0	149	19	0	0	13	0	0	11	10	1445	0	0	98	29375	
6	168	2293	8	0	0	0	465	0	0	0	0	0	0	6	0	132	0	0	0	0	0	19	0	24	0	0	0	0	13	0	0	0	0	0	0	0	0	3134
5	178	2	4268	1	41	48	317	8	0	0	0	0	0	294	12	116	10	0	0	0	10	6	0	64	17	0	0	0	0	0	0	0	0	0	0	0	1	5398
4	498	3	4	1348	0	22	171	0	0	20	56	0	0	8	69	10	5	0	0	0	3	0	0	19	0	0	0	0	0	0	0	0	102	12	0	0	2354	
28	53	0	18	0	2230	63	418	0	0	6	0	0	0	4	0	1361	0	0	0	0	0	0	3	9	0	0	0	0	0	0	0	0	0	0	0	0	4193	
2	299	0	81	0	21	4116	367	43	11	4	44	33	0	97	31	12	3	0	0	0	0	0	0	1	0	0	0	1	10	0	29	0	1	0	0	0	5206	
41	484	46	48	13	4	117	46961	2	0	0	10	20	22	300	19	680	0	0	0	2	170	51	0	237	16	0	0	4	0	0	0	0	172	69	0	24	49512	
14	0	0	0	0	0	0	46	3181	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3242	
0	0	0	0	0	0	0	0	24	200	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	224	
13	0	531	7	1	1	0	674	0	0	1542	259	5	0	31	8	155	0	0	0	13	1	7	0	0	0	0	0	0	0	0	0	0	177	0	0	1	3413	
0	216	0	23	4	0	5	216	0	0	15	2554	18	0	5	30	0	0	0	0	0	16	14	0	18	0	0	0	10	0	8	1	0	11	0	0	10	3174	
0	9	0	9	0	0	0	64	19	0	0	1015	118	226	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	0	0	0	12	0	0	0	0	1484	
4	78	0	0	0	0	0	94	0	2	0	35	102	6444	27	0	0	15	0	15	2	114	0	0	6	23	46	33	7	56	73	152	2	377	0	0	23	7730	
0	150	0	27	0	2	0	219	0	0	0	4	0	16	4667	0	18	0	2	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	2	0	5109	
0	21	0	0	0	0	0	2	0	0	0	0	0	0	2	906	0	5	0	3	0	3	0	0	30	0	0	0	0	3	0	0	0	0	0	0	0	972	
16	314	3	3	0	21	28	957	0	0	6	1	0	9	29	0	9452	0	0	0	8	1	0	14	0	0	0	0	0	0	0	0	0	0	0	2	0	86	10950
0	3	0	1	0	0	0	98	173	8	0	0	10	25	249	0	0	1706	0	0	125	0	0	2	0	2	0	0	19	53	32	46	0	3	0	8	0	2561	
0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	25	0	0	0	371	
0	7	0	0	0	0	13	109	0	0	0	0	0	0	0	0	0	7	1137	0	52	0	0	0	0	17	124	1	0	0	39	120	0	383	0	7	0	2016	
0	0	0	0	0	0	5	50	14	0	1	0	0	66	0	0	0	12	0	13	984	20	0	0	0	0	0	123	15	12	0	134	20	0	312	3	0	3	1787
0	215	0	0	0	0	0	316	0	0	0	2	0	37	14	5	0	4	0	0	0	5309	0	2	18	61	43	3	0	1	51	125	2	44	0	0	22	6274	
18	108	1	0	0	0	0	234	0	0	0	7	0	0	80	0	55	0	0	0	0	38	952	0	0	6	0	0	5	0	0	0	0	8	0	0	0	1512	
0	35	0	0	0	0	18	832	0	0	8	15	0	0	0	2	513	0	0	0	0	0	0	0	676	25	0	0	1	0	0	0	0	70	0	0	0	2195	
7	69	0	0	14	0	0	470	0	0	0	10	3	9	0	3	13	14	0	0	13	0	3	5248	0	0	0	5	0	0	19	0	57	8	0	35	6000		
0	34	0	28	0	0	34	34	0	0	0	0	0	1	7	0	0	0	0	1	316	0	0	17	1063	2	0	0	0	0	17	17	0	4	0	0	0	1575	
0	0	0	0	0	0	0	65	0	0	0	0	0	254	0	0	0	10	0	39	34	103	0	44	0	4314	30	4	21	86	161	0	185	0	3	3	5356		
0	13	0	0	0	0	3	0	0	0	0	9	0	49	0	0	0	0	0	3	0	0	0	0	0	0	90	1303	0	0	109	0	127	0	0	0	1706		
5	366	2	4	4	2	21	752	0	0	0	31	0	0	186	32	0	32	0	0	6	68	0	0	45	1	69	7	3263	8	0	13	4	94	23	0	34	5072	
0	0	0	0	0	0	0	8	0	0	0	16	1	60	0	0	0	32	0	9	2	92	0	0	0	0	0	0	0	0	1146	0	0	0	0	0	1191		
0	46	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	16	57	64	0	0	0	4827	68	0	527	0	2	7	5834	
0	256	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	12	3	0	2	16	269	0	0	0	0	20	3597	0	107	0	0	0	4283	
0	49	0	0	0	0	0	6	0	0	0	0	0	140	2	0	0	0	0	0	15	0	0	0	0	0	8	5	0	0	0	755	1691	0	0	0	2671		
5	332	0	0	0	0	14	1967	0	0	1	39	27	557	40	13	36	10	0	25	2	139	0	0	137	10	98	109	29	0	294	465	28	112384	2	58	18	116839	
0	19	0	0	0	0	0	434	0	0	0	0	0	0	27	0	22	0	0	4	0	0	0	0	98	0	0	0	0	0	0	0	0	0	1235	0	0	1839	
0	21	0	0	0	0	0	28	0	0	0	0	0	329	0	0	0	28	0	14	3	91	0	0	0	0	357	21	0	14	240	24	0	1878	0	1821	0	4869	
1	85	0	0	0	0	0	135	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	9	0	34	0	5	0	0	0	9	0	88	0	16469	16840	
Razem Total	2452	28977	2472	4567	1416	2329	4621	58164	3481	221	1625	3248	1278	8212	6784	1267	12981	1899	328	1252	1046	7207	1107	691	6268	1265	5628	1594	3383	1339	5930	4877	801	120284	1356	1899	16839	329088

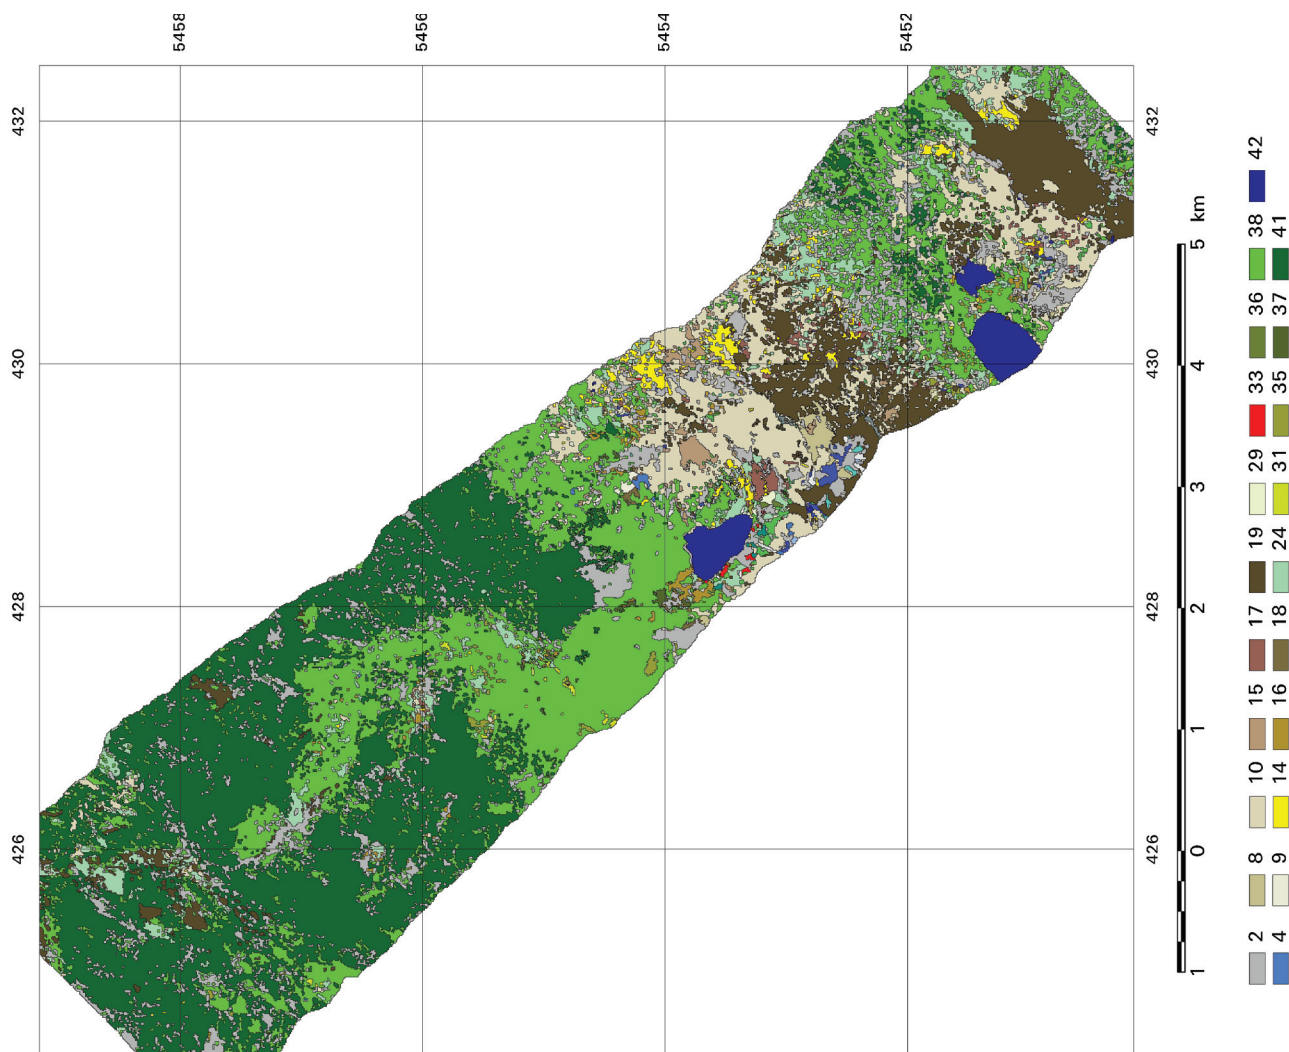


Ryc. 31. Wynik klasyfikacji 20 kanałów MNF 5 linii zobrazowania DAIS 7915 po 5000 iteracji. Macierz błędów zob. tabele 11 i 12. Objaśnienia jak na ryc. 30

Fig. 31. Results of the twenty-MNF-band DAIS 7915 set classification of the flight line No. 5 (after 5000 iterations). Error matrices see tables 11 and 12. Classified units correspond with the fig. 30

Tabela 12. Macierz błędów (liczba pikseli) klasyfikacji 20 kanałów MNF 5 linii zobrazowania DAIS 7915
 Table 12. Error matrix (number of pixels) of twenty-MNF-band DAIS 7915 set classification of the flight line No. 5

#1	#2	#3	#4	#5	#7	#8	#10	#11	#12	#13	#14	#15	#16	#17	#18	#19	#20	#21	#22	#23	#24	#25	#26	#27	#29	#30	#31	#33	#34	#35	#36	#37	#38	#39	#40	#42	Razem Total	
2265	90	9	4	0	7	0	181	17	0	0	0	0	0	9	0	142	0	0	0	0	10	36	0	52	0	0	0	0	0	0	0	0	0	0	0	0	5	2827
29	22894	106	40	24	8	84	1511	0	0	22	155	39	76	432	137	264	13	0	0	4	463	24	0	123	16	0	0	13	0	0	11	10	1445	0	0	98	28041	
6	198	2293	8	0	0	0	497	0	0	0	0	0	0	9	0	132	0	0	0	0	0	19	0	24	0	0	0	0	13	0	0	0	0	0	0	0	3199	
5	178	2	4268	1	41	48	338	8	0	0	0	0	0	294	12	116	10	0	0	0	10	6	0	64	17	0	0	0	0	0	0	0	0	0	0	1	5419	
4	644	3	4	1348	0	22	171	0	0	20	56	0	0	8	69	10	5	0	0	0	3	0	0	45	0	0	0	0	0	0	0	0	102	12	0	0	2526	
28	52	0	18	0	2202	59	418	0	0	6	0	0	0	4	0	1361	0	0	0	0	0	0	3	9	0	0	0	0	0	0	0	0	0	0	0	0	4160	
2	325	0	81	0	42	4120	458	43	11	4	44	33	0	104	31	12	3	0	0	0	0	0	0	1	0	0	1	10	0	29	0	1	0	0	0	5355		
41	558	46	48	13	4	117	45318	2	0	0	10	20	22	285	19	680	0	0	0	2	160	51	0	237	16	0	0	11	0	0	0	172	69	0	24	47925		
14	0	0	0	0	0	0	79	3181	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3275	
0	0	0	0	0	0	0	0	24	200	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	224	
0	531	7	1	1	0	0	674	0	0	1542	259	5	0	31	8	155	0	0	0	0	13	1	7	0	0	0	0	0	0	0	0	177	0	0	1	3413		
0	216	0	23	4	0	5	216	0	0	15	2554	18	0	5	30	0	0	0	0	0	16	14	0	18	0	0	10	0	8	1	0	11	0	0	10	3174		
0	10	0	9	0	0	0	67	19	0	0	1015	118	226	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	12	0	0	0	12	0	0	0	1488	
4	78	0	0	0	0	0	105	0	2	0	35	102	6444	27	0	0	16	0	15	2	114	0	6	23	46	33	7	56	73	162	2	494	0	0	23	7869		
0	323	0	27	0	2	0	222	0	0	4	0	16	4673	0	18	0	2	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	5291	
0	21	0	0	0	0	0	2	0	0	0	0	0	0	2	906	0	0	5	0	3	0	0	0	30	0	0	0	0	3	0	0	0	0	0	0	0	972	
16	314	3	3	0	21	28	1077	0	0	6	1	0	9	29	0	9452	0	0	0	0	8	1	0	14	0	0	0	0	0	0	0	0	2	0	86	11070		
0	3	0	1	0	0	0	104	173	8	0	10	25	249	0	0	1579	0	0	0	0	125	0	0	0	0	0	0	0	53	36	99	0	3	0	8	2476		
0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	25	0	0	0	0	371	
7	0	0	0	0	0	13	109	0	0	0	0	0	0	0	0	7	1099	0	52	0	0	0	0	17	119	1	0	0	39	120	0	383	0	7	0	1973		
0	0	0	0	0	0	5	50	14	0	1	0	0	66	0	0	0	12	0	15	984	20	0	0	0	123	15	12	0	134	38	0	312	3	0	3	1807		
0	347	0	0	0	0	0	421	0	0	2	0	37	14	5	0	4	0	0	0	5321	0	2	18	61	43	3	0	1	51	125	2	44	0	0	22	6523		
18	226	1	0	0	0	0	242	0	0	7	0	0	80	0	55	0	0	0	0	0	38	952	0	0	6	0	0	0	0	0	0	0	8	0	0	0	1638	
0	35	0	0	0	0	18	1097	0	0	8	15	0	0	2	513	0	0	0	0	0	0	0	676	25	0	0	1	0	0	0	0	70	0	0	0	2460		
7	69	0	0	14	0	0	470	0	0	10	3	9	0	3	13	33	0	0	0	13	0	3	5250	0	0	17	119	1	0	0	19	0	57	8	0	35	6031	
0	59	0	28	0	0	0	34	68	0	0	0	0	1	7	0	0	0	0	0	1	317	0	0	17	1066	2	0	0	17	17	0	4	0	0	0	1638		
0	0	0	0	0	0	0	65	0	0	0	0	254	0	0	0	10	0	73	34	103	0	0	44	0	4319	30	4	21	86	224	0	185	0	3	3	5458		
0	13	0	0	0	0	3	0	0	0	9	0	49	0	0	0	0	0	0	0	3	0	0	0	0	90	1303	0	0	109	0	0	127	0	0	0	1706		
5	684	2	4	4	2	21	783	0	0	31	0	0	186	32	0	75	0	0	0	6	68	0	0	45	1	69	7	3237	8	0	13	4	94	23	0	34	5438	
0	0	0	0	0	0	0	0	0	0	0	0	5	0	40	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1146	0	0	0	0	0	0	1191		
0	46	0	0	0	0	8	0	0	8	0	16	1	60	0	0	96	0	11	2	92	0	0	16	57	64	0	0	0	4830	77	0	527	0	2	7	5912		
2	531	0	0	7	0	0	24	0	0	1	0	0	0	0	0	0	0	0	0	12	3	0	2	16	269	0	0	13	3220	0	0	0	0	0	0	4100		
0	49	0	0	0	0	0	6	0	0	0	0	140	2	0	0	0	0	0	0	0	15	0	0	0	8	5	0	0	0	0	762	3088	0	0	0	4075		
5	345	0	0	0	0	14	2739	0	0	1	39	27	557	40	13	36	10	0	25	2	139	0	137	10	98	109	57	0	294	689	21	110977	2	58	18	116462		
0	19	0	0	0	0	0	434	0	0	0	0	0	0	27	0	22	0	0	0	4	0	0	98	0	0	0	0	0	0	0	0	0	1235	0	0	1839		
0	21	0	0	0	0	0	52	0	0	0	0	0	329	0	0	28	0	14	3	91	0	0	0	0	357	21	0	14	240	24	0	1878	0	1821	0	4893		
1	91	0	0	0	0	0	135	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	9	0	34	0	5	0	0	9	0	88	0	0	16469	16846		
Razem Total	2452	28977	2472	4567	1416	2329	4621	58141	3481	221	1625	3248	1278	8212	6784	1267	12981	1899	328	1252	1046	7207	1107	691	6268	1265	5628	1594	3383	1339	5930	4877	801	120284	1356	1899	16839	329065



Ryc. 32. Wynik klasyfikacji 40 oryginalnych kanałów 4 linii DAIS 7915 po 5000 iteracji. Macierz błędów zob. tabele 13 i 14. Sklasyfikowane jednostki: 2 zbiorowiska porostów naskalnych; 4 wilgotne traworośla kosmatkowe; 8 murawa alpejska typowa; 9 murawa alpejska porostowa; 10 fragmenty muraw alpejskich na półkach skalnych; 14 murawa alpejska postać piargowa z sitem skucina; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyskami; 18 murawa alpejska w kompleksie z traworoślami; 19 kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach; 24 traworośle trzcinnikowe; 29 wilgotne murawy w kompleksie z wyleżyskami i ziołoroślami; 31 murawy wypasowe wilgotne; 33 wysokogórskie borówczyska bażynowe; 35 zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 41 bór górnoreglowy; 42 woda

Fig. 32. Results of the forty-band DAIS 7915 set classification of the flight line No. 4 (after 5000 iterations). Error matrices see tables 13 and 14. Classified units: 2 epilittic lichen communities – *Rhizocarpetalia*; 4 *Luzuletum alpinopilosae*; 8 *Oreochloa distichae-Juncetum trifidi typicum*; 9 *Oreochloa distichae-Juncetum trifidi cetrarietosum*; 10 *Oreochloa distichae-Juncetum trifidi* – vegetation fragments on rocky shelves; 14 *Oreochloa distichae-Juncetum trifidi scree form with Juncus trifidus*; 15 *Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis*; 16 *Oreochloa distichae-Juncetum trifidi subalpine anthropogenic form*; 17 *Oreochloa distichae-Juncetum trifidi* in a complex with snow-bed communities; 18 *Oreochloa distichae-Juncetum trifidi* in a complex with *Calamagrostietum villosae*; 19 *Oreochloa distichae-Juncetum trifidi* in a complex with *Festuca piceticoloris-Agrostietum*; 24 *Calamagrostietum villosae tatricum*; 29 *Festuca picta* community in a complex with *Luzuletum alpinopilosae*; 31 *Deschampsia flexuosa* community, *Hieracio alpini-Nardetum*; 33 *Empetro-Vaccinietum*; 35 *Vaccinium myrtillus* community in a complex with *Pinetum mugho carpaticum silicicolum*; 36 *Vaccinium myrtillus* community in a complex with tall herb communities; 37 willow thicket – *Chamaenerion angustifolium-Salix silesiaca* community; 38 mountain-pine scrub on silicate substrate – *Pinetum mugho carpaticum silicicolum*; 41 montane spruce forest – *Plagiothecio-Piceetum*; 42 water

Tabela 14. Macierz błędów (liczba pikseli) klasyfikacji zbiorowisk roślinnych 40 kanałów 4 linii zobrazowania DAIS 7915
 Table 14. Error matrix (number of pixels) of forty-band DAIS 7915 set classification of the flight line No. 4

	#2	#4	#8	#9	#10	#14	#15	#16	#17	#18	#19	#24	#29	#31	#33	#35	#36	#37	#38	#41	#42	Razem Total
#2	12853	0	84	0	526	10	0	101	57	0	11	38	1	0	0	0	9	31	2248	2699	55	18723
#4	0	227	6	0	36	0	0	0	0	0	0	0	0	0	0	0	0	0	52	0	0	321
#8	21	0	6356	0	272	0	22	0	0	0	166	0	0	0	0	0	0	0	0	0	0	6837
#9	0	0	0	463	70	0	2	0	0	12	0	0	0	0	0	0	0	0	119	29	0	695
#10	423	6	62	0	25294	10	12	50	2	1	842	0	15	0	0	0	5	0	1482	1	115	28320
#14	430	0	0	0	72	475	3	3	41	0	0	25	1	0	0	0	0	6	417	0	0	1473
#15	51	0	105	0	689	1	2018	1	0	0	19	0	0	0	0	0	0	0	291	0	0	3175
#16	106	0	0	0	0	0	0	3275	0	0	0	49	11	16	1	0	0	68	675	0	17	4218
#17	106	0	0	0	130	5	0	0	2712	0	0	34	1	0	0	0	0	0	7	0	0	2995
#18	17	2	0	3	1	0	0	0	0	724	0	0	0	0	0	0	0	0	96	19	0	862
#19	42	0	149	0	1094	0	0	0	0	0	9755	0	0	0	0	0	0	0	0	0	0	11040
#24	68	0	0	0	535	0	0	45	6	0	0	3659	4	0	0	1	0	15	860	0	31	5224
#29	3	0	0	0	27	0	0	0	26	0	27	16	900	0	0	2	0	0	0	0	1	1002
#31	0	0	0	0	0	0	0	21	0	0	0	33	0	443	0	0	0	0	253	0	0	750
#33	19	0	0	0	0	0	0	1	0	0	0	0	0	0	81	0	0	3	21	0	3	128
#35	0	0	0	0	0	0	0	9	6	0	0	34	16	0	0	205	0	16	120	0	0	406
#36	22	0	0	0	26	0	0	0	0	0	3	0	3	0	0	0	288	0	35	0	0	377
#37	9	0	0	0	0	0	0	26	0	0	0	0	0	0	0	0	0	874	795	0	7	1711
#38	746	2	0	5	466	2	4	84	4	22	0	124	17	94	0	1	4	157	96433	6502	17	104684
#41	315	0	0	0	12	0	0	0	0	0	0	0	0	0	0	0	115	0	1170	39106	0	40718
#42	45	0	0	0	0	0	0	0	0	0	0	10	2	0	0	0	0	0	22	0	18800	18879
Razem Total	15276	237	6762	471	29250	503	2061	3616	2854	759	10823	4022	971	553	82	209	421	1170	105096	48356	19046	252538

Ryc. 33. Wynik klasyfikacji 40 oryginalnych kanałów 2 linii zobrazowania DAIS 7915 po 5000 iteracji. Macierz błędów zob. tabele 15 i 16. Sklasyfikowane jednostki: 1 pionierskie zbiorowiska roślin zarodnikowych; 2 zbiorowiska porostów naskalnych; 3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; 4 wilgotne traworośla kosmatkowe; 5 wyleżyńska w piętrze alpejskim; 7 murawa subniwalna; 8 murawa alpejska typowa; 10 fragmenty muraw alpejskich na półkach skalnych; 13 murawa alpejska z wierzbą Kitaibela; 14 murawa alpejska postać piargowa z sitem skucią; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyskami; 18 murawa alpejska w kompleksie z traworoślami; 19 kompleks przetrzenny muraw alpejskich na podłożu granitowym i mylonitach; 20 murawa alpejska na podłożu węglanowym; 21 torfowisko przejściowe; 22 wilgotne psiary; 23 wilgotne psiary w kompleksie z ziołoroślami; 24 traworoście trzcinikowe; 25 traworoście trzcinikowe postać pionierska; 26 traworoście trzcinikowe w kompleksie z wilgotnymi murawami; 27 traworoście trzcinikowe w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi; 28 ziołorośla; 29 wilgotne murawy w kompleksie z wyleżyskami i ziołoroślami; 30 murawy powypasowe świeże i suche; 31 murawy powypasowe wilgotne; 33 wysokogórskie borowczyńska bażynowe; 35 zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 39 kępy kosodrzewiny na ścianach skalnych; 40 zarośla kosodrzewiny na podłożu węglanowym; 41 bór górnoregłowy; 42 woda

Fig. 33. Results of the forty-band DAIS 7915 set classification of the flight line No. 2 (after 5000 iterations). Error matrices see tables 15 and 16. Classified units: 1 cryptogamic plant communities on scree – initial phase; 2 epilittic lichen communities – *Rhizocarpetalia*; 3 scree communities – *Androsacetalia alpinae*; 4 *Luzuletum alpino-pilosae*; 5 *Salicetum herbaceae*, *Luzuletum spadiceae*; 7 subnivale swards – *Oreochloa distichae-Juncetum trifidi* subnivale form; 8 *Oreochloa distichae-Juncetum trifidi* typicum; 10 *Oreochloa distichae-Juncetum trifidi* – vegetation fragments on rocky shelves; 13 *Oreochloa distichae-Juncetum trifidi salicetosum kitaibeliana*; 14 *Oreochloa distichae-Juncetum trifidi* scree form with *Juncus trifidus*; 15 *Oreochloa distichae-Juncetum trifidi carictosum semperivirens*; 16 *Oreochloa distichae-Juncetum trifidi* subalpine anthropogenic form; 17 *Oreochloa distichae-Juncetum trifidi* in a complex with snow-bed communities; 18 *Oreochloa distichae-Juncetum trifidi* in a complex with *Calamagrostietum villosae*; 19 *Oreochloa distichae-Juncetum trifidi* in a complex with *Festuca versicoloris-Agrostietum*; 20 *Festuca versicoloris-Agrostietum*; 21 *Caricetum fuscae subalpinum*; 22 *Sphagno-Nardetum*, *Polytricho-Nardetum*; 23 *Sphagno-Nardetum*, *Polytricho-Nardetum* in a complex with *Caltha laeta* community; 24 *Calamagrostietum villosae tatricum*; 25 *Calamagrostietum* in a complex with *Luzuletum alpino-pilosae* pioneer form; 26 *Calamagrostietum* in a complex with wet subalpine meadows; 27 *Calamagrostietum* in a complex with *Pinetum mugho* and subalpine meadows; 28 tall herb communities – *Adenostylion*; 29 *Festuca picta* community in a complex with *Luzuletum alpino-pilosae*; 30 *Festuca picta* community; 31 *Deschampsia flexuosa* community, *Hieracio alpini-Nardetum*; 33 *Empetro-Vaccinietum*; 35 *Vaccinium myrtillus* community in a complex with *Pinetum mugho carpaticum silicicolum*; 36 *Vaccinium myrtillus* community in a complex with tall herb communities; 37 willow thicket – *Chamaenorton angustifolium*-*Salix silesiaca* community; 38 mountain-pine scrub on silicate substrate – *Pinetum mugho carpaticum silicicolum*; 39 mountain-pine scrub – *Pinetum mugho carpaticum silicicolum* in a complex with epilittic lichen communities; 40 mountain-pine scrub on calcareous substrate – *Pinetum mugho carpaticum calcicolum*; 41 montane spruce forest – *Plagiothecio-Piceetum*; 42 water

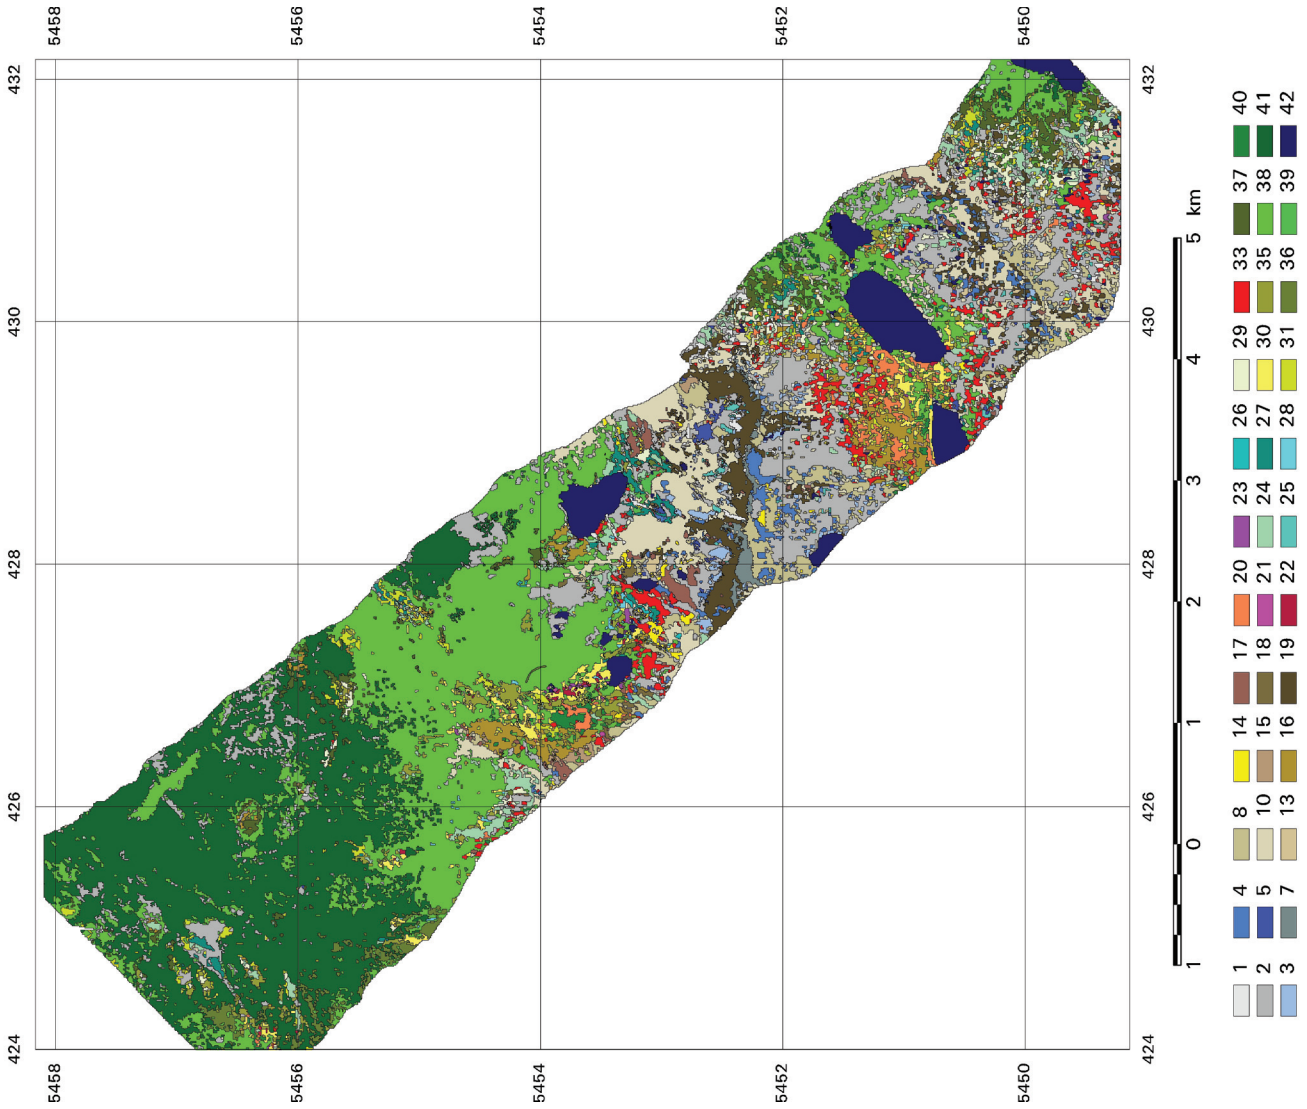
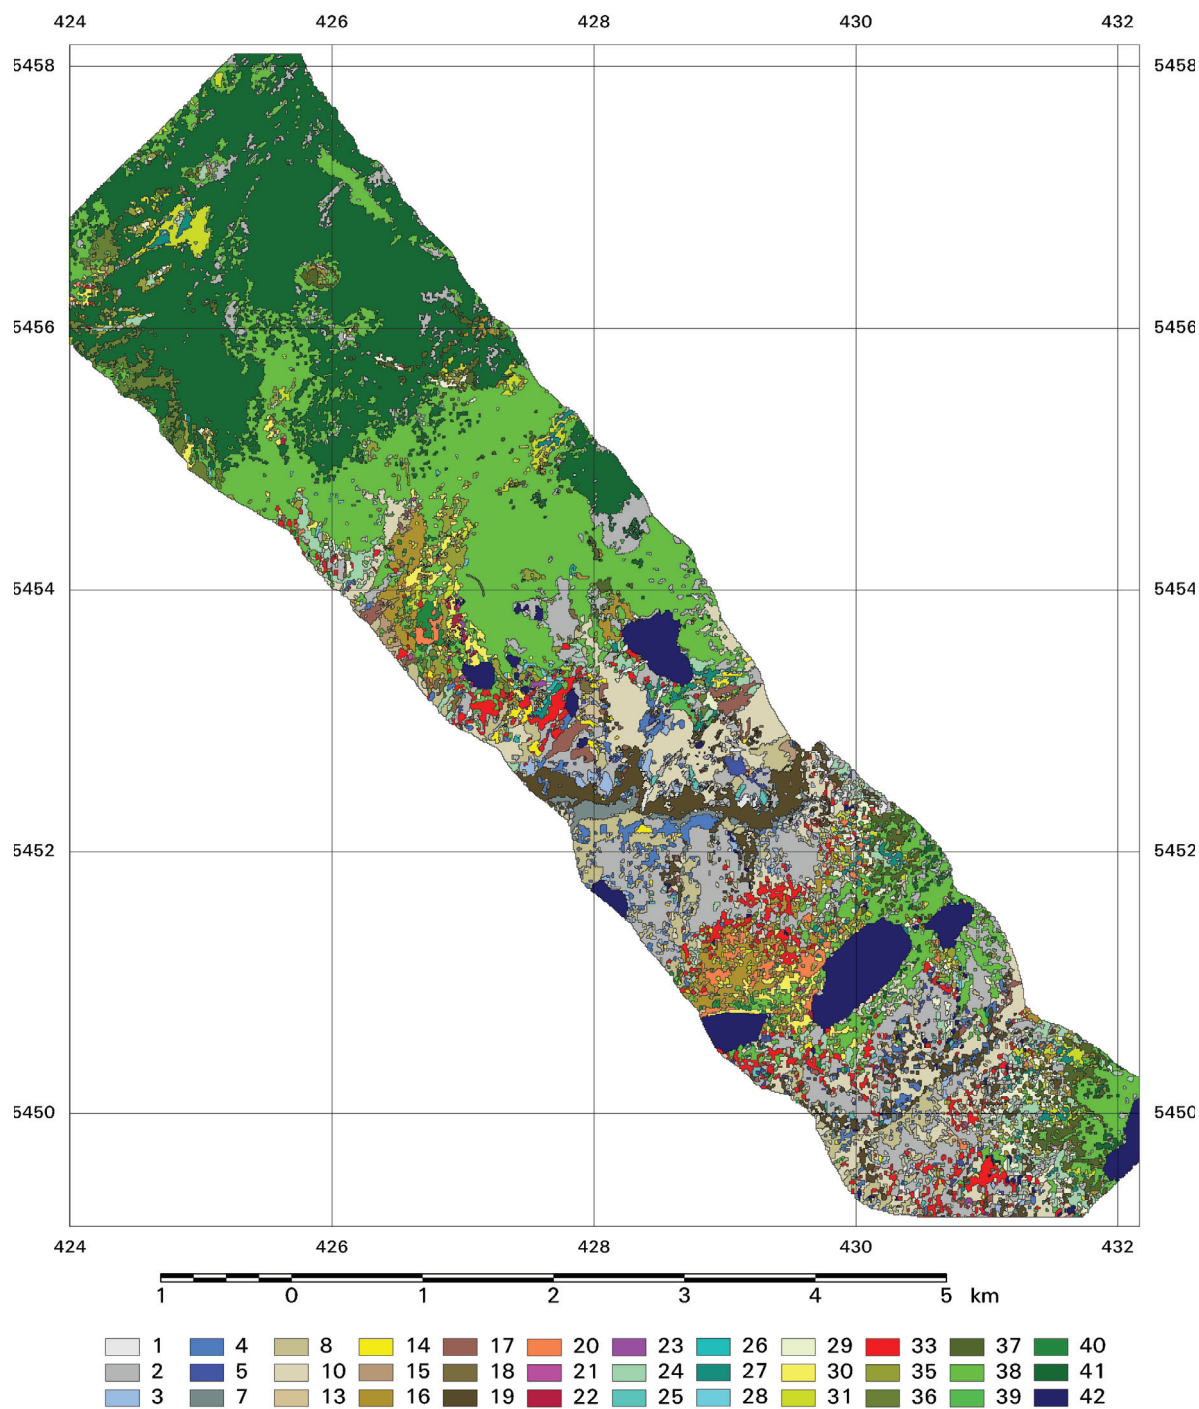


Tabela 16. Macierz błędów (liczba pikseli) klasyfikacji 40 kanałów 2 linii zobrazowania DAIS 7915
 Table 16. Error matrix (number of pixels) of forty-band DAIS 7915 set classification of the flight line No. 2

#1	#2	#3	#4	#5	#7	#8	#10	#13	#14	#15	#16	#17	#18	#19	#20	#21	#22	#23	#24	#25	#26	#27	#28	#29	#30	#31	#33	#35	#36	#37	#38	#39	#40	#41	#42	Razem Total	
#1	2123	219	9	4	7	9	0	348	12	29	0	0	0	0	138	0	0	0	10	5	0	129	0	0	0	0	0	1	0	0	0	5	0	0	0	12	3060
#2	44	28551	39	28	156	32	178	1481	53	172	9	138	77	63	164	4	0	0	171	44	0	511	5	116	0	0	39	0	39	0	78	5	1664	0	716	271	31809
#3	23	634	2646	16	0	10	0	475	0	0	0	0	0	0	115	0	0	0	13	0	32	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3964
#4	11	296	5	3592	0	62	113	417	0	0	0	0	0	9	86	18	0	0	0	4	0	65	0	0	0	0	1	0	0	0	19	0	0	0	0	4698	
#5	9	383	0	0	1994	0	48	112	0	39	0	0	0	16	0	0	0	0	15	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	11	2677	
#7	50	38	0	31	0	2458	57	115	0	0	0	3	0	498	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	3255	
#8	14	486	7	82	30	46	7054	784	0	32	0	9	16	0	58	0	0	0	1	8	7	0	0	0	0	33	0	0	0	44	0	0	0	0	8711		
#10	12	642	9	24	3	23	53	45528	23	38	0	15	114	0	534	2	0	0	22	2	34	165	0	0	0	34	0	0	0	477	25	4	0	40	47823		
#13	0	145	0	3	0	0	4	111	1624	68	0	0	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	24	0	0	0	0	1986	
#14	1	219	0	12	0	0	1	322	60	2995	0	0	101	0	10	2	0	0	0	6	0	63	8	0	0	0	1	2	3	0	76	0	0	5	3887		
#15	0	10	0	0	0	0	1	12	0	0	311	25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	22	0	0	0	0	381	
#16	9	34	0	0	0	0	2	51	0	0	25	7739	0	0	25	0	2	10	77	0	0	0	0	0	10	9	36	5	11	0	33	349	0	11	0	8452	
#17	0	622	0	0	2	0	0	1090	7	25	6	27	5273	0	61	0	0	0	28	0	0	137	0	22	0	0	0	0	0	0	0	6	0	0	0	7306	
#18	0	172	0	0	0	0	4	33	6	22	0	2	2	1035	0	4	0	0	0	0	34	0	34	0	1	0	6	3	7	0	97	0	0	0	1428		
#19	11	809	13	21	6	87	59	2345	8	4	0	6	39	0	16709	0	0	0	4	0	40	0	0	0	0	0	0	0	0	0	12	0	0	0	63	20236	
#20	0	17	0	0	12	0	0	0	0	0	31	0	0	0	1776	0	0	9	21	0	0	18	0	0	0	2	21	72	0	9	4	1	0	1	1994		
#21	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	132	3	0	0	0	0	0	0	0	1	0	0	0	0	20	0	0	0	0	158		
#22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	1	1143	0	0	0	0	0	3	0	135	1	0	24	8	0	44	0	0	0	1361		
#23	0	0	0	0	0	0	2	0	3	0	0	0	0	0	0	0	4	888	0	0	0	0	4	0	54	0	0	6	0	73	0	1	0	6	1041		
#24	18	216	0	0	0	0	25	1128	0	38	0	152	55	103	0	0	0	2	6339	0	0	205	0	100	0	7	4	60	2	10	415	0	0	26	8905		
#25	9	279	10	12	0	0	2	184	0	4	0	0	0	0	0	0	0	0	0	1385	0	13	0	0	0	0	0	0	0	0	0	0	0	0	0	1979	
#26	0	8	0	0	0	0	0	33	0	44	0	0	0	0	0	0	0	0	0	0	641	17	0	0	0	5	0	0	0	40	0	0	0	0	788		
#27	25	171	0	0	0	0	13	840	0	4	0	9	17	2	0	0	0	0	142	0	14	8149	0	43	1	0	18	6	12	0	67	10	0	0	106	9649	
#28	2	25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	46	0	1	0	639	0	31	2	0	28	11	0	98	0	0	0	883		
#29	6	72	0	0	0	0	1	24	0	0	0	34	20	0	0	0	0	0	96	0	0	103	0	1351	0	0	0	6	0	5	0	0	0	3	1721		
#30	0	0	0	0	0	0	0	0	0	0	0	314	0	0	1	0	68	38	73	0	0	13	3	3445	56	6	309	39	0	1263	0	0	0	117	5745		
#31	0	0	0	0	0	0	0	226	0	6	0	136	0	0	0	0	20	10	246	0	0	128	3	0	15	1690	0	90	0	265	0	0	0	0	2835		
#33	4	380	5	3	8	0	13	601	10	20	0	13	19	27	29	0	0	24	49	0	112	5	46	0	0	0	3163	0	7	0	137	19	1	0	51	4746	
#35	0	70	0	0	0	0	0	16	1	0	6	103	10	0	30	0	5	21	177	0	0	130	47	11	91	52	0	5298	193	0	1337	0	20	0	4	7622	
#36	0	18	0	0	0	0	3	0	0	0	0	16	0	0	6	0	0	0	37	0	0	83	0	22	8	0	0	31	1224	0	109	0	2	0	0	1559	
#37	0	20	0	0	0	0	0	0	0	0	0	101	0	0	0	0	0	0	19	0	0	0	0	0	12	0	0	0	1081	930	0	18	0	2181			
#38	15	1027	0	0	0	0	0	1154	0	36	0	269	31	12	0	1	4	29	329	0	6	148	5	34	122	33	24	128	222	36	1434	18	0	37	1037	147	148205
#39	0	2	0	0	0	0	0	313	0	0	0	0	0	0	10	0	0	0	10	0	0	243	0	0	0	0	0	0	0	0	30	1272	0	0	0	1880	
#40	0	0	0	0	0	0	0	0	0	0	0	82	0	0	62	0	3	2	0	0	0	0	0	0	1	0	0	19	2	0	127	0	1828	0	0	2126	
#41	0	167	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13	0	344	0	0	12623	0	13147	
#42	3	124	0	2	0	0	16	94	0	0	0	0	0	0	0	1	0	13	0	0	0	60	1	0	5	0	17	8	0	109	3	0	0	25574	26030		
Razem Total	2389	35856	2743	3830	2218	2727	7651	57837	1807	3576	357	9221	5777	1267	18493	1933	135	1252	1046	7892	1479	704	10649	733	1758	3919	1891	3383	6101	1721	1170	151607	1356	1905	14394	26451	397228



Ryc. 34. Wynik klasyfikacji 20 kanałów MNF 2 linii zobrazowania DAIS 7915 po 5000 iteracji. Macierz błędów zob. tabele 17 i 18. Objasnienia jak na ryc. 33

Fig. 34. Results of the twenty-MNF-band DAIS 7915 set classification of the flight line No. 2 (after 5000 iterations). Error matrices see tables 17 and 18. Classified units correspond with the fig. 33

Uwzględniając liczbę analizowanych wydzieleni oraz złożony charakter poszczególnych zbiorowisk, uzyskane wyniki klasyfikacji należy uznać za dobre. Świadczy o tym liczba wydzieleni, które udało się wyznaczyć (40 z 42 analizowanych klas) oraz poziom uzyskanych dokładności. Średnia dokładność producenta dla wszystkich klasyfikacji (wszystkie linie zobrazowań oraz klasyfikacje danych oryginalnych i po transformacji MNF) wyniosła 86,0%, natomiast dokładność użytkownika 75,1%. Średnia dokładność klasyfikacji zestawów 40 kanałowych wyniosła odpowiednio 88,6 i 76,4%. Dla danych MNF było to odpowiednio 82,6 i 73,8% (tab. 24). We wszystkich analizowanych przypadkach całkowita dokładność uzyskiwana z klasyfikacji 40 oryginalnych kanałów jest nieznacznie wyższa, w porównaniu do wyników 20 kanałów MNF. Różnica ta nie jest często aż tak dobrze widoczna w poszczególnych klasach, gdzie najlepsze wyniki klasyfikacji równie często występują w klasyfikacji 20 MNF, jak i 40 kanałów. Jednakże przeglądając tabelę 24 dość wyraźnie można zaobserwować, że najniższe dokładności poszczególnych klas częściej pojawiają się w wynikach 20 kanałów MNF. Jako przykłady mogą służyć wartości poniżej 70% (dla dokładności zarówno producenta, jak i użytkownika), dla linii nr 6 i klasyfikacji 40 kanałów zaobserwowano osiem razy dokładność poniżej 70%, natomiast 20 razy w przypadku klasyfikacji 20 kanałów MNF. Podobnie wygląda sytuacja w wynikach klasyfikacji 5 linii odpowiednio 15 i 16 oraz w przypadku 2 linii 8 i 22 razy (tab. 22).

Analizując poszczególne linie zobrazowania, najwyższą dokładność całkowitą klasyfikacji osiągnięto dla 40 oryginalnych kanałów 4 linii zobrazowania (21 analizowanych klas występujących na danym terenie) i wyniosła ona 89,07% (224 941 pikseli zostało poprawnie sklasyfikowanych spośród 252 538 analizowanych). Najniższa dokładność całkowita to 84,45% (335445/397228), wystąpiła ona w klasyfikacji 20 kanałów MNF 2 linii zobrazowania DAIS 7915 (tab. 22).

Wskaźnik kappa, który jest miarą podobieństwa pomiędzy wynikami klasyfikacji a wzorcem (w tym przypadku powstałym na bazie szczegółowej weryfikacji terenowej wybranych poligonów poklasyfikacyjnych *Spectral Angle Mapper*) wyniósł średnio 0,84, wahając się od 0,81 do 0,86 (tab. 22). Wynik ten należy uznać za dobry, gdyż oznacza, że ponad 80% wydzieleni map poklasyfikacyjnych zgadza się ze wzorcami.

Najlepsze wyniki (powyżej 90% dokładności użytkownika i producenta) uzyskały homogeniczne spektralnie klasy: muraw alpejskich typowych (#8), muraw alpejskich torfowcowych (#11), muraw alpejskich w kompleksie z wyleżyskami (#17), zarośla kosodrzewiny na podłożu bezwęglanowym (#38) oraz wody (#42).

Najgorsze wyniki klasyfikacji mierzonej przeszacowaniem lub niedoszacowaniem (powyżej 25% dokładności użytkownika i producenta) uzyskały wydzielenia kompleksowe, mieszane: murawy alpejskie postać piargowa z sitem skuciną (#14), murawy alpejskie postać subalpejska (#15), traworośla trzcinnikowe (#24), traworośla trzcinnikowe w kompleksie z zaroślami kosodrzewiny

i murawami subalpejskimi (#27), murawy powypasowe świeże i suche (#30) oraz wilgotne (#31), zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami (#36) oraz zbiorowiska zaroślowe wierzby śląskiej i malin (#37). Wyleżyska w piętrze subalpejskim oraz murawy powypasowe z fragmentami silnie zantropogenezowanymi nie zostały sklasyfikowane.

Centralną część obszaru badań, najbardziej zróżnicowaną pod względem struktury roślinności poddano osobnej klasyfikacji. Powierzchnię testową ograniczono do terenu Doliny Gąsienicowej oraz Doliny Pięciu Stawów Polskich. Klasyfikacja składała się z 10 000 iteracji symulatorem fuzzy ARTMAP. Uzyskane wyniki z dwóch niezależnych linii obrazowych połączono w jedną mapę (ryc. 35). Zgodnie z przyjętym założeniem, za mapą zamieszczono tabele prezentujące dane statystyczne uzyskanych wyników. Dotyczy to macierzy błędów (tab. 19 i 20) oraz dokładności poszczególnych zbiorowisk roślinnych (tabela 21).

Zwiększenie próby statystycznej do ponad 600 000 pikseli i podwojenie liczby iteracji pozwoliło uzyskać dokładność całkowitą klasyfikacji na poziomie 90%, współczynnik kappa wzrósł z 0,84 do 0,88 (tab. 20). Średnia dokładność producenta obliczona dla wszystkich klas wyniosła 89,9%, a użytkownika 77,8% (tab. 21). Oznacza to wzrost dokładności odpowiednio o 1,3% i 1,4%. Jednakże, zważywszy na fakt, że czas trwania klasyfikacji także uległ znacznemu zwiększeniu wydaje się, że klasyfikacja w 5000 iteracji jest rozwiązaniem optymalnym.

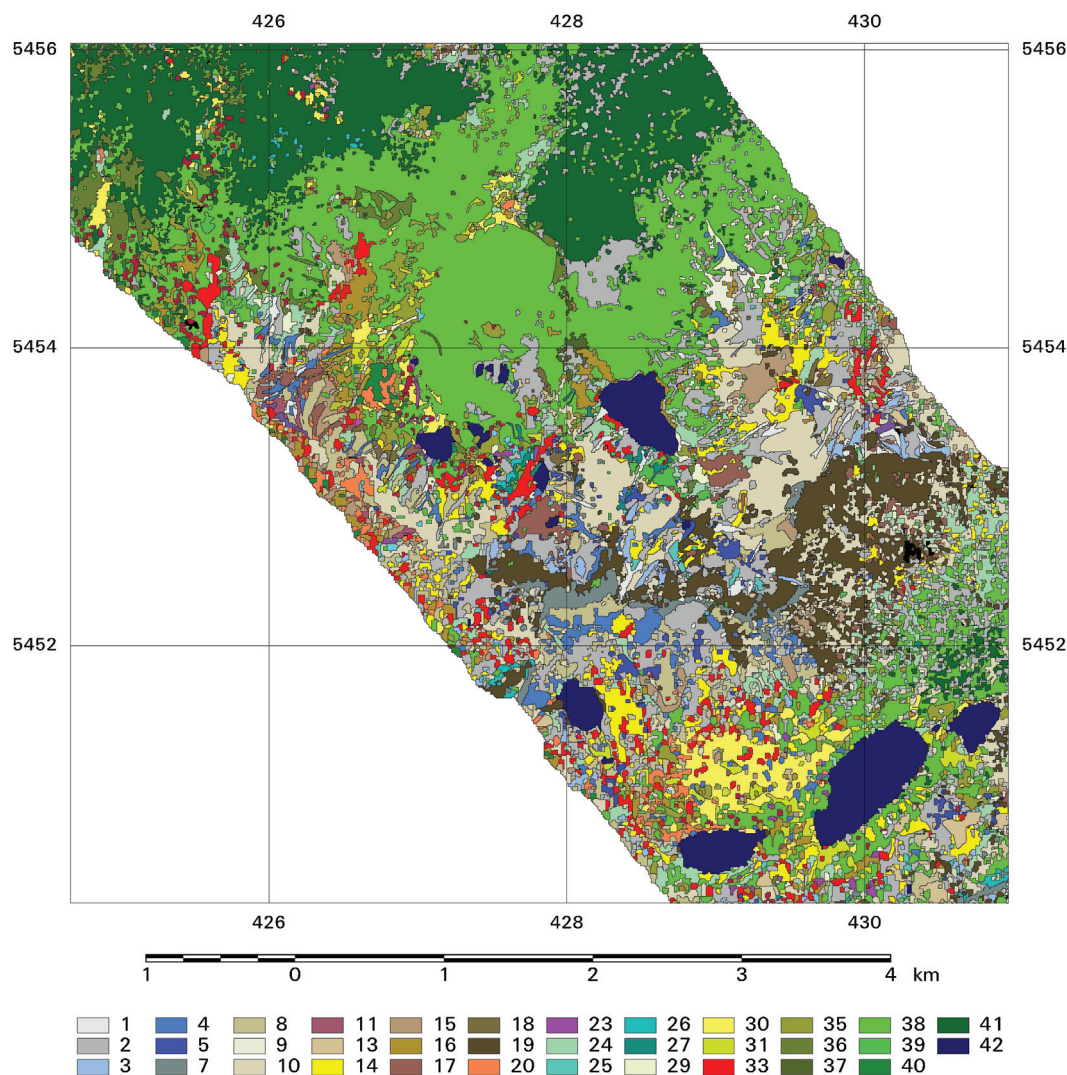
Analizę oraz zbiorcze zestawienie uzyskanych wyników przedstawiono w postaci tabel 22-25 i ryciny 36. Tabela 22 zawiera syntetyczne zestawienie dokładności wyrażonych w procentach i uzyskanych dla poszczególnych wydzieleni sklasyfikowanych na poszczególnych liniach zobrazowań. Merytorycznie identyczna jest tabela 23, która prezentuje wartości wyrażone w liczbie pikseli.

Szczególną uwagę należy zwrócić na tabelę 24. Stanowi ona kontynuację tabeli 22 i prezentuje zmienność wyników zarejestrowanych dla poszczególnych klas na wszystkich liniach zobrazowania. Pierwsze dwie kolumny zawierają wartości średnie dokładności użytkownika i producenta (obliczone z tab. 22), następne dwie odchylenia standardowe od wyników poszczególnych klas uzyskanych ze wszystkich linii zobrazowań (6, 5, 4 oraz 2), bez rozdzielania na rodzaj danych wejściowych do klasyfikacji (40 oryginalnych lub 20 kanałów MNF). Podział ten zaprezentowano w kolejnych kolumnach, gdzie oddzielona została dokładność uzyskana tylko z klasyfikacji 40 oryginalnych lub 20 kanałów MNF. Przedmiotem interesującej analizy mogą być najlepsze (max) i najgorsze wyniki (min), jakie uzyskały poszczególne zbiorowiska roślinne oraz i ich odchylenia standardowe.

Analiza danych z tabeli 24 prowadzi do wniosku, że zestaw danych składający się z kanałów MNF oferuje gorsze wyniki. Dokładność producenta była niższa średnio o 6%, natomiast użytkownika o 2,6%. Ponadto klasyfikacje bazujące na oryginalnych kanałach charakteryzowało mniejsze odchylenie standardowe (dokładność producenta o 2,6%, a użytkownika o 0,3%). Rycina 36

Tabela 18. Macierz błędów (liczba pikseli) klasyfikacji 20 kanałów MNF 2 linii zobrazowania DAIS 7915
 Table 18. Error matrix (number of pixels) of twenty-MNF-band DAIS 7915 set classification of the flight line No. 2

#1	#2	#3	#4	#5	#7	#8	#10	#13	#14	#15	#16	#17	#18	#19	#20	#21	#22	#23	#24	#25	#26	#27	#28	#29	#30	#31	#33	#35	#36	#37	#38	#39	#40	#41	#42	Razem Total	
#1	1990	219	12	0	7	6	0	385	25	95	0	0	0	123	0	0	0	0	10	24	0	130	0	0	0	0	1	0	0	0	0	5	0	0	12	3044	
#2	59	26938	59	31	287	40	250	2034	154	226	66	178	147	94	310	11	0	0	227	65	4	578	5	117	0	0	39	0	102	71	1700	0	0	1203	271	35266	
#3	33	637	2571	44	0	10	0	561	0	0	0	0	0	0	247	0	0	0	0	32	0	32	0	0	0	0	0	0	0	0	0	0	0	0	0	4167	
#4	36	320	5	3459	0	28	122	995	0	11	0	0	1	202	18	0	0	0	0	4	2	2406	0	0	0	1	0	0	0	19	34	0	0	0	0	7663	
#5	9	429	0	0	1679	0	48	77	0	39	0	0	40	1	0	0	0	0	15	0	0	50	0	0	0	0	0	0	0	0	0	0	0	0	0	2398	
#7	87	36	0	113	0	2374	86	115	0	0	0	0	0	860	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3671	
#8	14	532	18	82	62	53	6842	1254	121	84	0	9	66	0	27	0	4	0	12	0	1	91	7	0	0	33	0	6	0	46	0	0	0	0	0	9364	
#10	41	725	27	66	67	73	68	42479	10	78	20	15	103	0	553	5	0	0	0	26	2	27	244	0	0	0	22	0	14	0	479	34	10	0	38	45226	
#13	0	154	0	3	0	0	0	154	1325	78	0	0	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	22	0	0	0	0	0	1743	
#14	1	600	0	12	15	0	1	554	68	2694	0	130	0	42	2	0	0	0	0	6	0	297	0	0	0	1	2	0	0	89	0	0	0	5	4519		
#15	0	5	0	0	0	0	1	2	0	0	211	54	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	17	0	0	0	0	0	290	
#16	9	31	0	0	0	0	2	51	0	14	34	7391	9	0	25	0	2	10	91	0	0	0	0	19	10	38	5	12	28	30	490	0	11	0	14	8326	
#17	0	1011	0	0	9	7	0	1293	7	45	9	27	5027	0	64	0	0	0	25	0	10	125	0	35	0	0	0	0	0	0	4	0	0	0	0	0	7698
#18	0	170	0	0	0	0	4	33	23	29	0	2	965	0	7	0	0	0	0	0	0	34	0	0	24	0	6	3	25	0	97	0	0	0	0	1424	
#19	52	931	36	3	72	120	156	2987	22	4	0	6	64	0	15847	0	0	0	0	7	0	66	0	0	0	0	0	0	0	0	0	21	0	0	0	20457	
#20	0	17	0	0	12	0	0	0	0	0	37	0	0	0	1618	0	0	9	22	0	0	5	0	0	0	7	14	92	0	9	0	13	0	0	0	1855	
#21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	120	0	0	0	0	0	0	0	0	0	0	0	0	0	0	20	0	0	0	0	0	140	
#22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	9	1099	0	0	0	0	0	3	0	162	1	0	34	8	0	45	0	0	0	0	1363	
#23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	765	0	0	0	0	0	4	0	62	0	0	5	0	53	0	0	0	0	6	899	
#24	18	305	0	0	0	0	25	1089	0	28	0	130	111	103	0	4	0	0	2	5252	0	0	574	0	106	0	8	4	105	4	35	701	0	0	0	26	8630
#25	10	283	10	12	0	0	2	189	0	13	0	0	0	0	170	0	0	0	0	0	1323	0	13	0	0	0	0	93	0	19	0	0	0	0	0	2137	
#26	0	3	0	0	0	0	0	38	0	28	0	0	0	0	0	0	0	0	0	0	543	18	0	0	0	5	0	0	40	0	0	0	0	0	0	675	
#27	0	127	0	0	0	0	13	959	0	4	0	9	4	2	0	5	0	0	224	0	12	4049	0	4	1	0	18	3	9	0	26	12	0	0	0	74	5555
#28	2	25	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	46	0	1	0	647	0	41	2	0	28	12	0	98	0	0	0	0	904	
#29	6	91	0	0	0	0	1	24	0	0	0	70	9	0	0	0	0	0	101	0	0	311	0	1346	0	0	0	7	0	5	19	0	0	0	0	1996	
#30	0	0	0	0	0	0	0	0	10	0	338	0	0	0	15	0	97	38	73	0	0	0	13	3	3243	133	6	459	64	1413	0	0	0	0	0	117	6022
#31	0	0	0	0	0	0	0	199	0	6	0	144	0	0	0	0	10	10	763	0	0	136	3	0	9	1509	0	107	0	261	0	0	0	0	0	3157	
#33	4	492	5	3	8	16	14	656	47	32	7	13	50	46	32	14	0	0	83	134	0	159	5	46	0	0	3187	0	14	0	139	23	11	0	51	5291	
#35	0	176	0	0	0	0	0	16	1	14	10	112	10	0	84	0	7	25	235	0	0	132	47	11	107	118	0	4789	215	0	1359	0	40	0	4	7512	
#36	0	119	0	0	0	0	0	0	0	0	0	0	0	0	11	0	0	0	38	0	0	337	0	25	8	0	16	1068	0	103	0	2	0	0	0	1727	
#37	0	10	0	0	0	0	0	1	0	0	0	214	0	0	0	0	0	0	24	0	0	0	0	0	16	0	0	0	767	931	0	0	18	0	1981		
#38	15	1235	0	0	0	0	0	1168	4	42	0	383	45	16	0	1	30	77	591	0	11	476	5	46	247	59	24	279	137	262	142650	0	65	2067	154	150089	
#39	0	4	0	0	0	0	0	409	0	0	0	0	0	15	11	0	0	0	10	0	0	334	0	0	0	0	0	0	0	30	1220	0	0	0	0	2033	
#40	0	0	0	0	0	0	0	0	0	0	0	89	0	0	91	0	3	2	0	0	0	0	0	0	0	0	59	2	0	296	0	1753	0	0	2295		
#41	0	107	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13	0	324	0	0	11106	0	11550		
#42	3	124	0	2	0	0	16	115	0	0	0	0	0	0	10	1	0	13	0	0	3	129	1	0	5	0	17	8	0	112	3	0	0	25599	26161		
Razem Total	2389	35856	2743	3830	2218	2727	7651	57837	1807	3576	357	9221	5777	1267	18493	1933	135	1252	1046	7892	1479	704	10649	733	1758	3919	1891	3383	6101	1721	1170	151607	1356	1905	14394	26451	397228



Ryc. 35. Wynik klasyfikacji 40 oryginalnych kanałów DAIS 7915 po 10 000 iteracji dla centralnej części obszaru badań. Macierz błędów zob. tabele 19 i 20, dokładność klasyfikacji zob. tabela 21. Sklasyfikowane jednostki: 1 pionierskie zbiorowiska roślin zarodnikowych; 2 zbiorowiska porostów naskalnych; 3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; 4 wilgotne traworośla kosmatkowe; 5 wyleżyska w piętrze alpejskim; 7 murawa subniwalna; 8 murawa alpejska typowa; 9 murawa aplejska porostowa; 10 fragmenty muraw alpejskich na półkach skalnych; 11 murawa alpejska torfowcowa; 13 murawa alpejska z wierzbą Kitaibela; 14 murawa alpejska postać piargowa z sitem skuciną; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyskami; 18 murawa alpejska w kompleksie z traworoślami; 19 kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach; 20 murawa alpejska na podłożu węglanowym; 23 wilgotne psiary w kompleksie z ziołoroślami; 24 traworośle trzcinnikowe; 25 traworośle trzcinnikowe postać pionierska; 26 traworośle trzcinnikowe w kompleksie z wilgotnymi murawami; 27 traworośle trzcinnikowe w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi; 29 wilgotne murawy w kompleksie z wyleżyskami i ziołoroślami; 30 murawy powypasowe świeże i suche; 31 murawy powypasowe wilgotne; 33 wysokogórskie borówczyska bżynowe; 35 zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 39 kępy kosodrzewiny na ścianach skalnych; 40 zarośla kosodrzewiny na podłożu węglanowym; 41 bór górnoreglowy; 42 woda

Fig. 35. Results of the forty-band DAIS 7915 set classification of the central part of the research area (after 10,000 iterations). Error matrices see tables 19 and 20, classification accuracy see table 21. Classified units: 1 cryptogamic plant communities on scree – initial phase; 2 epilithic lichen communities – *Rhizocarpetalia*; 3 scree communities – *Androsacetalia alpinae*; 4 *Luzuletum alpino-pilosae*; 5 *Salicetum herbaceae*, *Luzuletum spadiceae*; 7 subnivale swards – *Oreochloa distichae-Juncetum trifidi subnivale* form; 8 *Oreochloa distichae-Juncetum trifidi typicum*; 9 *Oreochloa distichae-Juncetum trifidi cetrarietosum*; 10 *Oreochloa distichae-Juncetum trifidi* – vegetation fragments on rocky shelves; 11 *Oreochloa distichae-Juncetum trifidi sphagnetosum*; 13 *Oreochloa distichae-Juncetum trifidi salicetosum kitaibeliana*; 14 *Oreochloa distichae-Juncetum trifidi* scree form with *Juncus trifidus*; 15 *Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis*; 16 *Oreochloa distichae-Juncetum trifidi subalpine anthropogenic* form; 17 *Oreochloa distichae-Juncetum trifidi* in a complex with snow-bed communities; 18 *Oreochloa distichae-Juncetum trifidi* in a complex with *Calamagrostietum villosae*; 19 *Oreochloa distichae-Juncetum trifidi* in a complex with *Festuco versicoloris-Agrostietum*; 20 *Festuco versicoloris-Agrostietum*; 23 *Sphagno-Nardetum*, *Polytricho-Nardetum* in a complex with *Caltha laeta* community; 24 *Calamagrostietum villosae tatricum*; 25 *Calamagrostietum* in a complex with *Luzuletum alpino-pilosae* pioneer form; 26 *Calamagrostietum* in a complex with wet subalpine meadows; 27 *Calamagrostietum* in a complex with *Pinetum mugho* and subalpine meadows; 29 *Festuca picta* community in a complex with *Luzuletum alpino-pilosae*; 30 *Festuca picta* community; 31 *Deschampsia flexuosa* community, *Hieracio alpini-Nardetum*; 33 *Empetro-Vaccinietum*; 35 *Vaccinium myrtillus* community in a complex with *Pinetum mugho carpaticum silicicolum*; 36 *Vaccinium myrtillus* community in a complex with tall herb communities; 37 willow thicket – *Chamaenerion angustifolium-Salix silesiaca* community; 38 mountain-pine scrub on silicate substrate – *Pinetum mugho carpaticum silicicolum*; 39 mountain-pine scrub – *Pinetum mugho carpaticum silicicolum* in a complex with epilithic lichen communities; 40 mountain-pine scrub on calcareous substrate – *Pinetum mugho carpaticum calcicolum*; 41 montane spruce forest – *Plagiothecio-Piceetum*; 42 water

Tabela 19. Macierz błędów (%) klasyfikacji 40 kanałów DAIS 7915 połączonych linii po 10 000 iteracji
 Table 19. Error matrix (%) of forty-band DAIS 7915 sets classification of the central part of the High Tatras after 10,000 iterations

	#1	#2	#3	#4	#5	#7	#8	#9	#10	#11	#13	#14	#15	#16	#17	#18	#19	#20	#23	#24	#25	#26	#27	#29	#30	#31	#33	#35	#36	#37	#38	#39	#40	#41	#42	
#1	94	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
#2	2	88	13	0	4	1	1	0	1	0	0	10	0	1	0	1	2	0	0	2	4	0	0	0	0	0	4	0	1	1	1	1	0	1	0	
#3	0	0	82	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#4	0	0	1	93	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#5	0	1	0	0	90	0	1	0	0	0	3	4	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	
#7	0	0	0	0	0	91	0	0	1	0	1	0	0	0	0	0	6	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	
#8	0	0	0	0	0	2	90	0	0	0	0	1	1	0	0	0	0	3	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
#9	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#10	2	1	2	2	2	1	1	0	86	1	4	0	0	0	1	1	5	0	0	0	1	0	0	0	0	0	0	0	0	0	0	7	0	0	0	
#11	0	0	0	0	0	0	1	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#13	0	0	0	0	4	0	0	0	0	0	91	1	0	0	0	1	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	
#14	0	1	0	1	0	0	1	0	1	0	0	81	0	0	0	1	0	0	0	0	7	0	0	1	0	0	1	0	0	0	0	0	0	0	0	
#15	0	0	0	0	0	0	1	0	1	0	0	0	94	1	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#16	0	0	0	0	0	0	0	0	0	0	0	0	0	85	0	0	0	0	3	0	0	0	0	0	1	8	0	0	0	1	0	0	0	0	0	
#17	0	2	2	0	0	0	0	0	0	0	0	1	0	0	92	0	1	0	0	0	0	0	2	1	0	0	0	0	0	0	0	0	1	0	0	
#18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	92	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#19	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	82	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#20	0	0	0	0	0	0	1	0	0	1	0	0	2	1	1	0	0	94	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	
#23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	95	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
#24	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	88	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
#25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	83	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
#26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	8	0	0	0	0	0	0	0	0	0	0	0	0	
#27	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	84	0	0	1	0	0	0	0	0	1	0	0	0	
#29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	96	0	1	2	1	0	0	0	0	0	0	0	
#30	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	88	3	0	1	2	0	0	0	0	0	0	
#31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	85	0	1	0	0	0	0	0	0	0	
#33	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	1	0	0	0	78	0	0	0	0	1	0	0	0	
#35	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	2	0	0	1	86	0	0	0	0	0	0	0	
#36	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	0	77	0	0	0	0	0	0	
#37	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	95	0	0	0	0	0	0	
#38	0	3	0	0	0	1	0	2	4	0	0	0	0	6	0	2	0	0	2	2	0	0	4	0	5	2	8	9	11	2	93	0	0	0	7	
#39	0	0	0	0	0	0	0	0	1	0	0	0	1	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	85	0	0	0	0	
#40	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	0	0	0	0	0	0	
#41	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	8	0	4	0	0	92	0	
#42	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	99
Razem Total	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Dokładność całkowita = 89,62% (540618/603237 pikseli), współczynnik kappa = 0,88
 Overall accuracy = 89,62% (540618/603237 pixels), kappa coefficient = 0,88

Tabela 20. Macierz błędów klasyfikacji połączonych linii po 10 000 iteracji
 Table 20. Error matrix (number of pixels%) of forty-band DAIS 7915 sets classification of the central part of the High Tatras after 10000 iterations

#1	#2	#3	#4	#5	#7	#8	#9	#10	#11	#13	#14	#15	#16	#17	#18	#19	#20	#23	#24	#25	#26	#27	#29	#30	#31	#33	#35	#36	#37	#38	#39	#40	#41	#42	Razem Total	
#1	2449	67	12	21	0	104	0	0	43	2	0	6	0	0	0	93	0	0	197	1	0	0	0	0	0	0	40	0	0	13	6	0	0	19	3073	
#2	50	43285	542	9	81	59	271	0	960	0	0	509	24	138	15	20	1144	0	0	171	60	0	1	0	0	0	241	44	87	8	1650	26	0	319	92	49806
#3	0	125	3473	8	0	0	14	0	39	0	0	0	0	2	0	172	0	0	0	0	65	0	0	0	0	0	0	0	0	0	0	0	0	0	3898	
#4	2	187	41	5896	0	66	171	0	117	0	0	0	0	19	0	181	0	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	6684	
#5	0	298	0	1	1780	7	144	0	210	0	21	202	0	0	107	0	98	0	21	0	0	0	0	0	0	92	0	0	0	73	13	0	0	0	3067	
#7	0	34	0	5	0	9095	20	0	1032	0	7	0	0	0	43	0	2895	0	0	0	0	9	0	0	0	1	0	0	0	0	0	12	0	0	0	13153
#8	2	44	5	12	6	159	17241	0	274	0	0	50	35	0	6	7	169	76	0	38	0	0	0	0	0	41	0	0	0	12	0	0	0	0	18177	
#9	0	57	0	0	0	0	476	177	0	0	0	0	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0	0	0	824	
#10	64	609	67	107	34	122	219	0	79573	2	25	16	33	0	83	16	2601	2	0	32	10	0	0	0	0	22	0	5	0	209	186	0	0	9	84046	
#11	0	0	0	0	0	0	113	0	11	294	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	425	
#13	2	203	0	11	70	10	38	0	68	0	555	33	0	0	10	0	334	0	0	68	0	0	9	0	0	0	0	0	0	128	0	0	0	2	1541	
#14	0	295	11	42	1	12	237	0	1342	0	2	4223	14	8	6	15	143	0	0	111	0	0	9	0	0	44	10	0	0	21	51	0	0	0	6598	
#15	0	3	0	24	0	0	99	0	723	0	0	17	6502	135	19	0	46	0	0	0	0	0	0	0	0	0	13	0	0	73	0	0	0	0	7654	
#16	0	40	0	0	2	0	0	0	80	0	0	1	6	8768	7	0	0	11	22	0	0	21	8	73	227	7	41	4	9	402	0	0	0	13	9742	
#17	0	732	77	16	0	0	0	0	180	0	0	59	8	1	8685	0	452	0	0	49	1	0	0	6	0	0	0	10	0	31	13	0	0	0	10320	
#18	0	70	0	9	0	0	0	0	170	0	0	11	0	6	0	1801	0	0	7	0	0	0	0	0	0	15	0	0	196	0	0	0	0	2285		
#19	3	88	4	1	0	229	82	0	2887	0	0	0	18	0	36	0	40639	0	0	16	30	0	0	0	0	0	0	0	6	0	0	0	0	44039		
#20	0	3	0	4	0	0	190	0	82	3	0	2	122	134	112	0	2333	0	15	0	0	1	0	0	17	57	40	16	0	8	0	42	0	0	3181	
#23	0	0	0	0	0	0	0	0	25	0	0	0	0	22	0	0	0	0	366	0	0	0	0	0	0	10	53	0	0	96	0	0	0	0	572	
#24	0	154	0	0	0	0	30	0	203	0	0	0	32	64	37	28	0	0	9282	0	0	0	0	0	0	5	0	12	20	186	5	2	0	6	10066	
#25	12	198	0	0	0	0	22	0	30	0	0	0	0	0	87	0	80	0	0	1402	0	0	0	0	0	70	0	0	18	0	0	0	0	0	1919	
#26	0	11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	132	115	0	0	0	0	0	0	0	0	0	1	0	0	0	259	
#27	0	74	0	55	0	0	4	0	20	0	0	3	0	0	0	68	0	0	0	0	0	1169	0	0	0	73	0	0	41	18	0	0	0	84	1609	
#29	0	36	0	23	0	0	0	0	18	0	0	7	26	0	79	0	3	0	148	0	0	0	955	10	19	102	58	4	0	52	9	0	0	0	1549	
#30	0	0	0	0	0	0	30	0	67	0	0	0	62	0	0	0	1	1	23	0	0	0	0	0	5557	71	0	86	193	0	268	0	1	40	6400	
#31	0	5	0	0	0	0	12	0	37	0	0	0	0	0	0	0	0	0	0	0	0	0	0	17	2392	0	65	0	90	0	6	0	2	2626		
#33	4	110	0	40	0	0	152	0	291	0	0	21	0	37	16	28	1	0	52	0	0	12	0	4	0	5243	24	3	0	80	27	0	0	17	6162	
#35	0	4	0	0	0	0	1	0	0	0	0	6	0	153	8	0	0	0	21	0	0	0	15	31	7	44	8433	14	0	975	0	2	4	0	9718	
#36	0	1	0	3	0	0	6	0	18	0	0	8	0	0	10	0	0	0	25	0	0	0	0	0	216	0	18	8967	0	407	0	0	185	0	9864	
#37	0	29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1009	478	0	0	0	1516		
#38	6	1307	0	20	0	100	13	10	3590	0	0	8	24	641	5	41	213	0	8	174	0	0	55	0	327	55	554	875	1269	17	195679	0	0	2645	5	207641
#39	4	120	0	21	0	0	0	0	552	0	0	0	41	0	69	0	84	0	77	0	0	3	0	0	0	0	0	0	8	2159	0	0	0	0	3138	
#40	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	7	0	0	0	0	0	0	0	0	24	56	208	0	351	0	1680	12	0	2438	
#41	0	690	0	0	0	0	0	0	60	0	0	0	13	0	0	0	0	0	60	0	0	0	0	41	0	0	21	896	0	8172	0	0	36353	0	46306	
#42	0	61	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	63	0	3	0	0	41	0	0	0	22772	0	22941	
Razem Total	2598	48940	4232	6328	1974	9963	19109	486	92879	301	610	5182	6901	10282	9461	1956	49370	2472	387	10499	1680	132	1395	993	6339	2798	6731	9794	11678	1063	209866	2526	1733	39558	23021	603237

Dokładność całkowita = 89,62% (540618/603237 pikseli), współczynnik kappa = 0,88.

Overall accuracy = 89.62% (540618/603237 pixels), kappa coefficient = 0.88.

Tabela 21. Dokładność klasyfikacji 40 kanałów DAIS 7915 połączonych linii po 10 000 iteracji centralnej części Tatr Wysokich
 Table 21. Accuracy of forty-band DAIS 7915 classification sets after 10000 iterations of central part of the High Tatras

	Dokładność producenta / Producer accuracy		Dokładność użytkownika / User accuracy		Przeszacowanie / Commission		Niedoszacowanie / Omission	
	%	Piksele / Pixels	%	Piksele / Pixels	%	Piksele / Pixels	%	Piksele / Pixels
#1	94,3	2449/2598	79,7	2449/3073	20,3	624/3073	5,7	149/2598
#2	88,5	43285/48940	86,9	43285/49806	13,1	6521/49806	11,6	5635/48940
#3	82,1	3473/4232	89,1	3473/3898	10,9	425/3898	17,9	759/4232
#4	93,2	5896/6328	88,2	5896/6684	11,8	788/6684	6,8	432/6328
#5	90,2	1780/1974	58,0	1780/3067	42,0	1287/3067	9,8	194/1974
#7	91,3	9095/9963	69,2	9095/13153	30,9	4058/13153	8,7	868/9963
#8	90,2	17241/19109	94,9	17241/18177	5,2	936/18177	9,8	1868/19109
#9	97,9	476/486	57,8	476/824	42,2	348/824	2,1	10/486
#10	85,7	79573/92879	94,7	79573/84046	5,3	4473/84046	14,3	13306/92879
#11	97,7	294/301	69,2	294/425	30,8	131/425	2,3	7/301
#13	91,0	555/610	36,0	555/1541	64,0	986/1541	9,0	55/610
#14	81,5	4223/5182	64,0	4223/6598	36,0	2375/6598	18,5	959/5182
#15	94,2	6502/6901	85,0	6502/7654	15,1	1152/7654	5,8	399/6901
#16	85,3	8768/10282	90,0	8768/9742	10,0	974/9742	14,7	1514/10282
#17	91,8	8685/9461	84,2	8685/10320	15,8	1635/10320	8,2	776/9461
#18	92,1	1801/1956	78,8	1801/2285	21,2	484/2285	7,9	155/1956
#19	82,3	40639/49370	92,3	40639/44039	7,7	3400/44039	17,7	8731/49370
#20	94,4	2333/2472	73,3	2333/3181	26,7	848/3181	5,6	139/2472
#23	94,6	366/387	64,0	366/572	36,0	206/572	5,4	21/387
#24	88,4	9282/10499	92,2	9282/10066	7,8	784/10066	11,6	1217/10499
#25	83,5	1402/1680	73,1	1402/1919	26,9	517/1919	16,6	278/1680
#26	100,0	132/132	51,0	132/259	49,0	127/259	0,0	0/132
#27	83,8	1169/1395	72,7	1169/1609	27,4	440/1609	16,2	226/1395
#29	96,2	955/993	61,7	955/1549	38,4	594/1549	3,8	38/993
#30	87,7	5557/6339	86,8	5557/6400	13,2	843/6400	12,3	782/6339
#31	85,5	2392/2798	91,1	2392/2626	8,9	234/2626	14,5	406/2798
#33	77,9	5243/6731	85,1	5243/6162	14,9	919/6162	22,1	1488/6731
#35	86,1	8433/9794	86,8	8433/9718	13,2	1285/9718	13,9	1361/9794
#36	76,8	8967/11678	90,9	8967/9864	9,1	897/9864	23,2	2711/11678
#37	94,9	1009/1063	66,6	1009/1516	33,4	507/1516	5,1	54/1063
#38	93,2	195679/209866	94,2	195679/207641	5,8	11962/207641	6,8	14187/209866
#39	85,5	2159/2526	68,8	2159/3138	31,2	979/3138	14,5	367/2526
#40	96,9	1680/1733	68,9	1680/2438	31,1	758/2438	3,1	53/1733
#41	91,9	36353/39558	78,5	36353/46306	21,5	9953/46306	8,1	3205/39558
#42	98,9	22772/23021	99,3	22772/22941	0,7	169/22941	1,1	249/23021

Tabela 22. Porównanie dokładności (wyrażonej w %) klasyfikacji poszczególnych linii zobrazań DAIS 7915 obszaru Tatr Wysokich
 Table 22. Accuracy comparison (%) of all classified DAIS 7915 images of the High Tatras

Dokładność całkowita Overall accuracy Kappa coefficient Klasa Class	6 linia zobrazowania Flight line #6				5 linia zobrazowania Flight line #5				4 linia zobrazowania Flight line #4				2 linia zobrazowania Flight line #2			
	40 kanałów 40 bands		20 kanałów MNF 20 MNF bands		40 kanałów 40 bands		20 kanałów MNF 20 MNF bands		40 kanałów 40 bands		20 kanałów MNF 20 MNF bands		40 kanałów 40 bands		20 kanałów MNF 20 MNF bands	
	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.	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.
#1	87,8	75,1	88,3	73,9	92,4	80,1	80,1	80,1	80,1	88,9	69,4	88,9	69,4	88,9	69,4	
#2	78,5	74,3	78,9	72,9	83,6	82,5	79,0	81,6	81,6	79,6	82,0	79,6	82,0	75,13	76,39	
#3	96,0	54,9	90,7	53,5	92,8	73,2	92,8	71,7	-	96,5	66,8	96,5	66,8	93,73	61,7	
#4	97,4	68,0	97,5	67,7	93,5	79,1	93,5	78,8	95,8	93,8	76,5	93,8	76,5	90,31	45,14	
#5	95,6	72,1	95,6	72,1	95,2	57,3	95,2	53,4	-	89,9	74,5	89,9	74,5	75,7	70,02	
#7	90,7	65,9	90,7	64,1	95,8	53,2	94,6	52,9	-	90,1	75,5	90,1	75,5	87,06	64,67	
#8	89,4	74,8	89,5	74,2	89,1	79,1	89,2	76,9	94,0	92,2	81,0	92,2	81,0	89,43	73,07	
#9	-	-	-	-	-	-	-	-	98,3	-	-	-	-	-	-	
#10	73,3	92,6	73,4	91,7	80,7	94,9	77,9	94,6	86,5	78,7	95,2	78,7	95,2	73,45	93,93	
#11	-	-	-	-	91,4	98,1	91,4	97,1	-	-	-	-	-	-	-	
#12	-	-	-	-	90,5	89,3	90,5	89,3	-	-	-	-	-	-	-	
#13	91,7	73,0	80,5	69,0	94,9	45,2	94,9	45,2	-	89,9	81,8	89,9	81,8	73,33	76,02	
#14	82,2	64,0	54,4	52,9	78,6	80,5	78,6	80,5	94,4	83,8	77,1	83,8	77,1	75,34	59,61	
#15	87,9	83,2	70,7	82,1	79,4	68,4	79,4	68,2	97,9	87,1	81,6	97,9	81,6	59,1	72,76	
#16	76,2	94,4	65,0	94,7	78,5	83,4	78,5	81,9	90,6	83,9	91,6	83,9	91,6	80,15	88,77	
#17	81,4	82,5	68,9	80,1	68,8	91,4	68,9	88,3	95,0	91,3	72,2	91,3	72,2	87,02	65,3	
#18	85,9	73,6	86,0	71,5	71,5	93,2	71,5	93,2	95,4	81,7	72,5	81,7	72,5	76,16	67,77	
#19	84,8	76,8	84,8	76,2	72,8	86,3	72,8	85,4	90,1	90,4	82,6	90,4	82,6	85,69	77,46	
#20	95,1	85,2	61,8	86,3	89,8	66,6	83,2	63,8	-	91,9	89,1	91,9	89,1	83,7	87,22	
#21	-	-	-	-	95,7	84,6	95,7	84,6	-	97,8	83,5	97,8	83,5	88,89	85,71	
#22	85,6	80,7	74,0	75,2	90,8	56,4	87,8	55,7	-	91,3	84,0	91,3	84,0	87,78	80,63	
#23	93,8	78,2	83,5	67,4	94,1	55,1	94,1	54,5	-	84,9	85,3	84,9	85,3	73,14	85,09	
#24	82,1	73,4	78,2	71,9	73,7	84,6	73,8	81,6	91,0	80,3	71,2	80,3	71,2	66,55	60,86	
#25	95,8	67,9	91,6	65,8	86,0	63,0	86,0	58,1	-	93,6	70,0	93,6	70,0	89,45	61,91	
#26	89,7	67,5	73,8	63,8	97,8	30,8	97,8	27,5	-	91,1	81,4	91,1	81,4	77,13	80,44	
#27	-	-	-	-	83,7	87,5	83,8	87,1	-	76,5	84,5	76,5	84,5	38,02	72,89	
#28	83,9	79,5	64,4	76,5	-	-	-	-	-	87,2	72,4	87,2	72,4	88,27	71,57	
#29	97,8	73,9	91,8	73,4	84,0	67,5	84,3	65,1	92,7	76,9	78,5	76,9	78,5	76,56	67,43	
#30	80,8	57,4	74,8	48,5	76,7	80,6	76,7	79,1	-	87,9	60,0	87,9	60,0	82,75	53,85	
#31	85,5	71,0	69,7	66,5	81,7	76,4	81,7	76,4	80,1	89,4	59,6	89,4	59,6	79,8	47,8	
#33	96,1	75,9	96,6	73,9	96,5	64,3	95,7	59,5	98,8	93,3	66,7	93,3	66,7	94,21	60,23	
#34	-	-	-	-	85,6	96,2	85,6	96,2	-	-	-	-	-	-	-	
#35	84,8	72,0	85,7	67,6	81,5	82,7	81,5	81,7	98,1	86,8	69,5	86,8	69,5	78,5	63,75	
#36	75,3	73,7	63,6	73,3	73,8	84,0	66,0	78,5	68,4	71,1	78,5	71,1	78,5	62,06	61,84	
#37	92,6	66,0	63,3	60,4	94,3	28,3	95,1	18,7	74,7	92,4	49,6	92,4	49,6	65,56	38,72	
#38	95,8	93,9	96,0	93,4	93,4	96,2	92,3	95,3	91,8	94,6	96,8	94,6	96,8	94,09	95,04	
#39	85,2	72,6	85,4	71,9	91,1	67,2	91,1	67,2	-	93,8	67,7	93,8	67,7	89,97	60,01	
#40	-	-	-	-	95,9	37,4	95,9	37,2	-	96,0	86,0	96,0	86,0	92,02	76,38	
#41	81,3	97,0	81,4	97,0	-	-	-	-	80,9	87,7	96,0	87,7	96,0	77,16	96,16	
#42	97,4	98,1	97,5	98,0	97,8	97,8	97,8	97,8	98,7	96,7	98,3	96,7	98,3	96,78	97,55	

Objaśnienia: dokł. prod. – dokładność producenta, dokł. użyt. – dokładność użytkownika. Klasy: #1 pionierskie zbiorowiska roślin zarodnikowych; #2 zbiorowiska porostów naskalnych; #3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; #4 wilgotne trawośla kosmatkowe; #5 wyleżyńska w piętrze alpejskim; #6 wyleżyńska w piętrze subalpejskim; #7 murawa subniwalna; #8 murawa alpejska typowa; #9 murawa alpejska na półkach skalnych; #11 murawa alpejska torfowcowa; #12 murawa alpejska wyleżyškowa; #13 murawa alpejska z wierzbą Kitabelą; #14 murawa alpejska z sitem skucią; #15 murawa alpejska z turzycą zawieszoną; #16 murawa alpejska postać subalpejska; #17 murawa alpejska w kompleksie z wyleżyskami; #18 murawa alpejska w kompleksie z trawośłami; #19 kompleks przetrzenny muraw alpejskich na podłożu granitowym i mylonitach; #20 murawa alpejska na podłożu węglanowym; #21 torfowisko przejściowe; #22 wilgotne psiary; #23 wilgotne psiary w kompleksie z ziołoroślami; #24 trawośle trzcinnikowe; #25 trawośle trzcinnikowe postać pionierska; #26 trawośle trzcinnikowe w kompleksie z wilgotnymi murawami; #27 trawośle trzcinnikowe w kompleksie z zarośłami kosodrzewiny i murawami subalpejskimi; #28 ziołorośla; #29 wilgotne murawy w kompleksie z wyleżyskami i ziołoroślami; #30 murawy powyprawosne świeże i suche; #31 murawy powyprawosne wilgotne; #32 murawy powyprawosne, fragmenty silnie zantropogemizowane; #33 wysokogórskie borówczyńska bazyłowe; #34 wysokogórskie borówczyńska bazyłowe w kompleksie z zarośłami kosodrzewiny; #35 zbiorowiska borówki czernicy w kompleksie z zarośłami kosodrzewiny; #36 zbiorowiska borówki czernicy w kompleksie z trawośłami i ziołoroślami; #37 zbiorowiska zaroślowe wierzby śląskiej i malin; #38 zarośla kosodrzewiny na podłożu bezwęglanowym; #39 kępy kosodrzewiny na ścianach skalnych; #40 zarośla kosodrzewiny na podłożu węglanowym; #41 bór górnoregłowy; #42 woda

Explanation: Prod. acc. – producer accuracy, User acc. – user accuracy. Classes: #1 cryptogamic plant communities on scree – initial phase; #2 epilithic lichen communities – Rhizocarpetalia; #3 scree communities – Androsacetalia alpinae; #4 Luzuletum alpino-pilosae; #5 Salicetum herbaceae, Luzuletum spadiceae; #6 Salicetum herbaceae in a complex with Empetro-Vaccinietum; #7 subnivale swards – Oreochloa distichae-Juncetum trifidi typicum; #8 Oreochloa distichae-Juncetum trifidi typicum; #9 Oreochloa distichae-Juncetum trifidi tetraetiosum; #10 Oreochloa distichae-Juncetum trifidi – vegetation fragments on rocky shelves; #11 Oreochloa distichae-Juncetum trifidi sphagnetosum; #12 Oreochloa distichae-Juncetum trifidi salicetosum herbaceae; #13 Oreochloa distichae-Juncetum trifidi salicetosum kitabeliana; #14 Oreochloa distichae-Juncetum trifidi scree form with Juncus trifidus; #15 Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis; #16 Oreochloa distichae-Juncetum trifidi subalpine anthropogenic form; #17 Oreochloa distichae-Juncetum trifidi in a complex with snow-bed communities; #18 Oreochloa distichae-Juncetum trifidi in a complex with Calamagrostietum villosae; #19 Oreochloa distichae-Juncetum trifidi in a complex with Festuco versicoloris-Agrostietum; #20 Festuco versicoloris-Agrostietum; #21 Caricetum fuscae subalpinum; #22 Sphagno-Nardetum, Polytricho-Nardetum; #23 Sphagno-Nardetum in a complex with Caltha laeta community; #24 Calamagrostietum villosae tatricum; #25 Calamagrostietum in a complex with Luzuletum alpino-pilosae pioneer form; #26 Calamagrostietum in a complex with wet subalpine meadows; #27 Calamagrostietum in a complex with Pinetum mugho and subalpine meadows; #28 tall herb communities – Adenostylon; #29 Festuca picta community in a complex with Luzuletum alpino-pilosae; #30 Festuca picta community; #31 Deschampsia flexuosa community, Hieracio alpini-Nardetum; #32 grassland communities after grazing in a complex with ruderal communities; #33 Empetro-Vaccinietum; #34 Empetro-Vaccinietum in a complex with Pinetum mugho; #35 Vaccinium myrtillus community in a complex with Pinetum mugho carpaticum silicicolum; #36 Vaccinium myrtillus community in a complex with tall herb communities; #37 willow thicket – Chamaenerion angustifolium-Salix silesiaca community; #38 mountain-pine scrub on silicate substrate – Pinetum mugho carpaticum silicicolum; #39 mountain-pine scrub – Pinetum mugho carpaticum silicicolum in a complex with epilithic lichen communities; #40 mountain-pine scrub on calcareous substrate – Pinetum mugho carpaticum calcicolum; #41 montane spruce forest – Plagiothectio-Piceetum; #42 water

Tabela 23. Porównanie dokładności (wrażonej w liczbie pikseli) klasyfikacji poszczególnych linii zobrażowań DAIS 7915 obszaru Tatr.
Table 23. Accuracy comparison (number of pixels) of all classified DAIS 7915 images of the High Tatras.

Dokładność całkowita Overall accuracy	6 linia zobrażowania Flight line #6			5 linia zobrażowania Flight line #5			4 linia zobrażowania Flight line #4			2 linia zobrażowania Flight line #2		
	40 kanałów 40 bands	20 kanałów MNF 20 MNF bands	20 kanałów MNF 20 MNF bands	40 kanałów 40 bands	20 kanałów MNF 20 MNF bands	20 kanałów MNF 20 MNF bands	40 kanałów 40 bands	40 kanałów 40 bands	20 kanałów MNF 20 MNF bands	40 kanałów 40 bands	20 kanałów MNF 20 MNF bands	
87,40% (362757/415058)	87,40% (362757/415058)	86,48% (358569/414637)	86,96% (286175/329088)	85,46% (281235/329065)	89,07% (224941/252558)	88,79% (352691/397228)	84,45% (335445/397228)					
Wskaźnik kappa Kappa coefficient	0,8429	0,8310	0,8425	0,8248	0,8581	0,8634	0,8103					
Klasa Class	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.	Dokł. prod. Prod. acc.	Dokł. użyt. User acc.	Dokł. prod. Prod. acc.	Dokł. użyt. User acc.
#1	2393/2736	2393/3188	2406/2726	2265/2452	2265/2827	2265/2827	2265/2827	2265/2827	2123/3060	2123/3060	1990/2389	1990/3044
#2	2781/35453	2781/37439	27884/35554	24230/28977	24230/29375	22894/28041	22894/28041	22894/28041	28551/33856	28551/33856	26938/35856	26938/35566
#3	1893/1971	1893/3448	1788/3345	2293/2472	2293/3134	2293/3199	2293/3199	2293/3199	2646/3964	2646/3964	2571/4167	2571/4167
#4	3253/3340	3253/4781	3255/3340	4268/4567	4268/5398	4268/5419	4268/5419	4268/5419	3592/3830	3592/4698	3459/3830	3459/7663
#5	2009/2101	2009/2786	2009/2101	1348/1416	1348/2354	1348/1416	1348/2526	1348/2526	1994/2218	1994/2677	1679/2218	1679/2398
#7	2116/2333	2116/3211	2116/2333	2230/2329	2230/4193	2202/2160	2202/4160	2202/4160	2458/2727	2458/3255	2374/2727	2374/3671
#8	8098/9058	8098/10834	8098/9045	4116/4621	4116/5206	4120/5355	6356/6837	6356/6837	7054/7651	7054/8711	6842/7651	6842/9364
#9						463/471	463/695	463/695				
#10	47453/64786	47453/51237	47506/64747	46961/58164	46961/49512	45318/47925	45318/47925	45318/47925	45528/57837	45528/47823	42479/57837	42479/45226
#11				3181/3481	3181/3242	3181/3481						
#12			200/221	200/224	200/224	200/224						
#13	1593/1737	1593/2181	1395/1732	1542/1625	1542/3413	1542/1625	1542/3413	1542/3413	1624/1807	1624/1986	1325/1807	1325/1743
#14	1833/2230	1833/2866	1208/2219	2554/3248	2554/3174	2554/3174	2554/3174	2554/3174	2995/3576	2995/3576	2694/3576	2694/4519
#15	796/906	796/957	611/864	1015/1278	1015/1484	1015/1488	1015/1488	1015/1488	311/357	311/357	211/357	211/290
#16	6459/8478	6459/6845	5459/8395	6444/8212	6444/7730	6444/8212	6444/7869	6444/7869	7739/9221	7739/8452	7391/9221	7391/8326
#17	4371/5368	4371/5297	3697/5368	4667/4615	4667/5109	4667/4615	4667/5291	4667/5291	5273/7306	5273/7306	5027/7306	5027/7698
#18	1027/1196	1027/1396	1028/1196	906/1267	906/972	906/1267	906/972	906/972	1035/1267	1035/1428	965/1267	965/1424
#19	18892/22274	18892/24603	18863/22233	9452/12981	9452/10950	9452/12981	9452/11070	9452/11070	16709/18493	16709/20236	15847/18493	15847/20457
#20	311/327	311/365	202/234	1706/1899	1706/2561	1579/1899	1579/2476	1579/2476	1776/1933	1776/1994	1618/1855	1618/1855
#21				314/328	314/371	314/328	314/371	314/371	132/135	132/158	120/135	120/140
#22	798/932	798/989	690/932	1137/1252	1137/2016	1099/1252	1099/1973	1099/1973	1143/1252	1143/1361	1099/1252	1099/1363
#23	557/594	557/712	496/594	984/1046	984/1787	984/1046	984/1807	984/1807	888/1046	888/1041	765/1046	765/899
#24	4628/5640	4628/6308	4393/6113	5309/7207	5309/6274	5321/7207	5321/6523	5321/6523	6339/7892	6339/8905	5252/7892	5252/8630
#25	1389/1490	1389/2046	1328/1450	952/1107	952/1512	952/1107	952/1638	952/1638	1385/1479	1385/1979	1329/1479	1329/2137
#26	609/679	609/902	489/663	676/691	676/2195	676/691	676/2460	676/2460	641/704	641/788	543/704	543/675
#27				5248/6268	5248/6000	5250/6268	5250/6031	5250/6031	8149/10649	8149/9649	4049/10649	4049/5555
#28	598/713	598/752	459/713	1063/1285	1063/1575	1066/1285	1066/1638	1066/1638	639/733	639/883	647/733	647/904
#29	1001/1024	1001/1354	940/1024	4314/5528	4314/5528	4319/5528	4319/5458	4319/5458	1351/1758	1351/1721	1346/1758	1346/1996
#30	2405/2976	2405/4191	2225/2974	3597/4877	3597/4283	3597/4877	3597/4283	3597/4283	3445/3919	3445/5745	3243/3919	3243/6022
#31	1616/1891	1616/2275	1318/1891	1303/1594	1303/1706	1303/1594	1303/1706	1303/1706	1690/1891	1690/2835	1509/1891	1509/3157
#33	2318/2412	2318/3053	2329/2412	3263/3383	3263/5072	3237/3383	3237/5438	3237/5438	3163/3383	3163/4746	3187/3383	3187/5291
#34				1146/1339	1146/1191	1146/1339	1146/1191	1146/1191				
#35	4620/5451	4620/6414	4671/6907	4827/5930	4827/5834	4830/5930	4830/5912	4830/5912	5298/6101	5298/7622	4789/6101	4789/7512
#36	747/992	747/1014	631/992	3597/4877	3597/4283	3597/4877	3597/4283	3597/4283	1224/1559	1224/1721	1068/1559	1068/1727
#37	1083/1170	1083/1642	740/1170	762/801	762/2671	762/801	762/4075	762/4075	1081/1170	1081/2181	767/1170	767/1981
#38	155359/162120	155359/1654	155590/162116	11238/120284	11238/116839	11097/120284	11097/116462	11097/116462	143418/151607	143418/148205	142050/151607	142050/15008
#39	1172/1375	1172/1615	1174/1375	1235/1356	1235/1839	1235/1356	1235/1839	1235/1839	1272/1356	1272/1880	1220/1356	1220/2033
#40				1821/1899	1821/4869	1821/1899	1821/4893	1821/4893	1828/1905	1828/2126	1753/1905	1753/2295
#41	31437/38659	31437/52409	31437/38617	16469/16839	16469/16840	16469/16839	16469/16846	16469/16846	2557/26451	2557/26451	2557/26451	2557/26161
#42	22106/22696	22106/22527	22134/22696	16469/16839	16469/16840	16469/16839	16469/16846	16469/16846	18800/18879	18800/18879	18800/18879	18800/18879

Objaśnienia: dokł.prod. – dokładność producenta, dokł użyt. – dokładność użytkownika. Objasnienie jak w tabeli 22
Prod. acc. – producer accuracy, user acc. – user accuracy. Classes correspond with the table 22

Tabela 24. Analiza zmienności wyników klasyfikacji.
Table 24. Variability analysis of classification results.

Klasa Class	Wszystkie klasyfikacje All classifications									40 kanałów 40 bands									20 kanałów MNF 20 MNP bands											
	Średnia Average			Odchylenie standardowe Standard deviation			Średnia Average			Odchylenie standardowe Standard deviation			Średnia Average			Odchylenie standardowe Standard deviation			Średnia Average			Odchylenie standardowe Standard deviation			Max			Min		
	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.	Dokl. prod. acc.	użytk. User Prod.	Dokl. użytk. acc.			
#1	88,8	74,0	3,4	5,9	89,7	74,9	2,4	5,4	92,4	80,1	87,8	69,4	88,0	73,1	4,5	7,4	92,4	80,1	83,3	65,4										
#2	79,8	76,9	3,1	5,3	81,5	76,9	2,8	6,6	84,1	82,5	78,5	68,7	77,7	77,0	2,2	4,4	79,0	81,6	75,1	72,9										
#3	93,7	63,6	2,2	8,4	95,1	64,9	2,0	9,3	96,5	73,2	92,8	54,9	92,4	62,3	1,5	9,1	93,7	71,7	90,7	53,5										
#4	94,5	69,4	2,6	11,7	95,1	73,6	1,8	5,1	97,4	79,1	93,5	68,0	93,7	63,9	3,6	17,1	97,5	78,8	90,3	45,1										
#5	91,2	66,6	7,9	8,9	93,6	68,0	3,2	9,3	95,6	74,5	89,9	57,3	88,8	65,2	11,4	10,3	95,6	72,1	75,7	53,4										
#7	91,5	62,7	3,2	8,6	92,2	64,9	3,1	11,2	95,8	75,5	90,1	53,2	90,8	60,6	3,7	6,6	94,6	64,7	87,1	52,9										
#8	90,4	78,8	1,9	6,8	91,2	81,9	2,4	7,8	94,0	93,0	89,1	74,8	89,4	74,7	0,2	2,0	89,5	76,9	89,2	73,1										
#9	98,3	66,6			98,3	66,6			98,3	66,6	98,3	66,6					0,0	0,0	0,0	0,0										
#10	77,7	93,2	4,9	2,1	79,8	93,0	5,5	2,7	86,5	95,2	73,3	89,3	74,9	93,4	2,6	1,5	77,9	94,6	73,4	91,7										
#11	91,4	97,6	0,0	0,7	91,4	98,1			91,4	98,1	91,4	98,1	91,4	97,1			91,4	97,1	91,4	97,1										
#12	90,5	89,3	0,0	0,0	90,5	89,3			90,5	89,3	90,5	89,3	90,5	89,3			90,5	89,3	90,5	89,3										
#13	87,5	65,0	8,7	15,9	92,2	66,7	2,5	19,1	92,9	81,8	89,9	45,2	82,9	63,4	11,0	16,2	94,9	76,0	73,3	45,2										
#14	78,2	63,8	12,1	17,6	84,8	63,4	6,8	22,0	94,4	80,5	78,6	32,3	69,5	64,3	13,1	14,4	78,6	80,5	54,4	52,9										
#15	80,2	74,3	12,6	8,0	88,1	74,2	7,6	9,7	97,9	83,2	79,4	63,6	69,7	74,4	10,2	7,1	79,4	82,1	59,1	68,2										
#16	79,0	87,5	7,8	6,6	82,3	86,7	6,4	7,6	90,6	94,4	76,2	77,6	74,6	88,4	8,3	6,4	80,2	94,7	65,0	81,9										
#17	80,2	81,5	11,4	9,8	84,1	84,1	11,7	8,9	95,0	91,4	68,8	72,2	74,9	77,9	10,5	11,7	87,0	88,3	68,9	65,3										
#18	81,2	79,4	8,7	10,7	83,6	80,8	9,9	9,8	95,4	93,2	71,5	72,5	77,9	77,5	7,4	13,7	86,0	93,2	71,5	67,8										
#19	83,1	81,9	7,4	5,0	84,5	83,5	8,2	5,1	90,4	88,4	72,8	76,8	81,1	79,7	7,2	5,0	85,7	85,4	72,8	76,2										
#20	84,2	79,7	12,0	11,3	92,3	80,3	2,7	12,0	95,1	89,1	89,8	66,6	76,2	79,1	12,5	13,3	83,7	87,2	61,8	63,8										
#21	94,5	84,6	3,9	0,9	96,8	84,1	1,4	0,8	97,8	84,6	85,6	85,6	92,3	85,2	4,8	0,8	95,7	85,7	88,9	84,6										
#22	86,2	72,1	6,3	12,7	89,2	73,7	3,1	15,1	91,3	84,0	85,6	56,4	83,2	70,5	7,9	13,1	87,8	80,6	74,0	55,7										
#23	87,2	70,9	8,4	14,1	90,9	72,9	5,2	15,8	94,1	85,3	84,9	55,1	83,6	69,0	10,5	15,4	94,1	85,1	73,1	54,5										
#24	77,9	73,4	7,7	7,8	81,8	74,8	7,1	6,7	91,0	84,6	73,7	70,0	72,9	71,4	5,9	10,4	78,2	81,6	66,6	60,9										
#25	90,4	64,4	4,0	4,3	91,8	66,9	5,1	3,6	95,8	70,0	86,0	63,0	89,0	61,9	2,8	3,8	91,6	65,8	86,0	58,1										
#26	87,9	58,6	10,3	23,8	92,9	59,9	4,4	26,1	97,8	81,4	89,7	30,8	82,9	57,2	13,0	27,1	97,8	80,4	73,8	27,5										
#27	70,5	83,0	21,9	6,8	80,1	86,0	5,1	2,1	83,7	87,5	76,5	84,5	60,9	80,0	32,3	10,0	83,8	87,1	38,0	72,9										
#28	80,9	75,0	11,2	3,7	85,5	75,9	2,3	5,1	87,2	79,5	83,9	72,4	76,3	74,0	16,9	3,5	88,3	76,5	64,4	71,6										
#29	86,3	73,7	8,1	8,5	87,8	77,4	9,3	9,4	97,8	89,8	76,9	67,5	84,2	68,6	7,6	4,3	91,8	73,4	76,6	65,1										
#30	79,9	63,2	4,9	13,4	81,8	66,0	5,7	12,7	87,9	80,6	76,7	57,4	78,1	60,5	4,1	16,4	82,8	79,1	74,8	48,5										
#31	81,1	65,3	6,1	10,5	84,2	66,5	4,1	8,6	89,4	76,4	80,1	59,1	77,1	63,6	6,5	14,5	81,7	76,4	69,7	47,8										
#33	95,9	66,3	1,7	6,4	96,2	67,5	2,2	5,8	98,8	75,9	93,5	63,3	95,5	64,5	1,2	8,1	96,6	73,9	94,2	59,5										
#34	85,6	96,2			85,6	96,2			85,6	96,2	85,6	96,2	85,6	96,2			85,6	96,2	85,6	96,2										
#35	85,2	69,7	6,4	11,0	87,8	68,7	7,2	13,4	98,1	82,7	81,4	50,5	81,9	71,0	3,6	9,4	85,7	81,7	78,5	63,8										
#36	68,6	75,2	5,0	6,9	72,1	78,1	3,0	4,4	75,3	84,0	68,4	73,7	63,9	71,2	2,0	8,5	66,0	78,5	62,1	61,8										
#37	82,6	44,7	14,2	17,1	88,5	48,7	9,2	15,5	94,3	66,0	74,7	28,3	74,6	39,3	17,8	20,9	95,1	60,4	63,3	18,7										
#38	94,0	94,7	1,6	1,6	93,9	94,8	1,7	2,1	93,8	96,8	91,8	92,1	94,1	94,6	1,9	1,0	96,0	95,3	92,3	93,4										
#39	89,4	67,7	3,4	4,5	90,0	69,1	4,4	3,0	93,8	72,6	85,2	67,2	88,8	66,3	3,0	6,0	91,1	71,9	85,4	60,0										
#40	94,9	59,2	1,9	25,6	95,9	61,7	0,0	34,4	96,0	86,0	95,9	37,4	94,0	56,8	2,7	27,7	95,9	76,4	92,0	37,2										
#41	81,7	96,4	3,8	0,5	83,3	96,4	3,8	0,6	87,7	97,0	80,9	96,0	79,3	96,6	3,0	0,6	81,4	97,0	77,2	96,2										
#42	97,5	98,2	0,7	0,6	97,6	98,4	0,8	0,8	98,7	99,6	96,7	97,8	97,4	97,9	0,5	0,1	97,8	98,0	96,8	97,8										
Średnia Average	86,0	75,1	6,4	8,5	88,6	76,4	4,6	9,4	92,8	84,2	84,1	67,5	82,6	73,8	7,2	9,7	86,1	79,9	74,7	63,7										

Dokl.prod. – dokładność producenta, dokl. użyt. – dokładność użytkownika
Prod.acc. – producer accuracy, User acc. – user accuracy

Tabela 25. Dokładność klasyfikacji (%) roślinności Tatr w aspekcie przestrzennej kompleksowości poligonów (Kozłowska, 2006)
 Table 25. Classification accuracy (%) according to spatial content of vegetation patches (Kozłowska, 2006)

Zawartość poligonu Content of patch	Wszystkie klasyfikacje All classification				40 kanałów Fourt-band set						20 kanałów MNF Twenty-MNF-band set					
	Średnia Average		Odchylenie Standardowe		Średnia Average		Max		Min		Średnia Average		Max		Min	
	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.	Dokł. prod. Prod. acc.	Dokł. użytk. User acc.
a	88,2	77,4	4,8	7,9	90,3	78,2	94,1	86,2	87,2	70,5	84,3	77,4	80,2	76,7	72,7	64,1
b	86,5	67,2	7,1	11,1	90,0	68,9	93,0	79,4	85,2	54,7	82,6	65,4	89,7	75,9	75,0	53,1
c	86,0	63,7	7,1	13,0	90,0	64,2	95,5	76,9	85,7	43,6	81,0	63,3	86,2	76,1	72,6	53,2
d	86,9	73,6	6,2	8,9	89,5	74,9	93,5	82,9	85,6	65,5	83,4	72,3	85,7	77,7	74,4	61,1
e	84,8	75,7	6,7	8,7	87,7	77,0	92,6	85,4	82,6	67,8	81,4	74,2	87,2	82,6	75,6	65,9

a – zbiorowisko homogeniczne, b – kompleks typologiczny, c – kompleks dynamiczny, d – kompleks ekologiczny, e – kompleks topograficzny
 a – homogeneous community, b – typological complex, c – dynamic complex, d – ecological complex, e – topographic complex

jest graficzną ilustracją najlepszych wyników klasyfikacji 40 oryginalnych kanałów DAIS 7915 po 5000 iteracji.

Najmniejszą zmiennością uzyskanych wyników klasyfikacji (analizując wszystkie linie zobrazowania) cechowała się woda (#42). Odchylenie standardowe dokładności producenta i użytkownika nie przekroczyło 1%. Minimalnie gorsze wyniki zanotowano dla zarośli kosodrzewiny na podłożu bezwęglanowym (#38). W tym przypadku odchylenie standardowe wahało się w zakresie 1,0-2,1%. Zmiennością w przedziale 2-7 % charakteryzowały się: zbiorowiska porostów naskalnych (#2), fragmenty muraw alpejskich na półkach skalnych (#10), torfowiska przejściowe (#21), traworośla trzcinnikowe postać pionierska (#25), wysokogórskie borówczyska (#33), kępy kosodrzewiny na ścianach skalnych (#39) oraz bór górnoreglowy (#41).

Największą zmiennością uzyskanych wyników charakteryzowały się zarośla kosodrzewiny na podłożu węglanowym (#40), gdzie odchylenie standardowe wyniosło 25,6%, nieco lepsze wyniki obliczono dla traworośli trzcinnikowych w kompleksie z wilgotnymi murawami (#26) oraz w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi (#27). Ponadto murawy alpejskie: postać piargowa z sitem skuciną (#14) i na podłożu węglanowym (#20) oraz zbiorowiska zaroślowe wierzby śląskiej i malin (#37) osiągnęły dokładności wokół kilkunastu procent (11-18%).

Warto raz jeszcze podkreślić fakt, że klasyfikacja zestawu danych składających się z 40 oryginalnych kanałów pozwoliła uzyskać nieznacznie lepsze dokładności w porównaniu do zestawu danych MNF, średnio było to o 3% więcej.


Jedną z istotnych kwestii badawczych było ustalenie, czy pochodzenie i struktura płatów roślinności ma wpływ na jakość klasyfikacji. Aby uzyskać odpowiedź na to pytanie wykonano korelację wyników klasyfikacji uzyskanych z tabeli 24 z informacjami geobotanicznymi o poszczególnych zbiorowiskach (Kozłowska, 2006). Pochodzenie roślinności analizowane było w sześciu klasach: zbiorowiska naturalne, naturalne/pólnaturalne, pólnatu-

ralne/naturalne, pólnaturalne, pólnaturalne/synantropijne oraz synantropijne (Kozłowska, 2006). Każdej klasie nadano rangę z zakresu wartości 1-6 (1 – zbiorowiska naturalne, 6 – synantropijne). Uzyskany współczynnik korelacji wyniósł – 0,3. Ujemna wartość wskaźnika potwierdza, że wzrost dokładności klasyfikacji obserwuje się dla naturalnych zbiorowisk, natomiast niewielka wartość współczynnika oznacza, że korelacja nie jest silna. Należy jednak pamiętać, iż badany obszar jest parkiem narodowym i od wielu dziesięcioleci znajduje się pod ochroną. Ogranicza to działalność gospodarczą człowieka, skutkując brakiem roślinności silnie zmienionej antropogenicznie. Dotyczy to także wypasu owiec, który na wielu terenach został zaniechany lub silnie ograniczony.

Kolejnym analizowanym elementem była struktura zbiorowisk. Zgodnie z wydzieleniami opracowanymi przez A. Kozłowską (2006) za P. Seibertem (1974), na potrzeby niniejszych analiz korelacji wydzielono następujące klasy struktury poligonów roślinnych: 1) homogeniczne, 2) homogeniczne z kompleksami dominacji, 3) kompleksy dominacji, 4) kompleksy dominacji z kompleksami strefowości, 5) kompleksy dominacji z mozaikowymi kompleksami, 6) kompleksy strefowości, 7) mozaikowe kompleksy. Uzyskany współczynnik korelacji (– 0,2) wskazuje, że poligony o homogenicznej strukturze klasyfikowały się nieco lepiej niż mozaikowe kompleksy.

Najlepsze wyniki uzyskano jeśli chodzi o dokładność klasyfikacji i analizę zawartości poligonów, definiowanej według A. Kozłowskiej (2006) za P. Seibertem (1974): 1) zbiorowiska homogeniczne, 2) kompleksy typologiczne, 3) kompleksy dynamiczne, 4) kompleksy ekologiczne, 5) kompleksy topograficzne²². Współczynnik korelacji

²² Kompleksy typologiczne zawierają różne zbiorowiska należące do tej samej lub wyższej jednostki. Kompleksy dynamiczne cechują się tymi samymi etapami sukcesji lub należą do tych samych kręgów klimaksowych. Kompleksy ekologiczne charakteryzują specyficzne cechy ekologiczne, np. wilgotność siedliska. Kompleksy topograficzne są powiązane z określoną lokalizacją i zawierają zbiorowiska porastające powierzchnie zbyt małe by przedstawić je w skali danej mapy.



Ryc. 36. Średnia dokładność klasyfikacji 40 kanałów DAIS 7915. Klasy: 1 pionierskie zbiorowiska roślin zarodnikowych; 2 zbiorowiska porostów naskalnych; 3 pionierskie zbiorowiska roślin naczyniowych na wilgotnych piargach; 4 wilgotne traworośla kosmatkowe; 5 wyleżyska w piętrze alpejskim; 6 wyleżyska w piętrze subalpejskim; 7 murawa subniwalna; 8 murawa alpejska typowa; 9 murawa alpejska porostowa; 10 fragmenty muraw alpejskich na półkach skalnych; 11 murawa alpejska torfowcowa; 12 murawa alpejska wyleżyskowa; 13 murawa alpejska z wierzbą Kitaibela; 14 murawa alpejska postać piargowa z sitem skucina; 15 murawa alpejska z turzycą zawsze zieloną; 16 murawa alpejska postać subalpejska; 17 murawa alpejska w kompleksie z wyleżyskami; 18 murawa alpejska w kompleksie z traworoślami; 19 kompleks przestrzenny muraw alpejskich na podłożu granitowym i mylonitach; 20 murawa alpejska na podłożu węglanowym; 21 torfowisko przejściowe; 22 wilgotne psiary; 23 wilgotne psiary w kompleksie z ziołoroślami; 24 traworośle trzcinnikowe; 25 traworośle trzcinnikowe postać pionierska; 26 traworośle trzcinnikowe w kompleksie z wilgotnymi murawami; 27 traworośle trzcinnikowe w kompleksie z zaroślami kosodrzewiny i murawami subalpejskimi; 28 ziołorośla; 29 wilgotne murawy w kompleksie z wyleżyskami i ziołoroślami; 30 murawy powypasowe świeże i suche; 31 murawy powypasowe wilgotne; 32 murawy powypasowe, fragmenty silnie zantropogenizowane; 33 wysokogórskie borówczyska bażynowe; 34 wysokogórskie borówczyska bażynowe w kompleksie z zaroślami kosodrzewiny; 35 zbiorowiska borówki czernicy w kompleksie z zaroślami kosodrzewiny; 36 zbiorowiska borówki czernicy w kompleksie z traworoślami i ziołoroślami; 37 zbiorowiska zaroślowe wierzby śląskiej i malin; 38 zarośla kosodrzewiny na podłożu bezwęglanowym; 39 kępy kosodrzewiny na ścianach skalnych; 40 zarośla kosodrzewiny na podłożu węglanowym; 41 bór górnoregłowy; 42 woda

Fig. 36. Average classification accuracy of the forty-band set of DAIS7915 image. Classes: 1 cryptogamic plant communities on scree – initial phase; 2 epilithic lichen communities – Rhizocarpetalia; 3 scree communities – Androsacetalia alpinae; 4 Luzuletum alpino-pilosae; 5 Salicetum herbaceae, Luzuletum spadiceae; 6 Salicetum herbaceae in a complex with Empetro-Vaccinietum; 7 subnivale swards – Oreochloa distichae-Juncetum trifidi subnivale form; 8 Oreochloa distichae-Juncetum trifidi typicum; 9 Oreochloa distichae-Juncetum trifidi cetrarietosum; 10 Oreochloa distichae-Juncetum trifidi – vegetation fragments on rocky shelves; 11 Oreochloa distichae-Juncetum trifidi sphagnetosum; 12 Oreochloa distichae-Juncetum trifidi salicetosum herbaceae; 13 Oreochloa distichae-Juncetum trifidi salicetosum kitaibeliana; 14 Oreochloa distichae-Juncetum trifidi scree form with Juncus trifidus; 15 Oreochloa distichae-Juncetum trifidi caricetosum sempervirens; 16 Oreochloa distichae-Juncetum trifidi subalpine anthropogenic form; 17 Oreochloa distichae-Juncetum trifidi in a complex with snow-bed communities; 18 Oreochloa distichae-Juncetum trifidi in a complex with Calamagrostietum villosae; 19 Oreochloa distichae-Juncetum trifidi in a complex with Festuco versicoloris-Agrostietum; 20 Festuco versicoloris-Agrostietum; 21 Caricetum fuscae subalpinum; 22 Sphagno-Nardetum, Polytricho-Nardetum; 23 Sphagno-Nardetum, Polytricho-Nardetum in a complex with Caltha laeta community; 24 Calamagrostietum villosae taticum; 25 Calamagrostietum in a complex with Luzuletum alpino-pilosae pioneer form; 26 Calamagrostietum in a complex with wet subalpine meadows; 27 Calamagrostietum in a complex with Pinetum mugho and subalpine meadows; 28 tall herb communities – Adenostylon; 29 Festuca picta community in a complex with Luzuletum alpino-pilosae; 30 Festuca picta community; 31 Deschampsia flexuosa community, Hieracio alpini-Nardetum; 32 grassland communities after grazing in a complex with ruderal communities; 33 Empetro-Vaccinietum; 34 Empetro-Vaccinietum in a complex with Pinetum mugho; 35 Vaccinium myrtillus community in a complex with Pinetum mugho carpaticum silicicolum; 36 Vaccinium myrtillus community in a complex with tall herb communities; 37 willow thicket – Chamaenerion angustifolium-Salix silesiaca community; 38 mountain-pine scrub on silicate substrate – Pinetum mugho carpaticum silicicolum; 39 mountain-pine scrub – Pinetum mugho carpaticum silicicolum in a complex with epilithic lichen communities; 40 mountain-pine scrub on calcareous substrate – Pinetum mugho carpaticum calcicolum; 41 montane spruce forest – Plagiothecio-Piceetum; 42 water

dla wszystkich klasyfikacji wyniósł $-0,4$. Zbiorowiska homogeniczne uzyskały najwyższą średnią dokładność we wszystkich klasyfikacjach (dokładność producenta 88,2% i dokładność użytkownika 77,4%) oraz najniższe odchylenia standardowe (tab. 25). Podobnie najwyższe

średnie wartości zaobserwowane zostały dla klasyfikacji 40 oryginalnych oraz 20 kanałów MNF. Nawiększe odchylenia standardowe oraz stosunkowo najniższe wyniki klasyfikacji uzyskały zbiorowiska kompleksów typologicznych i dynamicznych.

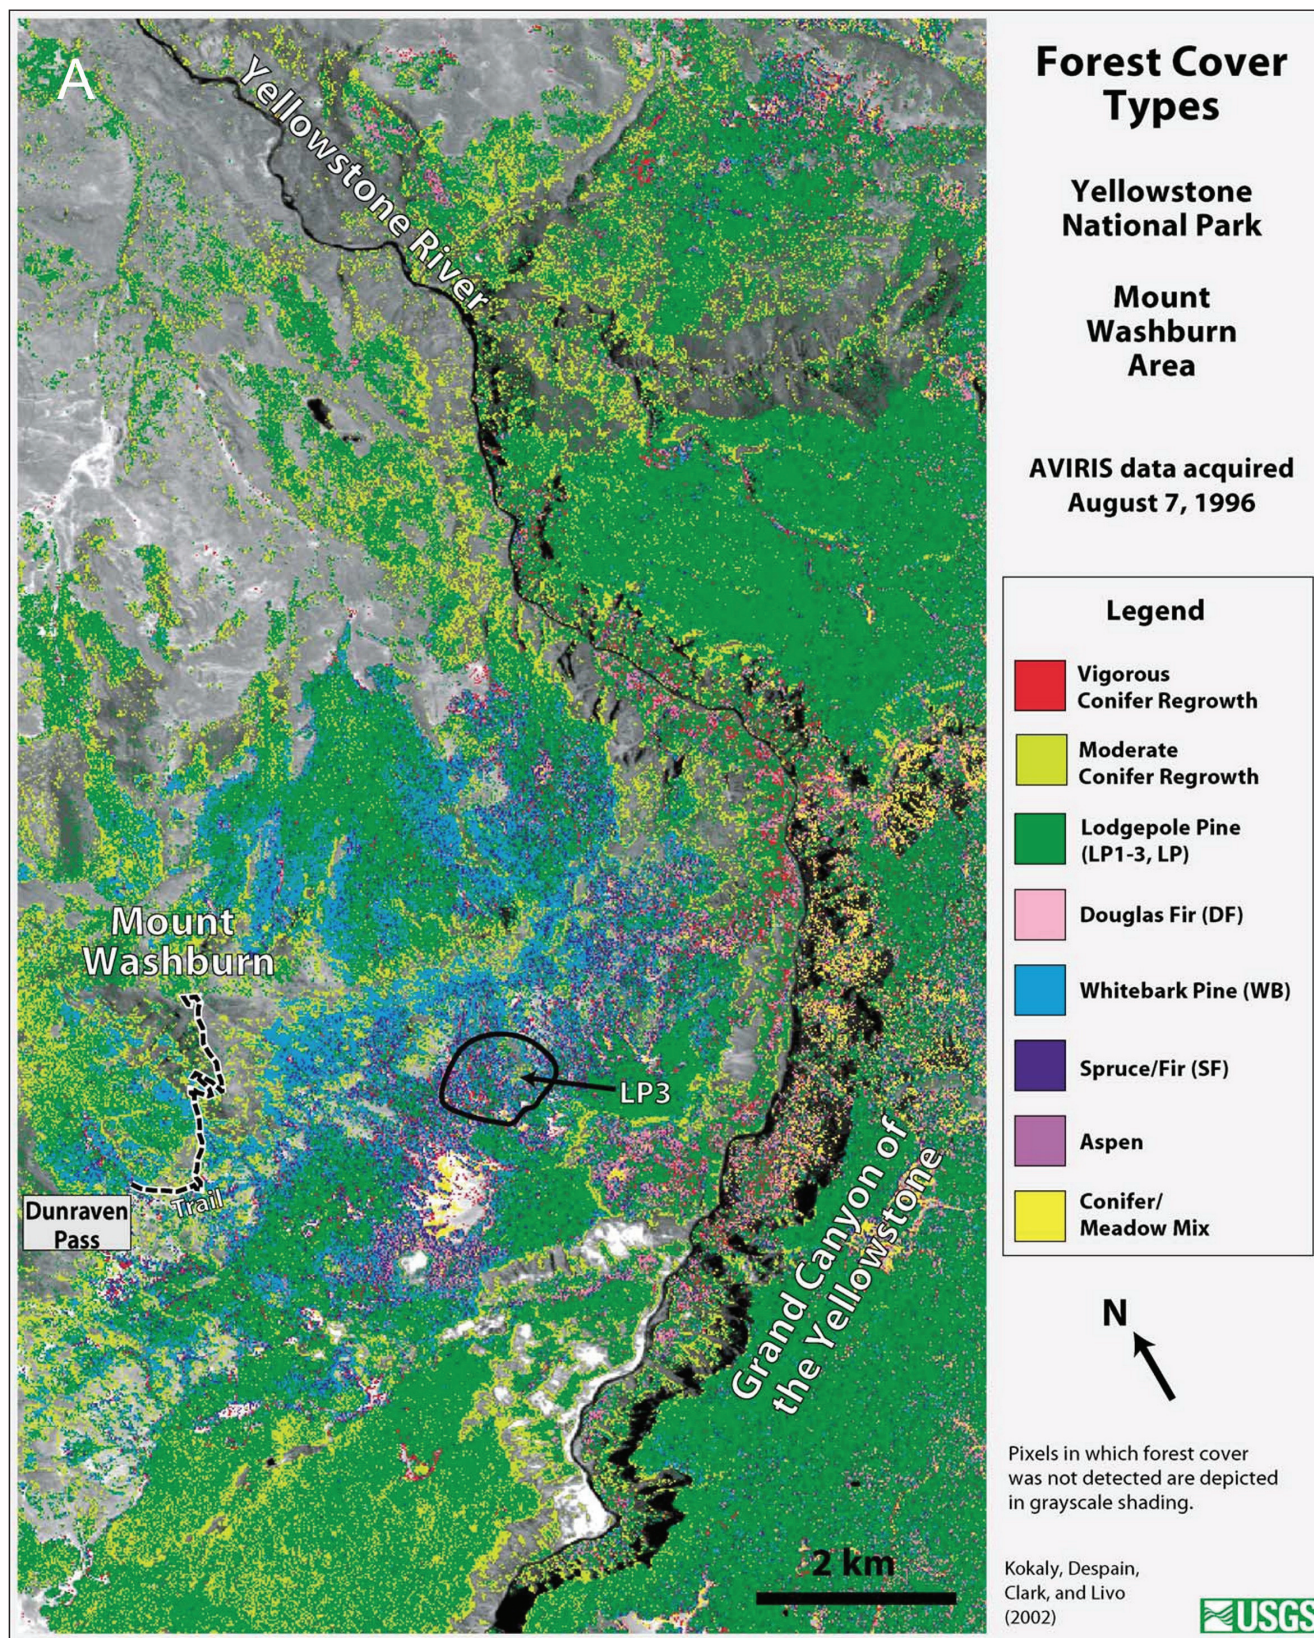
Zastosowania danych hiperspektralnych do klasyfikacji roślinności

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 (foton), 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 kilkaset tysięcy 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 równoległe 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. Filippiego 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 wydmami 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 wydmowa (*Pinus contorta*), Douglas fir – daglezja (*Pseudotsuga menziesii*), Whitebark pine – sosna *Pinus albicaulis*, Spruce/fir – świerk/jodła, 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)

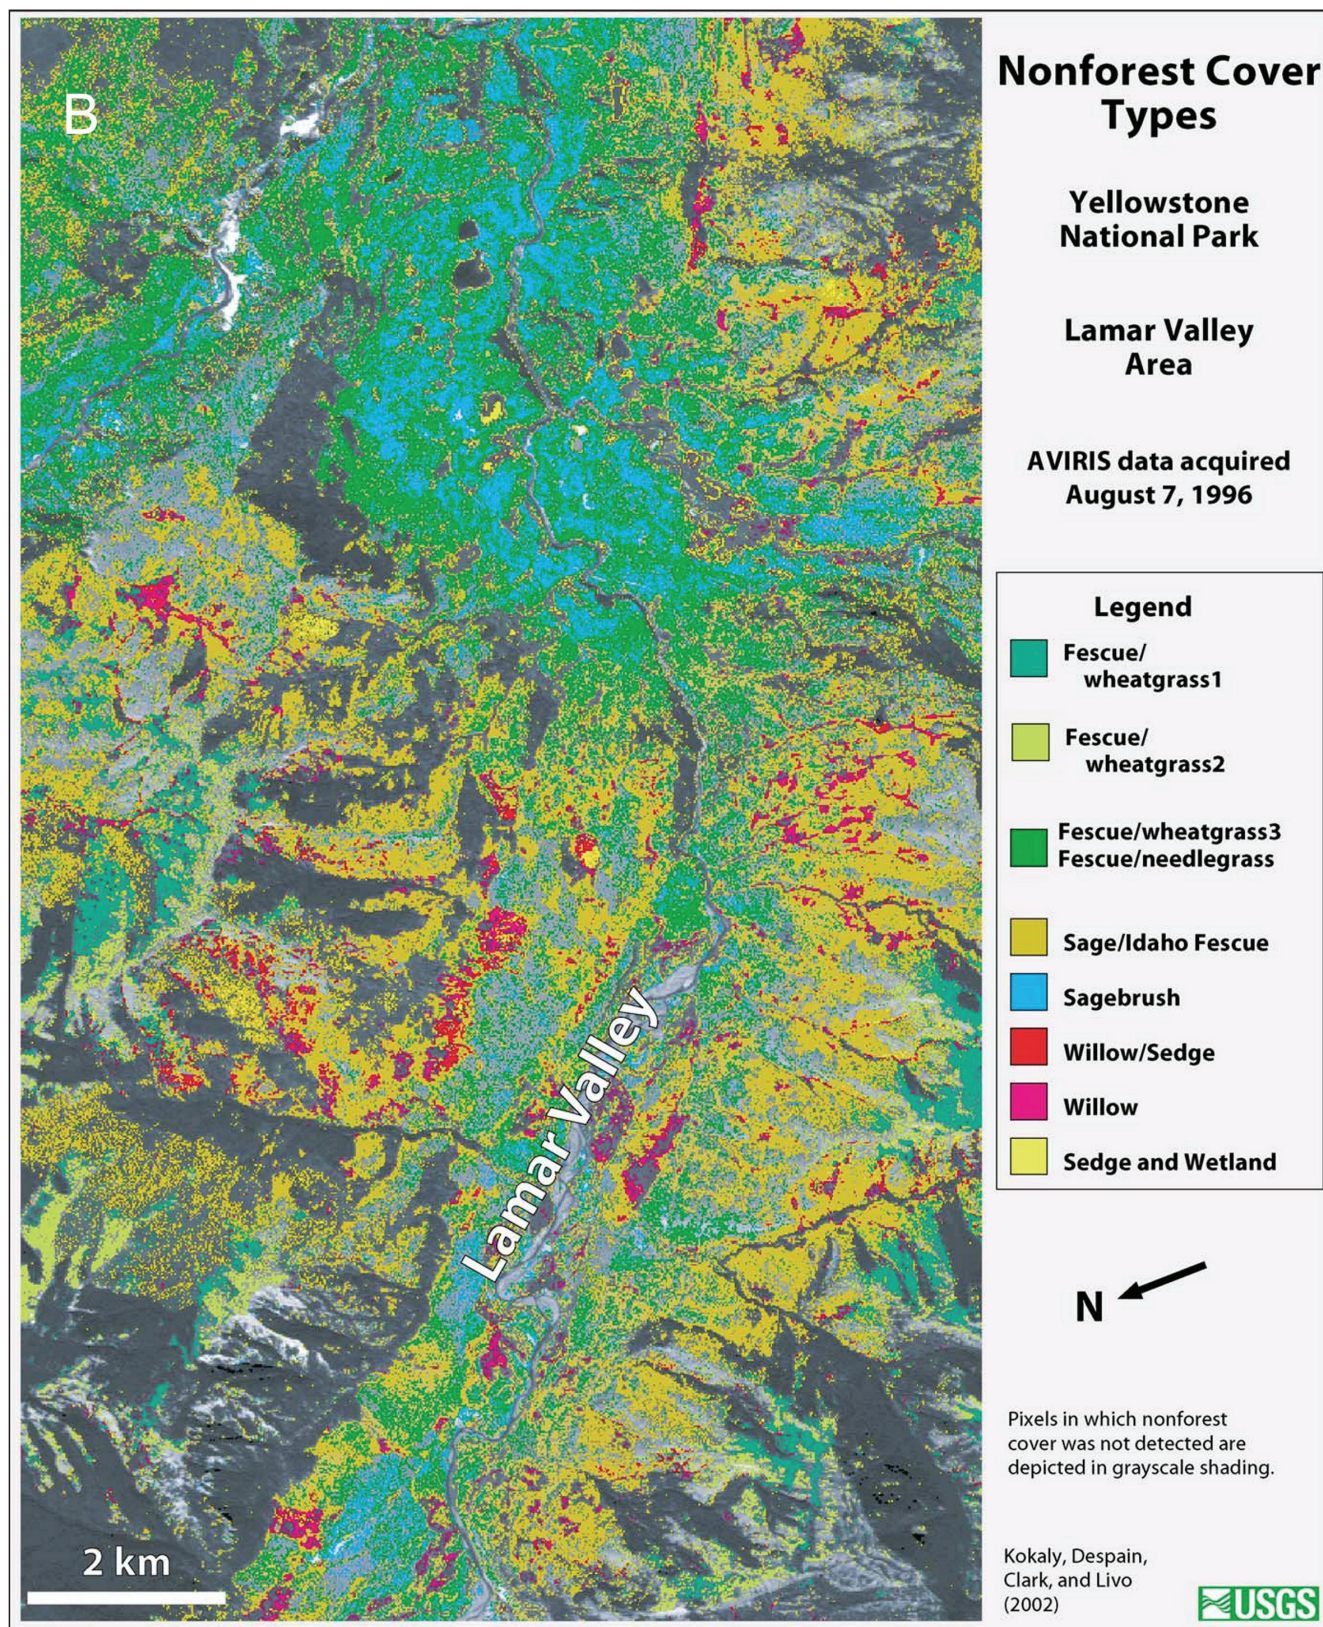
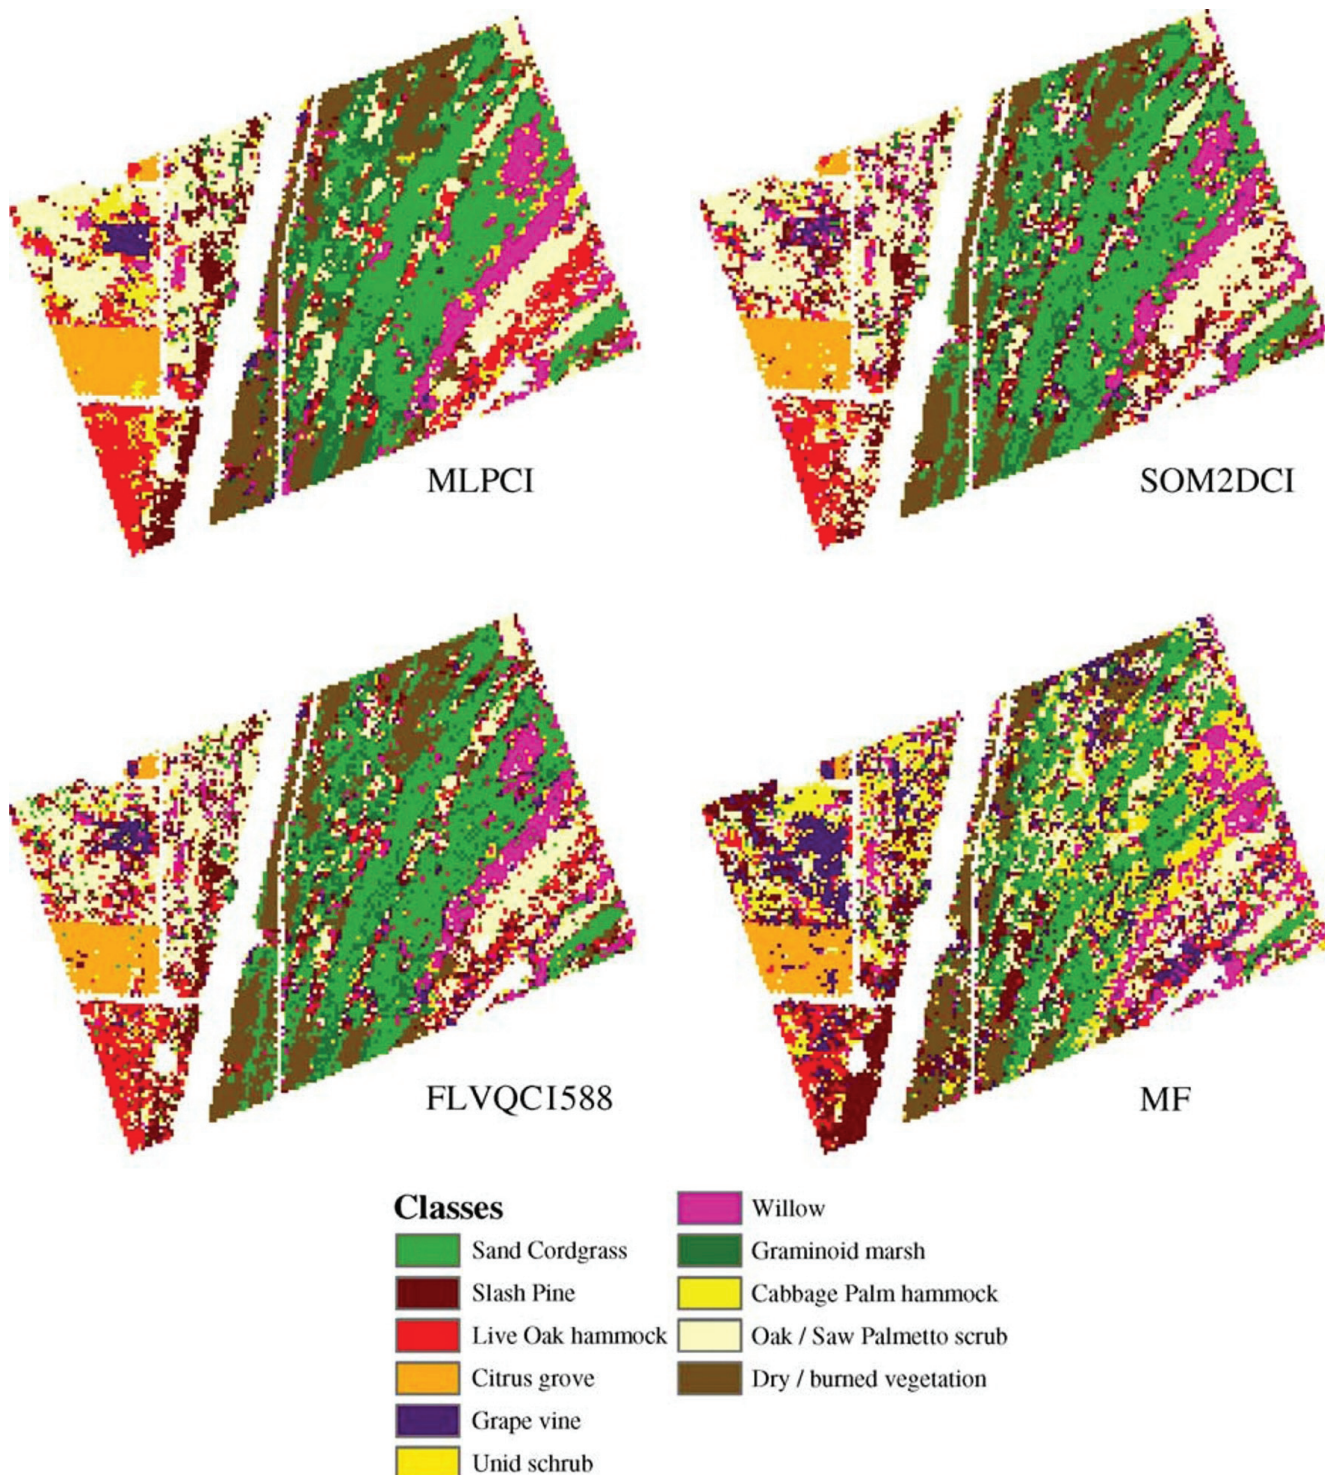


Fig. 37. The maps of: A – mountain forest cover of Mount Washburn area, B – nonforest cover of Lamar Valley (source: Kokaly et al., 2003)

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	
	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.
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	
<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.



Ryc. 39. Klasyfikacja roślinności półpustynnej Namibii na podstawie danych HyMAP (źródło: Oldeland i inni, 2010, zmodyfikowane)
 Fig. 39. Semidesert of Namibia vegetation classification's results of the HyMAP data (source: Oldeland et al., 2010, modified)



Ryc. 40. Wynik klasyfikacji upraw rolnych na podstawie obrazów hiperspektralnych HyMAP (źródło: Mader i inni, 2006, zmodyfikowane)
 Fig. 40. Crop classification of the HyMAP data (source: Mader et al., 2006, modified)

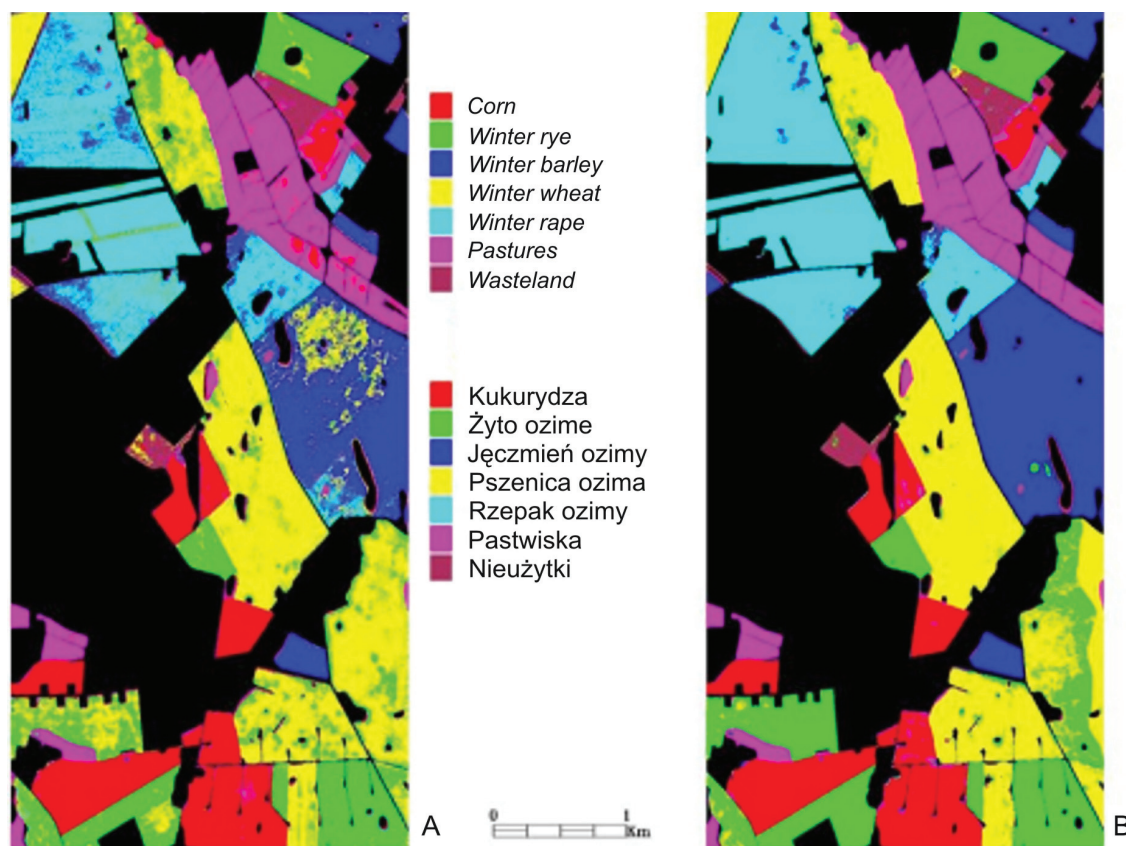
Tabela 27. Macierz transformacji klasyfikacji 15 kanałów MNF zobrazowania HyMAP

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 <i>a-corn</i>	69859	514	2	59	5	21	19	70479	19782	90,8
b-żyto ozime <i>b-winter rye</i>	108	75321	386	21732	32	143	246	97968	23030	93,5
c-jęczmień ozimy <i>c-winter barley</i>	215	309	89067	981	3073	54	381	94080	88333	98,3
d-pszenica ozima <i>d-winter wheat</i>	342	2862	5	143115	179	227	513	147243	125068	85,3
e-rzepak ozimy <i>e-winter rape</i>	351	400	171	268	116221	46	355	117812	132547	96,3
f-pastwiska <i>f-pastures</i>	5019	643	522	1276	874	64937	898	74169	129732	98,0
g-nieuzytki <i>g-wasteland</i>	1012	472	436	396	248	864	13847	17275	9376	85,2
Zestaw weryfikujący <i>Total ground. truth</i>	76906	80521	90589	167827	120632	66292	16259	619026	Dokładność całkowita = 92,5% <i>Overall accuracy = 92.5%</i>	
Dokł. użyt. <i>User acc. %</i>	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.



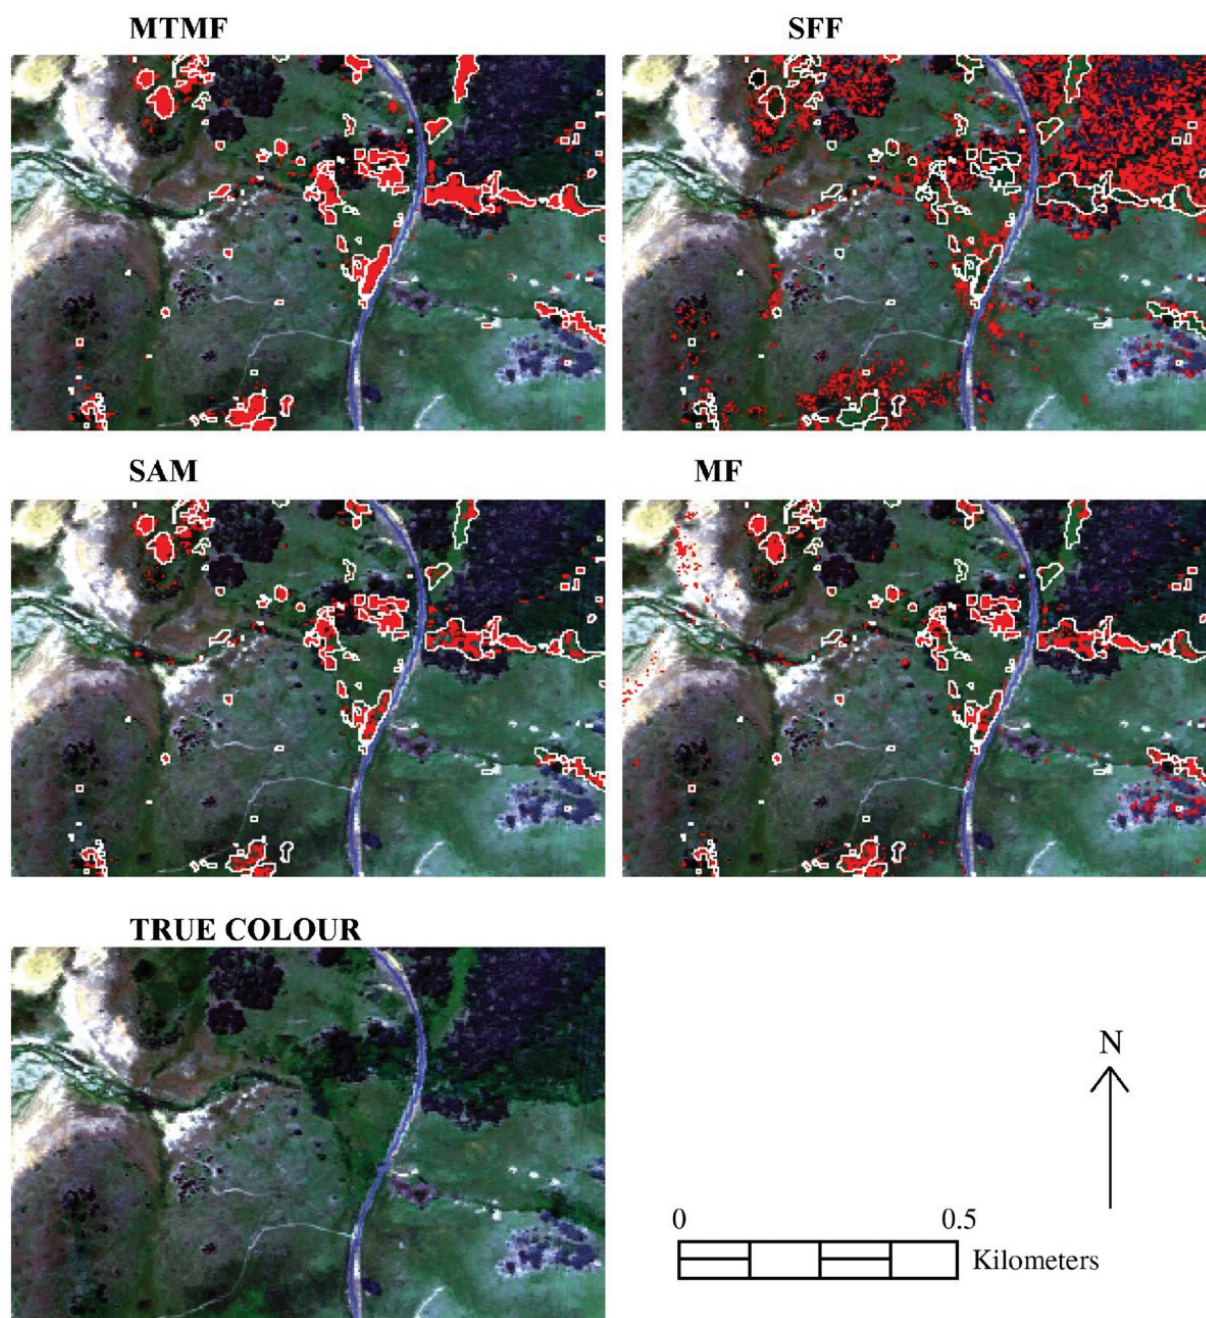
Ryc. 41. Wynik klasyfikacji upraw rolniczych symulatorem sztucznych sieci neuronowych SNNS danych HyMAP: A – z wykorzystaniem wskaźników roślinnych, B – 15 kanałów MNF (źródło: Olesiuk i inni, 2009, zmodyfikowane)

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)

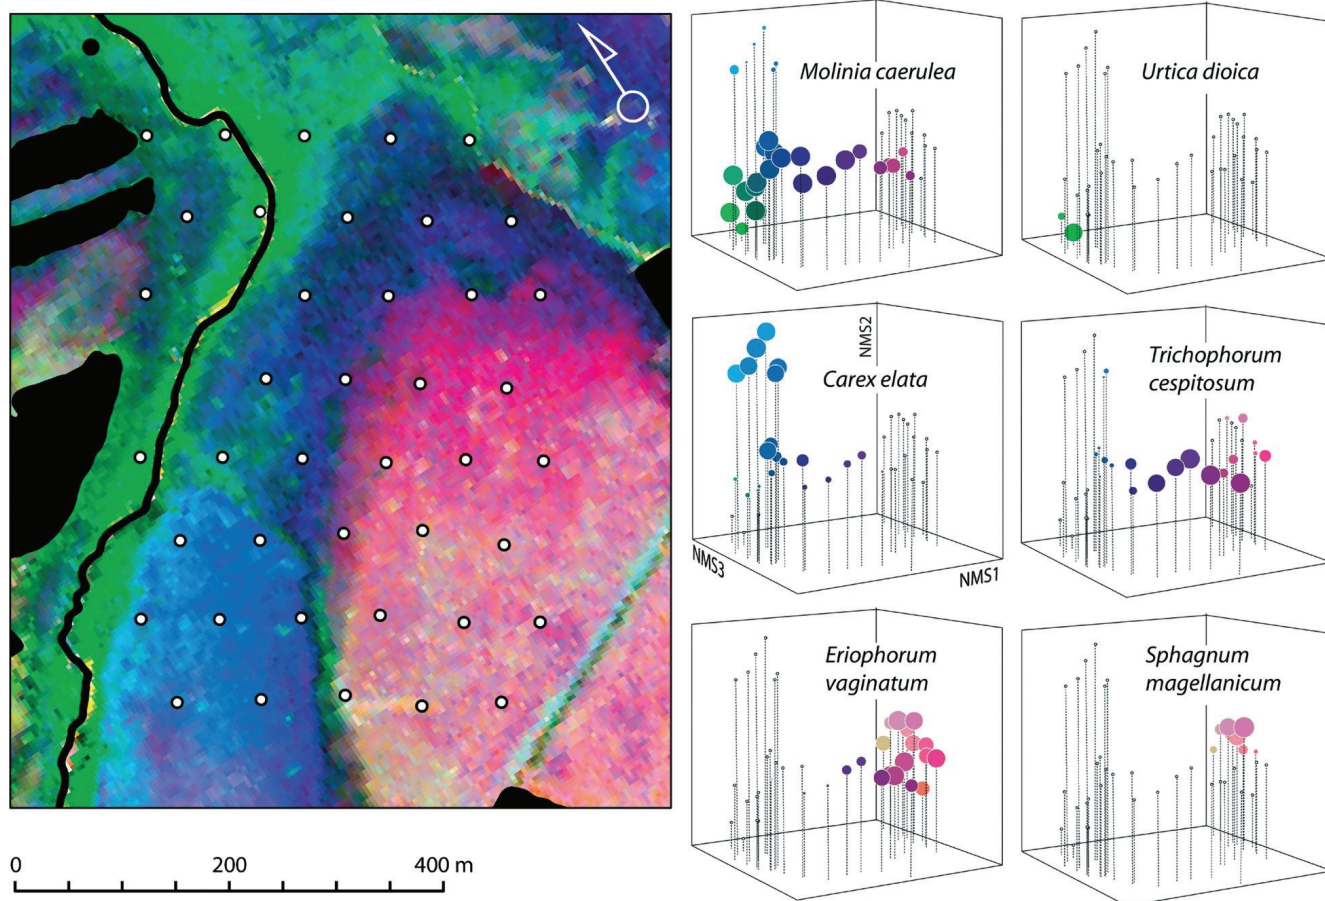
Powyższe wyniki znajdują potwierdzenie w pracach D. Olesiuka wykonanych w ramach stypendium DBU w DLR Oberpfafenhoffen (Olesiuk i inni, 2009). Autor przeanalizował dane HyMAP z rolniczego obszaru Demmin (północno-wschodnie Niemcy). Do klasyfikacji wykorzystał symulator SNNS, a jako dodatkowe warstwy 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 Euclidian 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 satelitar-nych 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 chabra *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 rozmieszania 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*.

Podsumowanie

Zaproponowana metoda klasyfikacji wysokorozdzielczych danych hiperspektralnych – cechujących się ciągłym widmem elektromagnetycznym w całym zakresie spektrum (VIS-SWIR) – zapisanych w dużej liczbie stopni szarości, pozwoliła na klasyfikację roślinności Tatr Wysokich. Istota zaproponowanego algorytmu polegała na:

- 1) eliminacji błędów wynikających z ruchu samolotu podczas rejestracji (parametryczna korekcja geometryczna);
- 2) eliminacji wpływu atmosfery i rzeźby terenu na obrazy (korekcja atmosferyczna);
- 3) eliminacji najmniej informacyjnych kanałów zobrażenia DAIS 7915;
- 4) terenowego przygotowania wzorców do uczenia sieci neuronowych oraz wzorców do weryfikacji danych poklasyfikacyjnych;
- 5) wykonaniu kilku wstępnych klasyfikacji w celu optymalnego doboru parametrów wejściowych symulatora sieci neuronowych;
- 6) wykonaniu właściwych klasyfikacji;
- 7) opracowaniu statystyk poklasyfikacyjnych;
- 8) końcowym przygotowaniu map poklasyfikacyjnych.

Jednym z ważniejszych osiągnięć pracy jest porównanie jakości klasyfikacji skompresowanych (transformacja MNF) oraz oryginalnych danych. Na uwagę zasługuje także analiza spadku błędu klasyfikacji wraz ze wzrostem liczby klasyfikowanych kanałów oraz liczby iteracji (ryc. 26).

Użycie sieci neuronowych, a w szczególności analiza danych rozmytych pozwoliła wykorzystać obok cech parametrycznych (np. jasność, odpowiadającą fototonowi danego piksela) – cechy nieparametryczne obrazu (struktura i tekstura, sąsiedztwo innych obiektów). Dzięki temu układ analityczny symulatora jest zasilany dodatkowymi, ważnymi informacjami – poszczególne

obiekty występujące w środowisku cechują się powtarzalnymi przestrzennie układami, np. sąsiedztwo, współwystępowanie innych obiektów (takich jak cienie, woda wokół zbiorowisk hydrofilnych, czy skały wokół porostów naskalnych). W zdecydowanej większości standardowych klasyfikacji cech nieparametryczne są pomijane, gdyż podczas klasyfikacji wykorzystuje się odległości spektralne od zadanego piksela, pełniące rolę wzorca.

Zaletą symulatorów sztucznych sieci neuronowych jest to, że potrafią wyeliminować ze wzorca danej klasy błędne sygnały (np. pojedyncze drzewa, kamienie). Jest to przydatne na etapie analizy wzorców i prowadzenia pierwszych iteracji klasyfikacji. Na obszarach heterogenicznych, gdzie występuje silne mieszanie sygnałów pochodzących od różnych spektralnie obiektów, możliwe staje się szybkie odseparowanie właściwych sygnałów i wykonanie właściwej klasyfikacji.

Dzięki wykonanej korekcji atmosferycznej, możliwe było porównywanie sygnałów poszczególnych obiektów na różnych obrazach lotniczych z rejestrowanymi na poziomie terenu. Dodatkowa korekcja dwukierunkowości odbicia promieniowania (BRDF) pozwala na porównywanie sygnałów odbitych z różnych ekspozycji i nachylenia terenu. Takie działania należy uznać za istotne w analizie obszarów wysokogórskich. Zastosowanie Numerycznego Modelu Terenu (NMT) w klasyfikacji dostarczyło informacje o położeniu zbiorowisk roślinnych w piętrach wysokościowych, co ułatwiło ich prawidłową identyfikację.

Dane wzorcowe i referencyjne zostały pozyskane w trakcie badań terenowych. Do stworzenia wzorca weryfikującego dokładność klasyfikacji wykorzystano metodę klasyfikacji SAM, która pozwoliła na wybór obszarów najbardziej zbliżonych spektralnie do poszukiwanych wzorców, eliminując jednocześnie obiekty obce

dla danej klasy (np. pojedyncze drzewa, kępy wyraźnie różniące się roślinnością, ścieżki, wody).

Ze względu na dużą liczbę zbiorowisk roślinnych i ich kompleksów przestrzennych oraz chęć wykonania klasyfikacji o wysokiej dokładności, zarówno do uczenia sieci, jak i analizy poklasyfikacyjnej stworzone zostały wzorce składające się z dużej liczby pikseli (starano się, by wszystkie klasy były reprezentowane przez próbki większe niż 400 pikseli).

Jednym z kluczowych elementów w klasyfikacjach danych hiperspektralnych jest optymalny dobór kanałów, gdyż każdy dodatkowy kanał rozbudowuje architekturę sieci klasyfikującej, co wydłuża czas samej klasyfikacji. W ramach niniejszego opracowania zastosowano dwie równoległe procedury: (1) dekorrelację szumu i analizę głównych składowych (MNF) i (2) analizę informacyjności poszczególnych kanałów. W drugim przypadku bazowano na algorytmach dostępnych w pakiecie SVM, a analiza informacyjności została wykonana w Interdyscyplinarnym Centrum Modelowania (ICM) UW. Uzyskane wyniki wskazały, że dane po transformacji MNF uzyskiwały dokładność o kilka procent niższą, ale z przyczyn czysto operacyjnych są to dobre wyniki, gdyż czas klasyfikacji jest znacznie krótszy. Wydaje się, że dobrym rozwiązaniem jest przeprowadzenie wstępnej klasyfikacji (w tym dobór parametrów sieci) na zbiorach MNF, a następnie – po ustaleniu optymalnych wskaźników uczenia sieci – wykonanie właściwej klasyfikacji na danych oryginalnych.

Wyniki klasyfikacji poszczególnych linii zobrazowania są w znacznym stopniu porównywalne (tab. 22). Należy jednak pamiętać, że zbiorowiska roślinne w poszczególnych okresach fenologicznych cechują się różną morfologią i parametrami biochemicznymi. Wykorzystane obrazy pozyskano w optimum rozwoju fenologicznego (rejestracja obrazów odbyła się 4.08.2002).

Uzyskane obrazy poklasyfikacyjne, liczba wyodrębnionych klas oraz poklasyfikacyjne dane statystyczne można uznać za satysfakcjonujące. Analiza wyników wskazuje, że spośród 42 analizowanych klas tylko dwie nie zostały rozpoznane na żadnej linii zobrazowania. 5-6 zbiorowisk cechowało się niezbyt dużą dokładnością poklasyfikacyjną. Dotyczy to głównie zbiorowisk powypasowych na Hali Gąsienicowej, które przekształcają się ze względu na zaprzestanie wypasu owiec.

Przegląd literatury potwierdził, że zdecydowana większość prac koncentruje się na klasyfikacji roślinności

obszarów chronionych (najczęściej parków narodowych), co jest przydatne np. w analizie zmian zasięgu gatunków inwazyjnych. Drugim dość popularnym kierunkiem jest analiza roślinności uprawnej. Obiecująco wygląda wykorzystanie danych hiperspektralnych do analizy składu gatunkowego zbiorowisk, jednakże największy potencjał do tego typu badań zawarty jest w spektralnym rozmieszaniu pikseli i analizach subpikselowych, które nie były przedmiotem zainteresowań niniejszej pracy, gdyż wyniki takich analiz przedstawiają miary statystyczne, np. prawdopodobieństwo wystąpienia gatunku na danym obszarze lub też prawdopodobieństwo wystąpienia określonego gatunku w danym zbiorowisku (np. ryc. 43).

Najlepsze średnie wyniki klasyfikacji 40 kanałów wyniosły 92,8% (dokładność producenta) oraz 84,2% (dokładność użytkownika), natomiast najgorsze odpowiednio 84,2% oraz 67,5%. W przypadku klasyfikacji 20 kanałów MNF uzyskano odpowiednio 86,1% i 79,9%, najgorsze zaś 74,7% i 63,7% (tab. 24). Najlepsze wyniki (dokładność producenta i użytkownika >90%) uzyskano w odniesieniu do zbiorowisk naturalnych: murawa alpejska typowa (#8), murawa alpejska torfowcowa (#11), murawa alpejska postać subalpejska (#16), murawa alpejska w kompleksie z wyleżyskami (#17), murawa alpejska w kompleksie z traworoślami (#18) oraz zarośla kosodrzewiny na podłożu bezwęglanowym (#38) (tab. 24, ryc. 36).

Uzyskane wyniki (ryciny 28-35 oraz tabele 5-24) wyraźnie potwierdzają postawioną na wstępie hipotezę, że wykorzystanie wysokorozdzielczych spektralnie i radiometrycznie danych hiperspektralnych oraz zastosowanie symulatorów sztucznych sieci neuronowych pozwala na identyfikację i kartowanie zbiorowisk roślinnych obszarów wysokogórskich, które są jednym z najtrudniejszych obiektów badawczych, nie tylko z teledetekcyjnego punktu widzenia.

Zaproponowana metoda kartowania roślinności powinna być rozwijana na innych zestawach danych hiperspektralnych, pozyskanych w różnych okresach sezonu wegetacyjnego, co umożliwi dokładniejszy monitoring środowiska obszarów chronionych i rolniczych. Przytoczone zagraniczne badania potwierdzają także przydatność danych hiperspektralnych i sieci neuronowych do powszechnego, aplikacyjnego stosowania.

Wnioski

- Dane hiperspektralne zawierają unikatowe informacje o roślinności, pozwalając na identyfikację zbiorowisk oraz ich układów przestrzennych;
- Sieci neuronowe są właściwym narzędziem do klasyfikacji skomplikowanych układów przestrzennych (symulator wykorzystuje informacje o przestrzennym ułożeniu i sąsiedztwie analizowanego obiektu), pozwoliły one na klasyfikację przeważającej większości typów roślinności wysokogórskiej (w rozpatrywanym przypadku 40 na 42 jednostki), przy wysokiej dokładności wyników (najwyższa średnia dokładność producenta dla wszystkich klas wyniosła 93%, a dokładność użytkownika 84%, natomiast średnia dokładność wszystkich klasyfikacji wyniosła odpowiednio 86 i 75%);
- Lepsze wyniki klasyfikacji uzyskuje się dla dużych, zwartych zbiorowisk roślinnych o jednorodnej strukturze (dokładność całkowita wyższa o 3-4% i o 2-4% mniejsze odchylenia standardowe w porównaniu do zbiorowisk tworzących mozaikowe kompleksy topograficzne);
- Mapa powstała w wyniku klasyfikacji obrazów hiperspektralnych wykazuje wysokie podobieństwo do mapy powstałej jako efekt badań terenowych, podobieństwo to waha się w zależności od linii zobrazowania i typu klasyfikowanych danych na poziomie 81-84% (wskaźnik kappa);
- Duża jest także powtarzalność wyników, uzyskanych z poszczególnych linii zobrazowania; odchylenie standardowe waha się na poziomie kilku procent. Oznacza to, że można mapę powstałą w wyniku przetwarzania danych hiperspektralnych traktować jako podstawę do sporządzania map roślinności gór w skali szczegółowej;
- Najważniejsze etapy pracy, których prawidłowe przeprowadzenie warunkuje satysfakcjonujące wyniki końcowe, to: badania terenowe podczas trwania zobrazowania (zebranie danych referencyjnych do korekcji geometrycznej oraz atmosferycznej), stworzenie odpowiednio dużych wzorców poligonów poszczególnych klas do uczenia sieci oraz weryfikacji poklasyfikacyjnej, wykonanie prawidłowej korekcji geometrycznej i atmosferycznej, optymalny dobór kanałów oraz parametrów sieci do klasyfikacji;
- Optymalny wzorzec do uczenia sieci powinien składać się z co najmniej 400 pikseli danej klasy oraz 40 kanałów;
- Czynnikiem wydłużającym klasyfikację jest liczba zadanych kanałów, dlatego zalecana jest analiza jakości i informacyjności poszczególnych wyciągów spektralnych;
- Zastosowanie danych po kompresji MNF przyspiesza klasyfikację, jednakże uzyskane wyniki są o kilkukilkaście procent gorsze od klasyfikacji przeprowadzonej na danych oryginalnych (po korekcji geometrycznej i atmosferycznej);
- Dla obszarów górskich wymagana jest pełna korekcja atmosferyczna (obejmująca także normalizację dwukierunkowości odbicia promieniowania). Pozwala to wyeliminować wpływ orografii atmosfery i geometrii słońce-obiekt detektor na odbicie sygnału;
- Darmowy dostęp do symulatorów oraz aktywnych grup dyskusyjnych poświęconych sieciom neuronowym pozwala z optymizmem patrzeć na przyszłość tego typu prac, tym bardziej, że operatorzy satelitarnego systemu hiperspektralnego EnMAP zapowiedzieli otwartą dystrybucję danych, co ma nastąpić po umieszczeniu sensora na orbicie w 2011/12 roku.

Podziękowania

Realizacja niniejszej pracy nie byłaby możliwa bez pomocy wielu osób i instytucji. Pierwszą osobą, do której chcę skierować słowa najszczerzych podziękowań jest Profesor dr hab. Jan R. Olędzki. W 1995 r. prof. Olędzki zaproponował mi, wtedy studentowi 2 roku Międzywydziałowych Studiów Ochrony Środowiska Uniwersytetu Warszawskiego UW, pracę w ówczesnym Zakładzie Teledetekcji Środowiska WGiSR UW. Dla mnie, młodego wówczas chłopaka, było to znaczące wsparcie, gdyż umożliwilo mi jednoczesne studiowanie oraz aktywny udział w życiu naukowym. Pod opieką prof. Olędzkiego zdobywałem doświadczenie naukowe oraz mogłem przygotować swoją pracę magisterską i doktorską, koncentrując się na teledetekcyjnych badaniach nad roślinnością. Od 15 lat wspólnej pracy Profesor służy mi ogromną pomocą, której efektem jest mój udział w wielu projektach krajowych i międzynarodowych, dzięki któremu mogłem zebrać znaczące doświadczenie dydaktyczne i naukowe. Panie Profesorze, bardzo dziękuję za wszystko.

Dzięki prof. Olędzkiemu w roku 1998 Zakład Teledetekcji Środowiska WGiSR UW wstąpił do Europejskiej Asocjacji Laboratoriów Teledetekcyjnych (EARSeL) i od tego czasu regularnie uczestniczyliśmy w organizowanych przez Asocjację konferencjach. W 2000 r. podczas uroczystej kolacji prof. Michael Schaepman (RSL, Uniwersytet w Zurichu) zainteresował mnie i Anię Jakomulską badaniami hiperspektralnymi i opowiedział o projekcie HySens. Dzięki niemu zrodziła się w naszym Zakładzie myśl aplikowania do tego projektu. Prof. Schaepman wielokrotnie służył nam pomocą i radą, to także dzięki niemu w naszej Katedrze rozwijane są metody hiperspektralne. *Michael, thank you very much for all, you know that our Imaging Spectroscopy is your child.* Chronologicznie drugą osobą, która przyczyniła

się do rozwoju teledetekcji hiperspektralnej w naszej jednostce jest dr Andreas Mueller (DLR Oberpfaffenhofen), który od pierwszego spotkania w Oberpfaffenhofen jest jednym z największych naszych przyjaciół. Andreas razem z Martinem Habermeyerem przyjechali z nieosiągalnym dla nas spektrometrem hiperspektralnym do Zakopanego, by pomierzyć nam dane do kalibracji obrazów hiperspektralnych DAIS 7915 oraz Rosis. To dzięki uporowi Andreasa samolot DLR oczekiwał w Krakowie tydzień na poprawę pogody, byśmy mieli dobre obrazy, a jak zapewnił nas Rolf Richter dane te należą do najlepszych jakie pozyskało DLR w 2002. Nie dość, że rachunek za pobyt Dorniera Do 228 był ogromny, to jeszcze Andreas Mueller zaprosił nas na trzy tygodnie do Oberpfaffenhofen, by nauczyć mnie i Marcina Sobczaka przetwarzania danych hiperspektralnych. W trakcie tego pobytu wykonaliśmy korekcję atmosferyczną oraz geometryczną danych (i to pod czujnym okiem dr. Rudolfa Richtera!), które są podstawą niniejszej pracy. *Andreas, vielen herzlichen Dank, wir sind Dir, Rolf, Martin B., Martin H., Wouter und natuerlich Steffi wirklich sehr dankbar.*

Szczególne miejsce w mojej pamięci zajmuje Ania Jakomulska, Jej odejście zostawiło ogromną dziurę nie tylko w moim sercu. To dzięki Ani doskonałej znajomości angielskiego przygotowaliśmy projekt HySens. Ania miała zająć się modulem przetwarzania obrazów, a ja pomiarów terenowych, ale los zrobił nam tragiczną niespodziankę i Ania nigdy nawet nie zobaczyła owoców swoich starań, gdyż kilka dni po zakończeniu badań terenowych w Tatrach wyjechała na urlop i 16.08.2002 r. na zawsze od nas odeszła. Aniu, bardzo dziękuję Ci za tych kilka lat wspólnej pracy, będę o nich zawsze pamiętał.

Wbrew potocznym opiniom, badania teledetekcyjne bazują na dużej liczbie pomiarów terenowych. Tak

też było w przypadku niniejszego projektu. Przez kilka kolejnych lat wyjeżdżaliśmy na kilka-kilkanaście dni w Tatry. Tam zawsze spotykaliśmy się z ogromną otwartością ze strony TPN. Dyrekcja Parku udostępniała nam Tatry Wysokie do badań oraz pomagała w transporcie i zakwaterowaniu. Chcę bardzo serdecznie podziękować Dyrekcji TPN oraz wszystkim pracownikom, którzy zawsze życzliwie nas przyjmowali. Szczególne słowa kieruję do Panów dr inż. Pawła Skawińskiego, dr inż. Wojciecha Gąsienicy Byrcyna, dr inż. Marcina Guzika, mgr inż. Jana Chmiela oraz kierowców TPN, którzy pomagali nam przewieźć cały sprzęt i służyli pomocą nawet w wolnym czasie. Gorące podziękowania kieruję do Państwa dr dr Magdaleny i Tomasza Zwijaczów-Koziców, którzy służyli nam ogromną pomocną merytoryczną oraz wielokrotnie przyjmowali nas w potrzebie, udostępniając własny kąk, kubek herbaty i ciepłą strawę, prąd do naładowania urządzeń, czy kasetkę do kamery.

Ogromną gościnność zawsze znajdowaliśmy w stacji IGiPZ PAN. Pisząc podania z prośbą o udostępnienie Stacji IGiPZ PAN na Hali Gąsienicowej zawsze mogliśmy liczyć na przychylność Kierownictwa, czyli prof. dr. hab. Adama Kotarby i doc. dr hab. Zofii Rączkowskiej, za co bardzo dziękuję. W Stacji z otwartymi rękami witali nas zawsze gospodarze: Marek Kotlarczyk i Janusz Konieczek. Kluczowymi osobami, wspomagającymi nie tylko w tatrzańskich badaniach terenowych są dr Jarosław Baranowski oraz doc. dr hab. Anna Kozłowska. Dzięki udostępnionej aparaturze i danym mogliśmy wykonać szczegółową kalibrację i weryfikację danych hiperspektralnych. Doc. dr hab. Anna Kozłowska zawsze była gotowa do pomocy podczas kartowań i identyfikacji roślin. Własne prace doc. Kozłowskiej oraz wspólne badania tatrzańskie stanowią jeden z głównych fundamentów niniejszej pracy.

W badaniach terenowych niezwykle pomocni byli także pracownicy i studenci Katedry Geoinformatyki i Teledetekcji WGiSR UW. Pragnę serdecznie podziękować mgr Alicji Folbrier, dr Elżbiecie Wołk-Musiał, dr Małgorzacie Krówczyńskiej, dr Magdalenie Zwijacz-Kozicy, dr Marcinowi Sobczakowi, dr Piotrowi Pabjankowi, dr Dariuszowi Ziółkowskiemu oraz wszystkim studentom, którzy bardzo chętnie i licznie wspierali prace terenowe; dotyczy to m.in. Ani Nowak, Ani Pietraszek, Marty Piechal, Karola Kąckiego, Karola Zaremskiego.

Proces przetwarzania danych nie byłby możliwy bez znacznego wsparcia finansowego, dotyczy to głównie Ministerstwa Nauki i Szkolnictwa Wyższego oraz przyznanych środków na realizację:

- projektu KBN nr rej. 5T12E 031 23 *Analiza spektralnych właściwości roślinności naziemnymi systemami teledetekcyjnymi*. Kierownik tematu: prof. dr hab. Jan R. Olędzki. Termin realizacji 2002-2005;

- projektu KBN nr rej. 5T12E 026 24 *Zastosowanie cyfrowych metod przetwarzania lotniczych obrazów hiperspektralnych w badaniach i kartografii roślinności*. Kierownik tematu: dr Bogdan Zagajewski. Termin realizacji 2003-2005;

- Inwestycji Aparaturowej MNiSW z 2007 roku.

Niezwykle pomocny w realizacji niniejszej pracy był dostęp do infrastruktury Interdyscyplinarnego Centrum Modelowania Matematycznego i Komputerowego. Dostęp ten był możliwy dzięki przyznaniu grantu obliczeniowego przez ICM Centrum Komputerów Dużej Mocy nr G33-4 *Klasyfikacja obrazów hiperspektralnych za pomocą sztucznych sieci neuronowych*. Kierownik tematu: dr Bogdan Zagajewski. Termin realizacji luty-maj 2008.

Szczególnie podziękowania kieruję pod adresem Kierownictwa ICM KDM oraz pracowników ICM: dr Witolda Rudnickiego, mgr Mirona Kursy oraz mgr Marity Nowotki, którzy wydatnie pomogli w statystycznej ocenie jakości poszczególnych kanałów zobrazowania DAIS 7915 Tatr Wysokich.

Niniejsza praca nie powstałaby, gdyby nie udział i znaczące wsparcie merytoryczne i finansowe ze strony projektu UE Hyperspectral Imaging Network (Hyper-i-net, MRTN-CT-2006-035927, kontrakt nr 6 – *Paolo, thank you very much for your significant support*.

W wielu zadaniach związanych z klasyfikacjami pomocni byli mgr Dawid Olesiuk oraz dr Małgorzata Krówczyńska. Małgosiu i Dawidzie bardzo Wam dziękuję.

Nad pierwszymi wersjami niniejszej publikacji uważnie pochylali się prof. Jan R. Olędzki, dr Elżbieta Wołk-Musiał, dr Piotr Pabjank oraz dr inż. Tomasz Zwijacz-Kozica – serdecznie im dziękuję za uwagi, komentarze i opinie, które podniosły wartość pracy.

Końcowa wersja publikacji została doszlifowana dzięki wsparciu doc. dr hab. Anny Kozłowskiej oraz mgr Ludmiły Kwiatkowskiej.

Wyjątkowo gorące słowa kieruję do koleżanek i kolegów z klubu Orzeł Judo Żyrardów, szczególnie do naszego trenera Jarka Zakrzewskiego, Jacka Waclawka, Jacka Markowskiego, Waldka Kuchty, którzy zachęcali mnie do wyłożonych ćwiczeń fizycznych, by w tym czasie mogły ostygnąć moje biologiczne sieci neuronowe. Przepraszam ich także, że podczas końcowych prac nad tą publikacją brak wolnego czasu wykluczył mnie z treningów.

Trud wynikający z przygotowania pracy odczuli na własnej skórze moi najbliżsi, bardzo dziękuję żonie, dzieciom i teściom za wyręczanie mnie w codziennych obowiązkach domowych. Dziękuję także rodzicom, którzy mocno przeżywają moją naukową aktywność.

Raz jeszcze gorąco dziękuję wszystkim, którzy pozwolili mi na realizację tego projektu, udzielali wielu korzystnych rad i pomogli sfinalizować niniejszą publikację.

Literatura

- Adams B., Smith M.O., Gillespie A.R., 1993, Imaging Spectroscopy: Interpretation Based on Spectral Mixture Analysis. W: C. M. Pieters, P. Englerty (red.), *Remote Geochemical Analysis: Elemental & Mineralogical Composition*, Cambridge University Press, s. 145-166.
- Adams W.W. III, Demmig-Adams B., Logan B.A., Barker D.H., Osmond C.B., 1999, Rapid changes in xanthophyll cycle-dependent energy dissipation and photosystem II efficiency in two vines, *Stephania japonica* and *Smilax australis*, growing in the understory of an open Eucalyptus forest. *Plant, Cell and Environment*, vol. 22, s. 125-136.
- Aldakheel Y.Y., Danson F.M., 1997, Spectral reflectance of dehydrating leaves: measurements and modelling. *International Journal of Remote Sensing*, vol. 18, s. 3683-3690.
- Amari S.I., 1972, Learning patterns and pattern sequences by self-organizing nets of threshold elements. *IEEE Transactions on Computers*, Vol. 21, s. 1197-1206.
- Anderson M.C., Kustas W.P., Norman J.M., 2003, Upscaling and downscaling – a regional view of the soil–plant–atmosphere continuum. *Agronomy Journal*, Vol. 95, s. 1408-1423.
- Anderson J., Silverstein J., Ritz S., Jones R., 1977, Distinctive features, categorical perception, and probability learning: Some applications of a neural model. *Psychological Review*, Vol. 84, s. 413-451.
- Ashton E.A., Schaum A., 1998, Algorithms for the Detection of Sub-Pixel Targets in Multispectral Imagery. *Photogrammetric Engineering & Remote Sensing*, Vol. 64, nr 7, s. 723-731.
- Balcerkiewicz S., 1984, Roślinność wysokogórska Doliny Pięciu Stawów Polskich w Tatrach i jej przemiany antropogeniczne. Wydawnictwo Naukowe UAM, Seria Biologia, 25, Poznań, s. 1-191.
- Balcerkiewicz S., Wojterska M., 1978, Sigmassoziationen in der Hohen Tatra. W: R. Tèuxen (red.), Assoziationskomplexe (Sigmeten) und ihre praktische Anwendung. *International Society for Plant Geography and Ecology*. J. Cramer, Vaduz, s. 161-177.
- Ball J.T., Woodrow I.E., Berry J.A., 1986, A model predicting stomatal conductance and its contribution to the control of photosynthesis under different environmental conditions. W: J. Biggins (red.), *Progress in photosynthesis research*. Nijhoff, Dodrecht, Holandia, s. 221–225.
- Barnes P.W., Flint S.D., Caldwell M. M., 1990, Morphological responses of crop and weed species of different growth forms to ultraviolet-B radiation. *American Journal of Botany*, Vol. 77, s. 1354-1360.
- Barton C.V.M, North P.R.J., 2001, Remote sensing of canopy light use efficiency using the photochemical reflectance index – model and sensitivity analysis. *Remote Sensing of Environment*, Vol. 78, s. 264-273.
- Benediktsson J.A., 1995, Classification and Feature Extraction of AVIRIS Data. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 33, nr 5, s. 1194-1205.
- Boardman J.W., 1994, Geometric mixture analysis of imaging spectrometry data. *Proceedings of International Geoscience and Remote Sensing Symposium*, Vol. 4, s. 2369-2371.
- Boardman J.W., Kruse F.A., 1994, Automated spectral analysis: A geological example using AVIRIS data, northern Grapevine Mountains, Nevada. W: *Proceedings, Tenth Thematic Conference, Geologic Remote Sensing, 9-12 May 1994*, San Antonio, Texas, s. 407-418.
- Bogusz W., Garbarczyk J., Krok F., 1997, *Podstawy fizyki*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, s. 569.
- Caldwell M.M., 1971, Solar ultraviolet radiation and the growth and development of higher plants. W: A.C. Giese (red.), *Photophysiology*, Academic Press, New York, s. 131-177.
- Carder K.L., Reinersman P., Chen R.F., Muller-Karger F., Davis C.O., Hamilton M.K., 1993, AVIRIS calibration and application in coastal oceanic environments. *Remote Sensing of Environment*, Vol. 44, s. 205-216.
- Carpenter G.A., 1997, Distributed learning, recognition, and prediction by ART and ARTMAP neural networks. *Neural Networks*, Vol. 10, s. 1473-1494.

- Carpenter G.A., Grossberg S., 1987, A massively parallel architecture for a self organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, nr 37, s. 54-115.
- Carpenter G.A., Grossberg S., 1990, ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. *Neural Networks*, Vol. 3, s. 129-152.
- Carpenter G.A., Grossberg S., 2003, Adaptive Resonance Theory. W: M.A. Arbib (red.), *The Handbook of Brain Theory and Neural Networks*, 2nd Edition. MIT Press, Cambridge, Mass.MA, s. 344.
- Carpenter G.A., Grossberg S., Markuzon N., Reynolds J.H., Rosen D.B., 1992, Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, 3, s. 698-713.
- Carpenter G.A., Grossberg S., Reynolds J.H., 1991, ARTMAP: A self-organizing neural network architecture for fast supervised learning and pattern recognition. *Neural Networks*, Vol. 4, s. 565-588.
- Carpenter G.A., Grossberg S., Reynolds J.H., 1995, A Fuzzy ARTMAP Nonparametric Probability Estimator for Nonstationary Pattern Recognition Problems. *IEEE Transactions on Neural Networks*, Vol. 6, nr 6, s. 1330-1336.
- Carpenter G.A., Grossberg S., Rosen D.B., 1991, Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, Vol. 4, s. 759-771.
- Carrère V., Conel J., 1993, Recovery of atmospheric water vapor total column abundance from imaging spectrometer data around 940 nm – Sensitivity analysis and application to Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) data. *Remote Sensing of Environment*, Vol. 44, s. 179-204.
- Carter G.A., 1994, Ratios of leaf reflectance in narrow wavebands as indicators of plant stress. *International Journal of Remote Sensing*, Vol. 15, s. 697-703.
- Chang C.-I., 2003, *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Kluwer Academic/Plenum Publishers, New York, s. 374.
- Chang C.-I., Du Q., 2004, Estimation of number of spectrally distinct signal sources in hyperspectral imagery. *IEEE Transaction on Geoscience and Remote Sensing*, Vol.42, no. 3, s. 608-619.
- Chang C.-I., Plaza A., 2006, A Fast Iterative Algorithm for Implementation of Pixel Purity Index. *IEEE Geoscience and Remote Sensing Letters*, Vol. 3, no. 1, s. 63-67.
- Chaudhry F.A., 2005, *Pixel Purity Index-Based Endmember Extraction for Hyperspectral Data Exploitation*, University of Maryland, Department of Computer Science and Electrical Engineering, MS thesis.
- Chiu H.Y., Collins W.E., 1978, A spectroradiometer for airborne remote sensing. *Photogrammetric Engineering and Remote Sensing*, Vol. 44, s. 507-517.
- Chyliński E., Chyliński J., 2009, *Artificial Intelligence*. C LabTech. Ze strony <http://www.ai.c-labtech.net/sn/sneuro.html#back>.
- Ciołkosz A., Jakomulska A., 2004, *Przetwarzanie cyfrowych zdjęć satelitarnych. Symulacja pracy komputera za pomocą papieru i ołówka*. Wydział Geografii i Studiów Regionalnych, Uniwersytet Warszawski, Warszawa, s. 116.
- Ciołkosz A., Miszański J., Ołędzki J.R., 1999, *Interpretacja zdjęć lotniczych*. PWN, Warszawa.
- Clark M.L., Roberts D.A., Clark D.B., 2005, Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sensing of Environment*, Vol. 96, s. 375-398.
- Cochrane M.A., 2000, Using vegetation reflectance variability for species level classification of hyperspectral data. *International Journal of Remote Sensing*, Vol. 21, s. 2075-2087.
- Cochrane M.A., 2001, Synergistic interactions between habitat fragmentation and fire in evergreen tropical forests. *Conservation Biology*, Vol. 15, nr 6, s. 1515-1521.
- Cochrane M.A., 2002, *Spreading like wildfire – tropical forest fires in Latin America and the Caribbean: prevention, assessment and early warning*. United Nations Environment Program, Regional Office for Latin America and the Caribbean. UNEP, s. 96.
- Collins W., Chang S.H., Kuo J.T., Rowan L.C., 1981, Remote mineralogical analysis using a high-resolution spectrometer: Preliminary results of the Mark II system. *IEEE International Geoscience and Remote Sensing Symposium*, Vol. 1, Washington D.C., Digest, s. 327-334.
- Crowley J.K., 1993, Mapping playa evaporite mineral with AVIRIS data: A first report from Death Valley, California. *Remote Sensing of Environment*, Vol. 44, s. 337-356.
- Dagher I., 2006, L-p Fuzzy ARTMAP neural network architecture. *Soft Computing*, Vol. 10, s. 649-656.
- Datt B., 1999, Visible/near infrared reflectance and chlorophyll content in Eucalyptus leaves. *International Journal of Remote Sensing*, Vol. 20, s. 2741-2759.
- Datt B., 2000, Red edge shifts for detecting phenologic change and stress symptoms in evergreen eucalyptus forests. *Proceedings of 10th Australasian Remote Sensing and Photogrammetry Conference*, Australia, Adelaide, s. 863-874.
- Dawson T.P., Curran P.J., Plummer S.E., 1998, The biochemical decomposition of slash pine needles from reflectance spectra using neural networks. *International Journal of Remote Sensing*, Vol. 19, s. 1433-1438.
- de Jong S.M., van der Meer F.D., (red.), 2004, *Remote Sensing Image Analysis. Including the Spatial Domain*. Remote sensing and digital image processing. Kluwer Academic Publishers, Dordrecht, s. 360.
- Dehaan R., Louis J., Wilson A., Hall A., Rumbachs R., 2007, Discrimination of blackberry (*Rubus fruticosus* sp. agg.) using hyperspectral imagery in Kosciuszko National Park, NSW, Australia. *ISPRS Journal of Photogrammetry & Remote Sensing*, Vol. 62, s. 13-24.
- Delalieux S., Somers B., Haest B., Kooistra L., Múcher C.A., Vanden Borre J., 2010, Monitoring heathland habitat status using hyperspectral image classification and unmixing. *Proceedings of the 2nd Whispers on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE GRSS, University of Iceland, Reykjavik, s. 50-54
- Dennison P.E., Halligan K.Q., Roberts D.A., 2004, A comparison of error metrics and constraints for multiple endmember spectral mixture analysis and spectral angle mapper. *Remote Sensing of Environment*, Vol. 93, s. 359-367.

- Elvidge C.D., Chen, Z., Groeneveld, D.P., 1993, Detection of trace quantities of green vegetation in 1990 AVIRIS data. *Remote Sensing of Environment*, Vol. 44, s. 271-280.
- Falińska K., 1997, *Ekologia roślin*, Wydawnictwo Naukowe PWN, Warszawa
- Filippi A.M., Jensen J.R., 2006, Fuzzy learning vector quantization for hyperspectral coastal vegetation classification. *Remote Sensing of Environment*, Vol. 100, s. 512-530.
- Fourty Th., Baret F., 1998, On spectral estimates of fresh leaf biochemistry. *International Journal of Remote Sensing*, Vol. 19, s. 1283-1297.
- Gamon J.A., Field C.B., Roberts D.A., Ustin S.L., Valentini R., 1993, Functional patterns in an annual grassland during and AVIRIS overflight. *Remote Sensing of Environment*, Vol. 44, s. 239-254.
- Gao B., Goetz A.F.H., 1990, Column atmospheric water vapor and vegetation liquid water retrievals from airborne imaging spectrometer data. *Journal of Geophysical Research*, Vol. 95, nr D4, s. 3549-3564.
- Gawroński R., 1970, *Rozpoznawanie i decyzja*, PWN, Warszawa.
- Gitelson A.A., Merzlyak M.N., 1997, Remote estimation of chlorophyll content in higher plant leaves. *International Journal of Remote Sensing*, Vol. 18, s. 2691-2697.
- Glossary of remote sensing technology, 2000, Committee on Earth Observations Satellites CNES (CEOS 2000). <http://ceos.cnes.fr:8100/cdrom-00b2/ceos1/science/glossary/gloss.htm>.
- Goetz A.F.H., Vane G., Solomon J.E., Rock B.N., 1985, Imaging Spectrometry for Earth Remote Sensing. *Science*, Vol. 228, nr 4704, s. 1147-1153.
- Green A.A., Berman M., Switzer P., Craig M.D., 1988, A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 26, nr 1, s. 65-74.
- Greniewski H., 1959, Elementy cybernetyki – sposobem matematycznym wyłożone. PWN, Warszawa, s. 208.
- Guyon I., Weston J., Barnhill S., Vapnik V., 2002, Gene selection for cancer classification using support vector machines. *Machine Learning*, Vol. 46, s. 389-422.
- Habermeyer M., Holzwarth S., Mueller A., Mueller R., Richter R., Seitz K.-H., Seifert P., Strobl P., 2003, Developing a Fully Automatic Processing Chain for the Upcoming Hyperspectral Scanner ARES. W: A. Mueller, S. Holzwarth (red.), *Proceedings of the 3rd EARSeL Workshop on Imaging Spectroscopy*. Wydanie elektroniczne na CD: ISBN 2-908885-26-3.
- Hall C.R., Hinkle C.R., Knott W.M., Summerfield B.R., 1992, Environmental monitoring and research at the John F. Kennedy space center. *Journal of the Florida Medical Association*, Vol. 79, nr 8, s. 545-552.
- Hamilton M.K., Davis C.O., Rhea W.J., Pilorz S.H., Carder K.L., 1993, Estimating chlorophyll content and bathymetry of Lake Tahoe using AVIRIS data. *Remote Sensing of Environment*, Vol. 44, s. 217-230.
- Hebb D.O., 1949, *The organization of behavior: A neuropsychological theory*. John Wiley and Sons, New York, s. 335.
- Hejmanowska B., Drzewiecki W., Głowienka E., Mularz S., Zagajewski B., Sanecki J., 2006, Próba integracji satelitarnych obrazów hiperspektralnych z nieobrazowymi naziemnymi danymi spektrometrycznymi na przykładzie Zbiornika Dobczyckiego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 16, s. 207–216.
- Hejmanowska B., Głowienka E., 2004, Wstępne wyniki pomiarów spektrometrycznych i klasyfikacji obrazów hiperspektralnych rekultywowanego obszaru Tarnobrzskiego Zagłębia Siarkowego. *Geoinformatica Polonica*, Tom 6, Prace Komisji Geoinformatyki PAU, Kraków, s. 49-58.
- Hines E.L., 2009, *Intelligent Systems Engineering*. University of Warwick, School of Engineering, s. 45. <http://www.eng.warwick.ac.uk/eng/staff/elh/ise/session06/lec4.pdf> (29.01.2009).
- Hoerig B., Kuehn F., Oschuetz F., Lehmann F., 2001, Hyperspectral remote sensing to detect hydrocarbons. *International Journal of Remote Sensing*, Vol. 22, s. 1413-1422.
- Holzwarth S., Mueller A., Habermeyer M., Richter R., Hausold A., Strobl P., Thiemann S., 2004, HySens – DLR's hyperspectral airborne campaigns 2000-2002. W: R. Goossens (red.), *Remote Sensing in Transition. Proceedings of the 23rd Symposium of the European Association of Remote Sensing Laboratories*, Millpress, Rotterdam, s. 471-478.
- Holzwarth S., Mueller A., Hausold A., Habermeyer M., Richter R., Thiemann S., Strobl P., 2003, HySens DAIS/RODIS Imaging Spectrometers at DLR. W: A. Mueller, S. Holzwarth (red.), *Proceedings of the 3rd EARSeL Workshop on Imaging Spectroscopy*. Wydanie elektroniczne CD: ISBN 2-908885-26-3.
- Jakomulska A., Sobczak M., 2001, Korekcja radiometryczna obrazów satelitarnych - metodyka i przykłady. *Teledetekcja Środowiska*, Tom 32, Klub Teledetekcji Środowiska PTG, Warszawa, s. 152-171.
- Jarvis P.G., 1993, Prospects for bottom-up models. W: J.R. Ehleringer C.B. Field (red.), *Scaling physiological processes leaf to globe*. Academic Press, San Diego, s. 115–126.
- Jarvis P.G., 1995, Scaling processes and problems. *Plant, Cell and Environment*, Vol. 18, s. 1079-1089.
- Jaworowski J., Tadeusiewicz R., 1974, ART 73b – język do przetwarzania informacji akustycznej dla potrzeb sterowania cyfrowego. W: Materiały konferencyjne *Cyfrowe systemy sterowania*, Wrocław, s. 21-27.
- Jollineau M.Y., Howarth P.J., 2008, Mapping an inland wetland complex using hyperspectral imagery. *International Journal of Remote Sensing*, Vol. 29, nr 12, s. 3609-3631.
- Joshi C.M., de Leeuw J., Skidmore A.K., 2006, Upscaling species invasion patterns from local to regional for forest ecosystem management. W: *Proceedings of ISPRS mid-term symposium 2006 remote sensing: from pixels to processes*, ITC Enschede, The Netherlands, s. 1-6.
- Kavzoglu T., Mather P.M., 2003, The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, Vol. 24, nr 23, s. 4907-4938.
- Kempisty M., (red.), 1973, *Mały słownik cybernetyczny*. Wiedza Powszechna, Warszawa, s. 533.
- Kirkpatrick S., Gelatt C.D., Vecchi M.P., 1983, Optimization by simulated annealing. *Science*, Vol. 220, s. 671-680.
- Klińska A., 2004, *Badanie głębokości optycznej atmosfery nad*

- wybranymi regionami. Wydział Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, praca magisterska, opiekun prof. dr hab. J. R. Olędzki, maszynopis.
- Kohonen T., 1990, The self organising maps. *Proceedings of IEEE*, Vol. 78, s. 1464-1479.
- Kokaly R.F., Despain D.G., Clark R.N., Livo K.E., 2003, Mapping vegetation in Yellowstone National Park using spectral feature analysis of AVIRIS data. *Remote Sensing of Environment*, Vol. 84, s. 437-456.
- Korbicz J., 2008, Artificial intelligence in technical diagnostics. *Diagnostyka*, Vol. 46, nr 2, s. 7-16.
- Korbicz J., Kowal M., 2007, Neuro-fuzzy networks and their application to fault detection of dynamical systems. *Engineering Applications of Artificial Intelligence*, Vol. 20, s. 609-617.
- Korbicz J., Obuchowicz A., Uciński D., 1994, *Sztuczne sieci neuronowe. Podstawy i zastosowania*. Akademicka Oficyna Wydawnicza, Warszawa, s. 253.
- Kozłowska A., Plit J., 2002, Mapy roślinności wysokogórskiej Tatr (Od Krzyżnego do Przełęczy Kondrackiej) w skali 1: 10000 i 1:20000. W: W. Borowiec, A. Kotarba, A. Kownacki, Z. Krzan, Z. Mirek (red.), *Przemiany środowiska przyrodniczego Tatr. Część 2 – Nauki Biologiczne*, Tatrzański Park Narodowy i Polskie Towarzystwo Przyjaciół Nauk o Ziemi, Oddział Kraków, Wydawnictwo Instytutu Botaniki PAN w Krakowie, Kraków-Zakopane, s. 203-210.
- Kozłowska A., 2006, Detailed mapping of high-mountain vegetation in the Tatra Mts. *Polish Botanical Studies*, Vol. 22, s. 333-341.
- Kozłowska A., Plit J., 2002, Mapy roślinności wysokogórskiej Tatr (Od Krzyżnego do Przełęczy Kondrackiej) w skali 1: 10000 i 1:20000. W: W. Borowiec, A. Kotarba, A. Kownacki, Z. Krzan, Z. Mirek (red.), *Przemiany środowiska przyrodniczego Tatr. Część 2 - Nauki Biologiczne*, Tatrzański Park Narodowy i Polskie Towarzystwo Przyjaciół Nauk o Ziemi, Oddział Kraków, Wydawnictwo Instytutu Botaniki PAN w Krakowie, Kraków-Zakopane, s. 203-210.
- Kozłowska A., Plit J., Zagajewski B., 2006, High-mountain vegetation of the Tatras (central part). *Geographica Polonica "Vegetation maps as a tool in environmental assessment and spatial planning"*, Vol. 79, nr 1, Spring 2006. Polish Academy of Sciences Institute of Geography and Spatial Organization, Warsaw.
- Kramer H.J., 1994, Observation of the Earth and Its Environment. Survey of Missions and Sensors, Springer-Verlag, s. 580.
- Krówczynska M., 2004, Wykorzystanie spektralnych i strukturalnych cech obiektów odwzorowanych na zdjęciach satelitarnych w kartowaniu użytkowania ziemi. Promotor: prof. dr hab. Andrzej Ciołkosz. Wydział Geografii i Studiów Regionalnych UW, Warszawa, maszynopis.
- Kruse F.A., 1988, Use of Airborne Imaging Spectrometer data to map minerals associated with hydrothermally altered rocks in the northern Grapevine Mountains, Nevada and California. *Remote Sensing of Environment*, Vol. 24, s. 31-51.
- Kruse F.A., Boardman J.W., Huntington J.F., 1999, Fifteen years of hyperspectral data: Northern Grapevine Mountains, Nevada. W: *Proceedings of the 8th JPL Airborne Earth Science Workshop*. Jet Propulsion Laboratory Publication, JPL Publication 99-17, s. 247-258.
- Kruse F.A., Lefkoff A.B., 1993, Knowledge-based geologic mapping with imaging spectrometers. *Remote Sensing Reviews, NASA Innovative Research Program (IRP) results*, Vol. 8, s. 3-28.
- Kruse F.A., Lefkoff A.B., Boardman J.B., Heidebrecht K.B., Shapiro A.T., Barloon P.J., Goetz A.F.H., 1993, The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging Spectrometer Data. *Remote Sensing of Environment*, Vol. 44, s. 145-163.
- Kulikowski J.L., 1972, *Cybernetyczne układy rozpoznające*. PWN, Warszawa.
- Kumar L., Schmidt K., Dury S., Skidmore A., 2001, Imaging Spectrometry and Vegetation Science. W: F.D. van der Meer, S.M. de Jong (red.), *Imaging spectrometry: basic principles and prospective applications*. Kluwer Academic, Dordrecht, s. 405.
- Lang H.R., Adams S.L., Conel J.E., McGuffie B.A., Paylor E.D., Walker R.E., 1987, Multispectral remote sensing as stratigraphic tool, Wind River Basin and Big Horn Basin areas. *American Association of Petroleum Geologists Bulletin*, Vol. 71, nr 4, Wyoming, s. 389-402.
- Lange O., 1965, *Wstęp do cybernetyki ekonomicznej*. PWN, Warszawa, s. 178.
- Lawrence R.L., Wood S.D., Sheley R.L., 2006, Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (random forest). *Remote Sensing of Environment*, Vol. 100, nr 3, s. 356-362.
- Lettvin J.Y., Maturana H.R., McCulloch W.S., Pitts W.H., 1968, What the frog's eye tells the frog's brain. W: W.C. Corning, M. Balaban (red.), *The mind: biological approaches to its functions*, Wiley, New York, s. 233-258.
- Lichtenthaler H.K., Wellburn R.R., 1983, Determination of total carotenoids and chlorophylls a and b in leaf extracts in different solvents. *Biochemical Society Transactions*, Vol. 603, s. 591-592.
- Lu S., Oki K., Shimizu Y., Omasa K., 2007, Comparison between several feature extraction/classification methods for mapping complicated agricultural land use patches using airborne hyperspectral data. *International Journal of Remote Sensing*, Vol. 28, nr 5, s. 963-984.
- Lucieer A., 2006, Fuzzy classification of sub-Antarctic vegetation on Heard Island based on high-resolution satellite imagery. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS '06)*, Denver, Colorado, s. 2777-2780.
- Mader S., Vohland M., Jarmer T., Casper M., 2006, Crop classification with hyperspectral data of the HyMAP sensor using different feature extraction techniques. *Proceedings of the 2nd Workshop of the EARSeL SIG on Land Use and Land Cover, Center for Remote Sensing of Land Surfaces, EARSeL, Bonn*, s. 96-101.
- Mandic D.P., Chambers J.A., 2001, Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures, and Stability. *Adaptive and learning systems for signal processing, communications, and control*. John Wiley & Sons, New York, s. 318.
- McClelland J.L., Rumelhart D.E., PDP Research Group, 1986, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Vol. 2, MIT Press, Cambridge, MA.
- McCulloch W.S., Pitts W.H., 1943, A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, Vol. 5, s. 115-119.

- Minsky M., Papert S., 1969, *Perceptrons. An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, s. 258.
- Mirek Z., (red.), 1996, *Przyroda Tatrzańskiego Parku Narodowego*. Tatrzański Park Narodowy, Instytut Botaniki im. W. Szafera PAN. Kraków–Zakopane, s. 787.
- Morecki A., Ekiel J., 1979, *Cybernetyczne systemy ruchu kończyn zwierząt i robotów*. PWN, Warszawa, s. 275.
- Mueller A., 2005, Spectroscopy in Earth Observation: From Technology Demonstrators to Operational Services. 4th EARSeL Workshop on Imaging Spectroscopy, keynote lecture, Warsaw.
- Nolin A.W., Dozier J., 1993, Estimating snow grain size using AVIRIS data. *Remote Sensing of Environment*, Vol. 44, nr 2-3, s. 231-238.
- North P.R.J., 2002, Estimation of fAPAR, LAI and vegetation fractional cover from ATSR-2 imagery. *Remote Sensing of Environment*, Vol. 80, s. 114-121.
- Nowotka M., Kursa M.B., Rudnicki W.R., Zagajewski B., 2010 (w przygotowaniu). Application of Random Forests and Support Vector Machine algorithms for classification of land coverage in multi-environment using hyper-spectral data. maszynopis.
- Oldeland J., Dorigo W., Lieckfeld L., Lucieer A., Jürgens N., 2010, Combining vegetation indices, constrained ordination and fuzzy classification for mapping semi-natural vegetation units from hyperspectral imagery. *Remote Sensing of Environment*, Vol. 114, s. 1155–1166.
- Olesiuk D., Bachmann M., Habermeyer M., Heldens W., Zagajewski B., 2009, Crop classification with neural networks using airborne hyperspectral imagery. *Roczniki Geomatyki*, Vol. VII, nr 32. Warszawa, s. 107-112.
- Olesiuk D., Zagajewski B., 2008, Wykorzystanie obrazów hiperspektralnych do klasyfikacji pokrycia terenu zlewni Bystrzanki. *Teledetekcja Środowiska*, Tom 39, Klub Teledetekcji Środowiska PTG, Warszawa, s. 125-148.
- Osińska-Skotak K., Kruk M., Mróz M., Szumiło M., 2005, CHRIS/PROBA superspectral data for inland water quality studies. W: B. Zagajewski, M. Sobczak (red.), *Imaging Spectroscopy. New quality in environmental studies*, EARSeL, Warsaw University, s. 356-366.
- Osowski S., 1996, *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa, s. 352.
- Osowski S., 2006, *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza PW, Warszawa, s. 422.
- Pal M., Mather P.M., 2006, Some issues in the classification of DAIS hyperspectral data. *International Journal of Remote Sensing*, Vol. 27, nr 14, s. 2895-2916.
- Pawłowski B., 1956, *Flora Tatr. Rośliny naczyniowe*, T. I. PWN, Warszawa.
- Pawłowski B., Sokolowski M., Wallisch K., 1928, Zespoły roślin w Tatrach, Cz. VII. Zespoły roślinne i flora doliny Morskiego Oka. *Rozprawy Wydziału Matematyczno-Przyrodniczego PAU*, Tom 67, PAU, Kraków, s. 171-311.
- Petykiewicz J., 1986, *Optyka falowa*. PWN, Warszawa, s. 278.
- Pieters C.M., Mustard J.F., 1988, Exploration of crustal/mantle material for the Earth and Moon using reflectance spectroscopy. *Remote Sensing of Environment*, Vol. 24, s. 151-178.
- Plummer S. E., North P. R. J., Briggs, S. A., 1994, The Angular Vegetation Index: an atmospherically resistant index for the second along track scanning radiometer (ATSR-2). *Proceedings of the 6th Symposium on Physical Measurements and Spectral Signatures in Remote Sensing*, CNES, Toulouse, s. 717-722.
- Proceedings of the AVIRIS performance Evaluation Workshop, 1988. The Jet Propulsion Laboratory, JPL 83-88, s. 184 (<ftp://popo.jpl.nasa.gov/pub/docs/workshops/aviris.proceedings.html>).
- Ramachandra T.V., Uttam K., 2005, Image Fusion in GRDSS for Land Cover Mapping. *Geomatics*. Map India, New Delhi, s. 1-22.
- Ray T.W., Murray B.C., 1996, Nonlinear Spectral Mixing in Desert Vegetation. *Remote Sensing of Environment*, Vol. 55, s. 59-64.
- Richter R., 2004, Atmospheric/topographic correction for airborne imager. *ARTCOR-4 User Guide*, Version 3.1. DLR, German Aerospace Center, Remote Sensing Data Center, s. 75.
- Richter R., Schläpfer D., 2002, Geo-atmospheric processing of airborne imaging spectrometry data. Part 2: Atmospheric/Topographic Correction. *International Journal of Remote Sensing*, Vol. 23, no. 13, s. 2631-2649.
- Roberts D.A., Smith M.O., Adams, J.B., 1993, Green vegetation, nonphotosynthetic vegetation, and soils in AVIRIS data. *Remote Sensing of Environment*, Vol. 44, s. 255-269.
- Rocki K., 2007, *Zastosowanie sieci neuronowych typu ART do lokalizacji i rozpoznawania obiektów przy użyciu sygnału wizyjnego*. Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych, Instytut Automatyki i Informatyki Stosowanej, Warszawa. Praca inżynierska napisana pod opieką prof. dr hab. Cezarego Zielińskiego, s. 83.
- Rosenblatt F., 1958, The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, Vol. 65, nr 6. Cornell Aeronautical Laboratory, s. 386-408.
- Ruban A.V., Horton P., Young A.J., 1993, Aggregation of higher plant xanthophylls: Differences in absorption spectra and in the dependency on solvent polarity. *Journal of Photochemistry and Photobiology*, B: Biology, Vol. 21, nr 2-3, s. 229-234.
- Rumelhart D.E., McClelland J.L., PDP Research Group, 1986, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Vol. 1, MIT Press, Cambridge, MA
- Russell S.J., Norvig P., 2003, *Artificial Intelligence. A Modern Approach*. Upper Saddle River, NJ: Prentice Hall, s. 1132.
- Rutkowska D., Piliński M., Rutkowski L., 1997, *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Wydawnictwo Naukowe PWN, Warszawa.
- Schaepman M.E., 1996, Michael Schaepman's Comprehensive List of Imaging Spectrometers. http://www.geo.unizh.ch/~schaep/research/apex/is_list.html. 06.11.1996.
- Schläpfer D., Richter R., 2002, Geo-atmospheric Processing of Airborne Imaging Spectrometry Data Part 1: Parametric Orthorectification. *International Journal of Remote Sensing*, Vol. 23, nr 13, s. 2609-2630.
- Schmidtlein S., Zimmermann P., Schüpferling R., Weiß C., 2007, Mapping the floristic continuum: Ordination space position estimated from imaging spectroscopy. *Journal of Vegetation Science*, Vol. 18, s. 131-140.

- Schwarz J., Staenz K., 2001, Adaptive threshold for spectral matching of hyperspectral data. *Canadian Journal of Remote Sensing*, Vol. 27, s. 216-224.
- Schwengerdt R.A., 1997, *Remote sensing: models and methods for image processing*. Academic Press, New York, s. 447.
- Seibert P., 1974, Die Rolle des Masstabes bei der Abgrenzung von Begetationseinheiten. W: W.H. Sommer, R. Tuexen (red.), *Tatsachen und Probleme der Grenzen in der Vegetation. Bericht ueber das Internationale Symposium der Internationalen Vereinigung fuer Vegetationskunde in Rinteln 8-11 April 1968*, Verlag J. Cramer, Lehre, s. 103-118.
- Sevrani F., Abe K., 2000, On the Synthesis of Brain-State-in-a-Box Neural Models with Application to Associative Memory. *Neural Computation*, Vol. 12, nr 2. MIT Press Cambridge, MA, s. 451-472.
- Shaw D.T., Malthus T.J., Kupiec J.A., 1998, High-spectral resolution data for monitoring Scots pine (*Pinus sylvestris* L.) regeneration. *International Journal of Remote Sensing*, Vol. 19, nr 13, s. 2601-2608.
- Shepard R.D., 1962, The analysis of proximities: Multidimensional scaling with an unknown distance function. *Psychometrika*, vol. 27, s. 219-246.
- Sitek Z., 1992, *Zarys Teledetekcji lotniczej i satelitarnej*. Część I – Pozyskiwanie danych, Część II – Przetwarzanie danych. Skrypty uczelniane, nr 1239. Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH, Kraków, s. 304.
- Sitek Z., 2000, *Wprowadzenie do teledetekcji lotniczej i satelitarnej*. Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH, Kraków, s. 354.
- Słownik Geoinformatyczny PAU, 2001, *Wielojęzyczny interdyscyplinarny terminologiczny słownik i leksykon geoinformatyczny*. Dział fotogrametria i teledetekcja. Wersja internetowa. <http://sownik.fotogrametria.agh.edu.pl/index.php>. (28.03.2007).
- Solberg R., Wężyk P., 2000, Forest Environmental Monitoring and Management System „FOREMMS” – contribution to the development of sustainable use of natural resources. W: S. Zihlavnik, L. Scheer (red.), *Application of Remote Sensing in Forestry*, Zvolen, Slovakia, s. 241-255.
- Strobl P., Richter R., Lehmann F., Müller A., Zhukov B., Oertel D., 1996, Preprocessing for the Airborne Imaging Spectrometer DAIS 7915. *SPIE Proceedings*, Vol. 2758, s. 375-382.
- Suits G.H., 1983, The nature of electromagnetic radiation. W: R.N. Colwell (red), *Manual of remote sensing*, Vol. 1, ASPRS, Falls Church, Virginia, USA.
- Swain P.H., Davis S.M., 1978, *Remote Sensing: The Quantitative Approach*. McGraw-Hill Inc, s. 396.
- Szafer W., Pawłowski B., Kulczyński S., 1923, Zespoły roślin w Tatrach. Cz. I. Zespoły roślin w Dolinie Chochołowskiej. *Bulletin International de l'Academie Polonaise des Sciences et des Lettres, Classe des Sciences Mathématiques et Naturelles*. Serie B., Suppl. III, s. 1-66.
- Szafer W., Pawłowski B., Kulczyński S., 1927, Zespoły roślin w Tatrach. Cz. I. Zespoły roślin w Dolinie Kościeliskiej. *Bulletin International de l'Academie Polonaise des Sciences et des Lettres, Classe des Sciences Mathématiques et Naturelles*. Serie B., Suppl. II, s. 13-78.
- Szostak W., 1978, *Cybernetyka społeczna*. Skrypty Uczelniane Nr 300. Uniwersytet Jagielloński, Kraków, s. 136.
- Tadeusiewicz R., 1993, *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa, s. 130.
- Tadeusiewicz R., Flasiński M., 1991, *Rozpoznawanie obrazów*. PWN, Warszawa, s. 217.
- Tadeusiewicz R., Gąciarz T., Borowik B., Leper B., 2007, *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*. PAU MKNT, Kraków, s. 428.
- Taranik J.V., Settle M., 1981, Space Shuttle: A New Era in Terrestrial Remote Sensing. *Science*, Vol. 214, nr 4521, s. 619–626.
- Thenkabail P.S., Enclona E.A., Ashton M.S., van der Meer B., 2004, Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. *Remote Sensing of Environment*, Vol. 91, s. 354-376.
- Tian Q., Tong Q., Pu R., Guo X., Zhao C., 2001, Spectroscopic determination of wheat water status using 1650-1850 nm spectral absorption features. *International Journal of Remote Sensing*, Vol. 22, s. 2329-2338.
- Trianni G., 2007, *Techniques for fusion of remotely sensed data over urban environments*, Università Degli Studi Di Pavia, Dottorato Di Ricerca in Ingegneria Elettronica Elettrica ed Informatica, XX Ciclo, Praca doktorska, promotor prof. dr Paolo Gamba, Pavia, s. 140.
- Tsai F.; Lin E.-K., Yoshino K., 2007, Spectrally segmented principal component analysis of hyperspectral imagery for mapping invasive plant species. *International Journal of Remote Sensing*, Vol. 28, s. 1023-1039.
- van der Meer F., Vasquez-Torres M., Van Dijk P.M., 1997, Spectral characterization of ophiolite lithologies in the Troodos Ophiolite Complex of Cyprus and its potential in prospecting for massive sulphide deposits. *International Journal of Remote Sensing*, Vol. 18, nr 6, s. 1245-1257.
- van der Meer F.D., de Jong S.M. (red.), 2001, *Imaging spectrometry: basic principles and prospective applications*. Kluwer Academic, Dordrecht, s. 405.
- Vane G., Goetz A.F.H., 1993, Terrestrial Imaging Spectroscopy: Current Status, Future Trends. *Remote Sensing of Environment*, Vol. 44, s. 117-126.
- Vane G., Porter W.M., Reimer J.H., Chrien T.G., Green R.O., 1988, AVIRIS performance during the 1987 flight season: an AVIRIS project assessment and summary of the NASA – sponsored performance evaluation. *Proceedings of the AVIRIS performance Evaluation Workshop*. The Jet Propulsion Laboratory, JPL 83-88, s. 1-20.
- Walthall C.L., 2008, Sources of imagery. W: *Airborne Remote Sensing Basics. Simple tools for checking image data quality*, USDA-ARS, Hydrology and Remote Sensing Lab, Beltsville, Maryland. <http://hydrolab.arsusda.gov/rsbasics/index.php>.
- Werbos P., 1994, The roots of backpropagation: from ordered derivatives to neural networks and political forecasting (adaptive and learning systems for signal processing, communications and control series). John Wiley and Sons, New York, s. 342.
- Wężyk P., Wertz B., 2005, Forest map revision using the hyperspectral scanner AISA images. W: B. Zagajewski, M. Sobczak (red.), *Imaging Spectroscopy. New Quality in Environmental Studies*, EARSeL, Warsaw University, Warsaw, s. 687-699.
- Wężyk P., Wertz B., Waloszek A., 2003, Skaner hiperspektralny AISA (Airborne Imaging Spectrometer for Applications) jako narzędzie pozyskiwania informacji o ekosystemie

- leśnym. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 13 B., Fotogrametria bliskiego i dalekiego zasięgu, s. 477-496.
- Wood S.D., Lawrence R.L., Sheley R.L., 2006, Mapping invasives plants using hyperspectral imagery, classification trees, and classification thresholds. *Proceedings of ASPRS 2006 Annual Conference*, Reno, Nevada, s. 1-9.
- Wullschleger S.D., Wilson K.B., Hanson P.J., 2000, Environmental control of whole-plant transpiration, canopy conductance and estimates of the decoupling coefficient for large red maple trees. *Agricultural and Forest Meteorology*, Vol. 104, s. 157-168.
- Zadeh L.A., 1965, Fuzzy sets. *Information and Control*, Vol. 8, s. 338-353.
- Zadeh L.A., 1972, A fuzzy-set-theoretical interpretation of linguistic hedges. *Journal of Cybernetics*, Vol. 2, s. 4-34.
- Zagajewski B., Jarocińska A., Olesiuk D., 2009, *Metody i techniki badań geoinformatycznych*, Wydział Geografii i Studiów Regionalnych UW. Warszawa, s. 118. Wydanie elektroniczne http://telegeo.wgsr.uw.edu.pl/bz/Zagajewski_Jarocinska_Olesiuk_cpo_2.pdf.
- Zagajewski B., Kozłowska A., Krowczyńska M., Sobczak M., Wrzesień M., 2005, Mapping high mountain vegetation using hyperspectral data. *EARSel eProceedings*, Vol. 4, nr 1, s. 70-78.
- Zagajewski B., Lechnio J., Sobczak M., 2007, Wykorzystanie teledetekcji hiperspektralnej w analizie roślinności zanieczyszczonej metalami ciężkimi. *Teledetekcja Środowiska*, Tom 37, Klub Teledetekcji Środowiska PTG, Warszawa, s. 82-100.
- Zagajewski B., Sobczak M., 2003, Field remote sensing techniques for mountains vegetation investigation. *Proceedings of the 3rd EARSel Workshop on Imaging Spectroscopy*, Oberpfaffenhofen, s. 580-596.
- Zagajewski B., Sobczak M., Próchnicki W. (red.), 2005, *4th Workshop on Imaging Spectroscopy. New Quality in Environmental Studies. Abstract Book*. EARSel & Warsaw University, Warsaw, s. 164.
- Zagajewski B., Sobczak M., Wrzesień M., 2004, Badania górskich zbiorowisk roślinnych z użyciem technik hiperspektralnych. *Przegląd Geofizyczny*, Tom XLIX, PWN, Warszawa, s. 115-129.
- Zagajewski B., Sobczak M., Wrzesień M., Kozłowska A., Krówczyńska M., 2006, Kartowanie górskich zbiorowisk roślinnych z użyciem zobrażeń hiperspektralnych DAIS7915. W: Z. Mirek, B. Godzik (red.), *Tatrzański Park Narodowy na tle innych górskich terenów chronionych*. Tom II. Nauki biologiczne. TPN, PTPNoZ – Oddział Krakowski, Zakopane, s. 137-150.
- Żurada J., Barski M., Jędruch W., 1996, *Sztuczne sieci neuronowe. Podstawy teorii i zastosowania*. PWN, Warszawa, s. 376.



Dr Bogdan Zagajewski, adiunkt w Katedrze Geoinformatyki i Teledetekcji (wcześniej Zakład Teledetekcji Środowiska) Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Zainteresowania naukowe koncentrują się wokół teledetekcji i SIG i ich zastosowań w badaniach środowiska. Od roku 2002 zajmuje się technikami hiperspektralnymi w badaniach nad roślinnością. Dane kontaktowe: e-mail: bogdan@uw.edu.pl, tel. 022 5521507, fax 022 5521521, http://telegeo.wgsr.uw.edu.pl/bz/bz_pl.html

Akronimy *Acronyms*

AAHIS – Advanced Airborne Hyperspectral Imaging System	BAM – Bidirectional Associative Memory
ABL – Atmospheric Boundary Layer	BCC – Beiman Cutler Classification
ADALINE – ADaptive LInear Neuron (Adaptive Linear Element)	BRDF – Bidirectional Reflectance Distribution Function
ADSM – Adstar Distributed Storage Manager	BSQ – Band Sequential in one file
AHS – Airborne Hyperspectral Scanner	CAESAR – CCD Airborne Experimental Scanner for Applicators in Remote Sensing
AI – Artificial Intelligence	CASI – Compact Airborne Spectrographic Imager
AIP – Airborne Instrument Program	CHRIS – Compact High Resolution Imaging Spectrograph Sensor
AIS – Airborne Imaging Spectrometer	CIS – Chinese Imaging Spectrometer
AISA – Airborne Imaging Spectrometer for Applications	CSES CIRES – Centre for the Study of Earth from Space, Cooperative Institute for Research in Environmental Sciences (University of Colorado)
AISA Dual – Airborne Imaging Spectrometer for Applications (sensor AISA – Eagle and AISA Hawk)	DAIS 7915 – Digital Airborne Imaging Spectrometer (79 kanałów, 15 bitów)
AMS – Airborne Modis Simulator	DBFE – decision boundary feature extraction
AMSS – Airborne Multispectral Scanner MK-II	DGPS – Differential Global Positioning System (różnicowy GPS)
ANN – Artificial Neural Network	DLR – Deutsches Luft und Raumfahrt Zentrum (Niemiecka Agencja Kosmiczna)
APAR – Absorbed Photosynthetically Active Radiation	DN – Digital Number (jasność piksela)
APEX – Airborne Prism Experiment	EARSeL – European Association of Remote Sensing Laboratories
APPI – Automatic Pixel Purity Index	EARSeL SIG IS – European Association of Remote Sensing Laboratories, Special Interest Group, Imaging Spectroscopy
ARES – Airborne Reflective Emissive Spectrometer	EEAs – Endmember Extraction Algorithms
ART – Adaptive Resonance Theory	EnMAP – Environmental Mapping and Analysis Program
ASAS – Advanced Solid State Array Spectroradiometer	ENNS – European Neural Network Society
ASD – Analytical Spectral Devices	EPS – Environmental Probe System
ASI – Airborne Spectral Imager	FAM – fuzzy ARTMAP
ASI (ISA)– Agenzia Spaziale Italiana	fAPAR – fraction of Absorbed Photosynthetically Active Radiation
ASPRS – American Society for Photogrammetry and Remote Sensing	
ATCOR – ATmospheric CORrection	
ATM – Airborne Thematic Mapper	
AVI – Angular Vegetation Index	
AVIRIS – Airborne Visual and Infra-Red Imaging Spectrometer	

- FIPPI – Fast Iterative PPI
 FLI – Fluorescence Line Imager
 FLVQ – Fuzzy Learning Vector Quantization
 FOV – Field Of View
 FTVFHSI – Fourier Transform Visible Hyperspectral Imager
 GERIS – Geophysical and Environmental Research Imaging Spectrometer
 GERS – Geophysical Environmental Research Spectroradiometer
 GFOV Ground Field of View
 GFZ – GeoForschungsZentrum Potsdam (Niemcy)
 HIRIS – High Resolution Imaging Spectrometer
 HSI – Hyperspectral Imager
 HYDICE – Hyperspectral Digital Imagery Collection Experiment
 HyMAP – Hyperspectral Mapper (w Stanach Zjednoczonych znany jako Probe-1)
 Hyper-i-net – Hyperspectral Imaging Network
 HYRESSA – HYperspectral REMote Sensing in Europe
 HySpex – HySpex Hyperspectral Cameras (zestaw 4 modułów z zakresu VIS, SWIR)
 IDL – Interactive Data Language
 IFOV – Instantaneous Field of View (chwilowe pole widzenia detektora)
 IISRB – Infrared Imaging Spectrometer
 IMSS – Image Multispectral Sensing
 InGaAs – Indium-Gallium-Arsenide
 INS – Inertial Navigation System (Inercyjny system nawigacji)
 IRIS – Infrared Imaging Spectroradiometer
 ISM – Imaging Spectroscopic Mapper
 ISPRS – International Society for Photogrammetry and Remote Sensing
 LEISA – Linear Etalon Imaging Spectral Array
 LIVTIRS – Livermore Imaging Fourier Transform Imaging Spectrometer
 LSBS – La Selva Biological Station
 LTM – Long Term Memory
 LUE – Light Use Efficiency
 MADALINE – Many ADALINE
 MAE – Mean Absolute Error
 MAIS – Modular Airborne Imaging Spectrometer
 MAMS – Multispectral Atmospheric Mapping Sensor
 MAS – MODIS Airborne Simulator
 MERIS – Medium Resolution Imaging Spectrometer
 MF – Matched Filtering
 MIDIS – Multiband Identification and Discrimination Imaging Spectroradiometer
 MIT – Massachusetts Institute of Technology
 MIVIS – Multispectral Infrared and Visible Imaging Spectrometer
 MLP – Multi Layer Perceptron
 MNF – Minimum Noise Fraction
 MODIS – Moderate Resolution Imaging Spectrometer
 MSE – Mean Squared Error
 MSG – Meteosat Second Generation
 MTMF – Mixture Tuned Matched Filter
 NEO – Norsk Elektro Optikk AS
 NIR – Near Infrared
 NMS – Non-Metric Multidimensional Scaling
 NMT – Numeryczny Model Terenu
 OMIS – Operative Modular Airborne Imaging Spectrometer
 PAR – Photosynthetically Active Radiation
 PARGE – PARAmetric GEocoding
 PAU – Polska Akademia Umiejętności
 PCA – Principal Component Analysis
 PMI – Programmable Line Imager
 PPI – Pixel Purity Index
 PRI – Photochemical Reflectance Index
 PRISMA – PRekursore IperSpettrale della Missione Applicativa (Hyperspectral Precursor of the Application Mission)
 PSI – Plant Stress Index
 RBFE – Recursive Backward Feature Elimination
 RF – Random Forest
 RNN – Recurrent Neural Network
 ROSIS – Reflective Optics System Imaging Spectrometer
 RTC – Radiative Transfer Codes
 RTRN – Real-Time Recurrent Network
 SAM – Spectral Angle Mapper
 SASI – Shortwave (Infrared) Airborne Spectrographic Imager
 SFCM – Supervised Fuzzy C-Means Classifier
 SFSI – SWIR Full Spectrographic Imager
 SIPS – Spectral Image Processing System
 SMIFTS – Spatially Modulated Imaging Fourier Transform Spectrometer
 SNARC – Stochastic Neural Analog Reinforcement Calculator
 SNNS – Stuttgart Neural Network Simulator
 SNR – Signal to Noise Ratio
 SOM – Self Organising Maps
 SPECIM – Spectral Imaging LTD
 SSE – Sum Squared Error
 SSN – Sztuczne Sieci Neuronowe
 SSTI HSI – Small Satellite Technology Initiative Hyperspectral Imager
 STM – Short Term Memory
 SVM – Support Vector Machine
 SWIR – Shortwave Infrared
 TIMS – Thermal Infrared Multispectral Scanner
 TRWIS – TRW Imaging Spectrometer
 UTM – Universal Transverse Mercator
 UTM – Universal Turing Machine
 UV – Ultraviolet
 VD – Virtual Dimensionality
 VIFIS – Variable Interference Filter Imaging Spectrometer
 VIMS – Visible Infrared Mapping Spectrometer
 WIS – Wedge Imaging Spectrometer
 WPHI – Wide-view Pushbroom Hyperspectral Imagery
 WTA – Winner Takes All
 WTM – Winner Takes Most

INFORMACJA DLA AUTORÓW

Teledetekcja Środowiska zamieszcza prace naukowe z zakresu teledetekcji środowiska poświęcone wykorzystaniu zdjęć lotniczych i satelitarnych oraz innych danych teledetekcyjnych i fotogrametrycznych w badaniach szeroko rozumianego środowiska naturalnego i antropogenicznego oraz w jego ochronie, a także poświęcone zagadnieniom z pogranicza teledetekcji i nauk o Ziemi. Materiały przeznaczone do publikacji powinny być przesłane pod adres: Redakcja *Teledetekcji Środowiska*, Klub Teledetekcji Środowiska PTG, Krakowskie Przedmieście 30, 00-927 Warszawa. Wszystkie nadesłane prace są recenzowane. Redakcja zastrzega sobie prawo wyboru prac i dokonywanie, w porozumieniu z autorem, niezbędnych zmian i skrótów. W przypadku przyjęcia tekstów do druku Redakcja zastrzega sobie prawo do wnoszenia niewielkich koniecznych poprawek w ramach pracy edytorskiej nad maszynopisem.

Do maszynopisu należy dołączyć informacje o autorze, jego miejscu pracy, numerze telefonu, faksu, e-mailu oraz zdjęcie. Autor powinien dołączyć oświadczenie, odnośnie oryginalności zgłoszonego do druku opracowania.

Możliwe jest publikowanie tekstów w języku angielskim. Warunkiem jest nadesłanie tekstu w tymże języku oraz jego skrótu (do 20% objętości tekstu podstawowego), dotyczy to autorów zagranicznych lub w języku polskim (od autorów polskich).

Prace powinny być dostarczone w formie maszynopisu na papierze w formacie A4 oraz zapisu na płycie CD lub DVD w standardzie IBM PC. Teksty powinny być pisane bez przenoszenia wyrazów i wyrównywania do prawego marginesu.

Na pierwszej stronie maszynopisu należy podać kolejno: tytuł pracy i jego tłumaczenie na język angielski, imię oraz nazwisko autora oraz słowa kluczowe.

Spis literatury powinien być ułożony alfabetycznie (bez numeracji) w następującym układzie: nazwisko autora, inicjały imion, przecinek, rok wydania, przecinek, tytuł publikacji, przecinek, nazwa czasopisma, numer tomu, numer zeszytu, lub tytuł monografii, w której zamieszczona jest cytowana praca, nazwa wydawnictwa, strony. W tekście obowiązuje cytowanie, przez podanie nazwiska i roku, np. G. Ambroziak (1979) – przy powoływaniu się na cytowanego autora lub (Ambroziak, 1979; Kozal, 1994) przy powoływaniu się na poglądy autorów zajmujących się daną kwestią. Literatura w języku rosyjskim powinna być podana w międzynarodowej transkrypcji, z zaznaczeniem w nawiasie (in Russian).

Do artykułu należy dołączyć notę biograficzną z adresem kontaktowym autora oraz zdjęcie autora.

Tabele powinny być wyłączone z tekstu, ponumerowane liczbami arabskimi i zaopatrzone w umieszczone nad nimi tytuły. Tytuły tabel i zawarte w nich objaśnienia tekstowe powinny być podane zarówno w języku polskim jak i angielskim (dotyczy autorów polskich), w przypadku autorów zagranicznych tylko w języku angielskim. Figury (rysunki, wykresy, szkice mapy i fotografie) powinny mieć podane numery i nazwiska autorów (napisane ołówkiem), np. „Ryc./Fig. 2A, Bekas”. Ich wielkość i jakość powinna być taka, aby po zmniejszeniu do kolumny lub szpalty tj. maksymalnie do rozmiaru 17,5 x 25 lub 8,5 x 25 cm były czytelne. Objaśnienia w obrębie figur muszą być podane w języku polskim i angielskim (dotyczy autorów polskich) lub tylko w angielskim (dotyczy autorów zagranicznych). Tytuły i dodatkowe objaśnienia figur powinny być napisane na oddzielnej kartce w języku polskim i angielskim (dotyczy autorów polskich) lub tylko w angielskim (dotyczy autorów zagranicznych).

Przypisy cytowane u dołu strony powinny być oznaczone numeracją, ciągłą, i zamieszczone na końcu maszynopisu.

INFORMATION FOR AUTHORS

Teledetekcja Środowiska publish scientific works dealing with environmental remote sensing, the use of air and satellite photography, and other remote sensing and photogrammetric data applied in the study of natural environment in a broad perspective. These also include anthropogenic studies, environmental protection and themes bordering remote sensing and Earth sciences. The reviews of publications are also welcome as well as reports from conferences. The material for publication should be submitted to: Redakcja *Teledetekcja Środowiska*, Klub *Teledetekcji Środowiska* PTG, Krakowskie Przedmieście 30, 00-927 Warszawa.

The Editors reserve themselves the right to select the submitted materials and effect in cooperation with the authors the necessary changes or cuts. The Editors may also introduce minor but necessary corrections in accepted for publication texts, in accordance with the rules of processing the manuscript for print.

The size of the manuscript should not exceed 40 type-written standard A4 pages, together with summary, figures, illustrations, and also recorded on disk CD or DVD in IBM PC standard. Text should be written without word transposition and right margin even up.

It is possible to publish a text in English under the condition that a text will be submitted in English along with an abbreviation ca 20% of a basic text, in English from foreign authors, and in Polish from Polish authors.

On the first page write: title of paper and its translation into English and initials and surname of the author and key words.

Bibliography arranged in alphabetic order (without numerals) in the following manner: authors surname, initials, year of publication, colon title of publication, full stop title of journal, number of volume, number of copy – or monograph title in which the quoted paper was contained, name of publisher, pages. Quotation in text, if citing the author – name and year, e.g. G. Ambroziak (1979) or (Ambroziak, 1979; Kozal, 1994) when referring to the opinion of the authors specializing in the given subject. Russian bibliography should be written in accordance with international transcription, marked in brackets (in Russian).

To the manuscript please to attach a piece of author's information and its photo.

Tables should be separated from text, numbered in Arabic and having titles above. Titles and explanations must be in English and Polish. Foreign authors – write only in English.

Figures (drawings, curves, schemes, maps and photographs) should have numbers and author's name, written by pencil, e.g. „Fig. 2A, Bekas”. Size and quality should enable, if necessary, the reduction to 17.5 x 25 cm or 8.5 x 25 cm and remain easy readable. Explanations of Figures must be in Polish and in English, foreign authors – only in English. Titles and separate sheet, in Polish and in English, foreign authors – only in English.

References quoted down the page should be numbered in sequence and attached by the end of manuscript.

