


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 głązy) dołożono 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 fitysocjologiczne, 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 posilkowano 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 RBEF (*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 górnoeregłowy
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 wydzieli (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>epilotic 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 – Oreochloa distichae-Juncetum trifidi subnivale form</i>	1876	2727	68,8
8	murawa alpejska typowa <i>Oreochloa distichae-Juncetum trifidi typicum</i>	6554	11624	56,4
9	murawa alpejska porostowa <i>Oreochloa distichae-Juncetum trifidi cetrarietosum</i>	483	1459	33,1
10	fragmenty muraw alpejskich na półkach skalnych <i>Oreochloa distichae-Juncetum trifidi – vegetation fragments on rocky shelves</i>	873	47501	1,8
11	murawa alpejska torfowcowa <i>Oreochloa distichae-Juncetum trifidi sphagnetosum</i>	689	3867	17,8
12	murawa alpejska wyleżyskowa <i>Oreochloa distichae-Juncetum trifidi salicetosum herbaceae</i>	426	896	47,5
13	murawa alpejska z wierzbą Kitaibela <i>Oreochloa distichae-Juncetum trifidi salicetosum kitaibeliana</i>	622	1807	34,4
14	murawa alpejska postać piargowa z sitem skuciną <i>Oreochloa distichae-Juncetum trifidi scree form with Juncus trifidus</i>	3997	9865	40,5
15	murawa alpejska z turzycą zawsze zieloną <i>Oreochloa distichae-Juncetum trifidi caricetosum sempervirentis</i>	2358	3740	63,0
16	murawa alpejska postać subalpejska <i>Oreochloa distichae-Juncetum trifidi subalpine anthropogenic form</i>	4943	9297	53,2
17	murawa alpejska w kompleksie z wyleżyskami <i>Oreochloa distichae-Juncetum trifidi in a complex with snow-bed communities</i>	4498	10128	44,4
18	murawa alpejska w kompleksie z traworoślami <i>Oreochloa 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>Oreochloa 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	Ziólorośla <i>tall herb communities – Adenostylin</i>	1128	1933	58,4
29	wilgotne murawy w kompleksie z wyleżyskami i zióloroślami <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 zióloroślami <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 obrazowania 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 obrazowania 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 filtrującą 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). Równolegle 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 zmniejszało 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 $\langle 0,1 \rangle$. 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 czułości 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 mikselami 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 klas trów wyodrębnionych w ARTa i ARTb²⁰. W przypadku relacji wektora y_i^a z warstwy 2 ARTa z dwoma wektorami y_i^b, y_z^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_z^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 czułości ρ , ponadto w trakcie trenowania sieci następują modyfikacje wartości i liczby wydzieleni. 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).