

Jerzy Chmiel

## PRZYKŁAD WYKORZYSTANIA SIECI NEURONOWYCH W CYFROWEJ KLASYFIKACJI POKRYCIA TERENU

*Streszczenie.* W referacie przedstawiono metodę analizy cyfrowej wykorzystującą sieci neuronowe w zastosowaniu do klasyfikacji pokrycia terenu w dość urozmaiconym i zarazem skomplikowanym obszarze zlewni rzeki Krutyni. Wyniki klasyfikacji pokrycia terenu z wykorzystaniem sieci neuronowych zostały porównane z wynikami klasyfikacji w oparciu o klasyczny algorytm 'maksymalne prawdopodobieństwo'.

### 1. Wprowadzenie.

Do podstawowych źródeł danych przy opracowywaniu map pokrycia terenu zalicza się zdjęcia lotnicze i satelitarne, mapy topograficzne oraz mapy tematyczne. Istniejące metody opracowania map pokrycia terenu w różny sposób wykorzystują wspomniane źródła danych.

Zdjęcia lotnicze czy satelitarne zawierają w zdecydowanie większym stopniu informacje o pokryciu terenu niż o użytkowaniu. Stąd przetwarza się je przede wszystkim dla uzyskania map pokrycia terenu, a te z kolei (jako produkt pośredni) po włączeniu dodatkowych informacji (także z rekonesansu terenowego) mogą służyć opracowaniu map użytkowania ziemi.

Mapy pokrycia terenu wykonane na podstawie map topograficznych są dla wielu aplikacji z reguły niewystarczającym źródłem informacji z uwagi na stan aktualności, ale również ze względu na zgeneralizowaną formę przekazu. Dlatego też częstą praktyką jest opracowanie mapy pokrycia terenu w oparciu o aktualne dane teledetekcyjne z różnych (w zależności od potrzeb) systemów satelitarnych.

Z punktu widzenia możliwości wykorzystania teledetekcji w omawianym zakresie, mapa pokrycia terenu stanowi jeden z jej podstawowych produktów, będący rezultatem najczęściej cyfrowego przetwarzania (klasyfikacji) zdjęć satelitarnych lub lotniczych.

U podstaw klasyfikacji są reguły zgodnie z którymi określony charakter odpowiedzi spektralnej może być identyfikowany z danym typem pokrycia terenu. Reguły te funkcjonują poprawnie jeśli istnieją dość wyraźne różnice w odpowiedzi spektralnej dla obiektów tematycznie odmiennych (należących do różnych, umownie definiowanych klas) a z drugiej strony obiekty współtworzące daną klasę, cechuje duże podobieństwo odpowiedzi spektralnej.

Spełnienie tak nakreślonych wymogów w rzeczywistości nie zawsze jest w pełni możliwe co wpływa na poprawność rezultatu klasyfikacji. Stąd różnorodność istniejących metod i algorytmów klasyfikacji oraz poszukiwanie doskonalszych rozwiązań w tej dziedzinie.

Klasyczne metody klasyfikacji i inne rodzaje przetworzeń zdjęć nie zawsze przynoszą zadawalające rezultaty, szczególnie w obszarach o złożonej strukturze przestrzennej i o wysoce niejednorodnej charakterystyce spektralnej obiektów. Wśród typowych przykładów takich obszarów można wymienić tereny zabudowane (zwłaszcza na obszarach wiejskich), niektóre rodzaje obszarów podmokłych, określone zbiorowiska roślinne, itp. W celu podniesienia dokładności klasyfikacji, a tym samym poprawności odtworzenia zróżnicowania pokrycia terenu w tych trudniejszych przypadkach, literatura przedmiotu wskazuje na podejścia i metody analizy obrazów, które mogą zwiększyć dokładność opracowań, wykorzystując między innymi:

- dodatkowe źródła informacji (np. już istniejące warstwy tematyczne GIS) oraz deklaratywne formy wiedzy (np. o zależnościach między elementami krajobrazu a ich determinantami),
- w większym stopniu kontekst przestrzenny elementów obrazu (pikseli),
- łączenie danych o różnej rozdzielczości przestrzennej i spektralnej,
- algorytmy nieparametryczne.

Znane i szeroko stosowane w praktyce algorytmy parametryczne (oparte na parametrach statystycznych) zakładają istnienie rozkładu normalnego Gaussa dla zbiorów pikseli tworzących poszczególne klasy. Założenie to pozwala estymować parametry tego rozkładu (jako nieznanne) na podstawie pobranych prób w postaci pikseli pól treningowych dla kolejnych klas identyfikowanych w rozpatrywanym obszarze. Klasycznym przykładem jest często stosowany w praktyce algorytm z kryterium decyzyjnym opartym na maksymalnym prawdopodobieństwie przynależności (określonym funkcją gęstości prawdopodobieństwa) piksela do klasy. W większości przypadków jest to najskuteczniejszy algorytm spośród algorytmów parametrycznych. Algorytmy nieparametryczne nie wymagają powyższego założenia o charakterze rozkładu.

W większości przypadków wspomniane założenie o rozkładzie normalnym pikseli poszczególnych klas jest w przybliżeniu spełnione. Jednakże w obszarach o bardziej złożonej charakterystyce pokrycia terenu i dużej jej zmienności nie zawsze postulatywny z natury podział obiektów przestrzeni spektralnej na klasy informacyjne (tematyczne) i odpowiadająca mu (nie koniecznie trafna) reprezentacja w postaci wybranych przez użytkownika pól treningowych spełniają wymogi postawionego założenia o charakterze normalnym rozkładu. W dużej mierze o sukcesie takiej klasyfikacji przesądza doświadczenie i profesjonalizm przeprowadzającego klasyfikację. Dlatego poszukuje się również alternatywnych metod i algorytmów klasyfikacji, które nie wymagałyby tak istotnego dla algorytmów parametrycznych

założenia. Obiecującym w tym zakresie rozwiązaniem są algorytmy oparte na sieciach neuronowych należące do algorytmów nieparametrycznych.

W celu dokonania oceny możliwości cyfrowej analizy z wykorzystaniem sieci neuronowych w klasyfikacji pokrycia terenu w dość urozmaiconym (w znaczeniu zróżnicowania spektralnego obiektów) i skomplikowanym (w sensie struktury przestrzennej) obszarze, przeprowadzono klasyfikację dla zestawu danych w dwóch wariantach rozdzielczości (30m i 10m) w różnych wariantach architektury zaprojektowanej i wytrenowanej sieci neuronowej. Uzyskane wyniki poddano weryfikacji i porównano z wynikami klasyfikacji metodą 'maksymalne prawdopodobieństwo'. W obu przypadkach zastosowano nadzorowane podejście do klasyfikacji.

## **2. Ogólna charakterystyka klasyfikacji opartej na sieci neuronowej.**

Sieci neuronowe wychodzą naprzeciw potrzebom wielu aplikacji, w których stosowanie metod parametrycznych napotyka często na problemy wynikające ze złożoności przedmiotu analizy co powoduje trudności z realizacją założeń będących u podstaw tych metod. Są one coraz szerzej stosowane w rozwiązywaniu skomplikowanych problemów w różnych dziedzinach nauki i techniki. Typowe przykłady zastosowań dotyczą: ogólnie pojętej klasyfikacji, rozpoznawania obrazów, predykcji, rozumienia mowy, sterowania robotami, itp.

Sieci neuronowe tym się różnią w ogólności od innych metod stosowanych w klasyfikacji, że nie działają według wcześniej znanych reguł dyskryminacji klas, a tworzą te reguły dopiero w trakcie etapu wytrenowania sieci na reprezentatywnych przykładach. Pozwala to często rozwiązywać skomplikowane problemy (także te nie dające się sformalizować) bez wnikania głębiej w istotę rozpatrywanej dziedziny. Umiejętność uczenia się i zapamiętywania, a następnie na tej podstawie uogólniania i rozpoznawania sprawia, iż sieci neuronowe znalazły zastosowanie także w cyfrowej klasyfikacji pokrycia terenu. Jednakże należy podkreślić, iż pomimo swej atrakcyjności nie są one powszechnie stosowane w praktyce przetwarzania cyfrowego zdjęć satelitarnych. Dlatego też nieliczne są przykłady znaczących opracowań w tym zakresie. Bardziej znane dotyczą prac: Civco, (1993) i Foody, (1995) także Paola i Schowengerdt (1995) oraz Kanellopoulos i Wilkinson (1997). Wciąż jednak niewiele jest doświadczeń i szerszych badań nad wykorzystaniem sieci neuronowych do klasyfikacji pokrycia terenu, a zwłaszcza w obszarach różnorodnych spektralnie o bardziej złożonym, heterogenicznym krajobrazie. Wśród powodów niewielkiej do niedawna popularności algorytmów klasyfikacji opartych na sieciach neuronowych należy wymienić ograniczoną dostępność oprogramowania (zwłaszcza specjalizowanego dla cyfrowej klasyfikacji zdjęć satelitarnych) co oznacza, iż tylko nieliczne pakiety programowe oferują ten moduł, oraz wysokie wymagania co do mocy obliczeniowej platformy sprzętowej.

Jak wynika z nazwy, sztuczne sieci neuronowe stanowią pewną analogię do systemów nerwowych żywych organizmów złożonych z wielu elementarnych komórek, powiązanych wieloma połączeniami o swoistym sposobie przetwarzania i przepływu informacji.


Zasymulowanie programowe (lub sprzętowe w postaci elektronicznego wielowęściowego układu sumującego) podstawowych właściwości komórki nerwowej prowadzi do tzw. neuronu; z kolei symulacja wielu sztucznych neuronów – do sztucznej sieci neuronowej. Sztuczne sieci neuronowe są organizowane w warstwy (struktura warstwowa). Maksymalna dozwolona liczba możliwych warstw jak i neuronów w warstwie jest wyłącznie cechą oprogramowania w ramach którego konstruuje się daną sieć. Wejście każdego neuronu z danej warstwy ma połączenie z wyjściami wszystkich neuronów w warstwie poprzedniej. Siła połączenia między neuronami zależy od wartości wag, które tym połączeniom są przypisane.

Podział istniejących algorytmów opartych na sztucznych sieciach neuronowych dokonywany jest najczęściej ze względu na dwa podstawowe kryteria (Osowski, 1996):

1. ze względu na architekturę sieci (co uwzględnia ilość oraz sposób połączenia neuronów i ich wzajemnego współdziałania),
2. ze względu na metodę trenowania (doboru wag):

Szczegółową charakterystykę poszczególnych typów sieci jak również technik trenowania w obrębie wyróżnionych metod trenowania zawierają między innymi prace: Osowski, 1996; Muławka 1997, Białko 2000.

Dla przeprowadzenia w niniejszej pracy klasyfikacji pokrycia terenu w oparciu o algorytm sieci neuronowej, wykorzystano moduł Neural Network Classification oprogramowania PCI (v6.3 EASI/PACE). Jest to jednokierunkowa wielowarstwowa sieć z metodą trenowania 'pod nadzorem' w oparciu o algorytm propagacji błędu wstecz. Podstawową ideę omawianej klasyfikacji ilustruje Rys.1.




Rys.1. Schemat ideowy klasyfikacji pokrycia terenu z zastosowaniem algorytmu opartego na sieci neuronowej jednokierunkowej z dwoma przykładowymi warstwami ukrytymi  $H_1$  i  $H_2$ ; ilość komórek w warstwie: wejściowej - po 3 komórki na 1 obraz (razem  $n$ ), I ukrytej  $m$ , II ukrytej  $m$ , wyjściowej  $k$ .

Proces ogólnie pojętej klasyfikacji z wykorzystaniem algorytmu opartego na sieci neuronowej jednokierunkowej wielowarstwowej z metodą trenowania 'pod nadzorem' w oparciu o algorytm propagacji wstecznej obejmuje trzy podstawowe etapy:

1. Zaprojektowanie sieci; liczba warstw ukrytych oraz ilość neuronów w warstwie wejściowej i warstwach ukrytych.
2. Wytrenowanie sieci. Wytrenowanie sieci przy założeniu jej określonej architektury oraz metody uczenia pod nadzorem ma na celu taki dobór wag, który pozwoli zrealizować odwzorowanie wejściowych danych uczących na żądaną (i określoną) postać wyjściową w sposób poprawny (z dostateczną dokładnością) dla konkretnego zadania. Osiąga się to poprzez minimalizację tzw. funkcji celu, która może przybierać różne definicje. Z bardziej znanych w praktyce należy wymienić definicję funkcji celu w postaci sumy kwadratów różnic (lub sumy różnic jako wartości bezwzględnych) między wartościami żądanymi (ze zbioru treningowego) i aktualnymi na wyjściu sieci. Sumowanie odbywa się zatem na poziomie neuronów warstwy wyjściowej dla kolejnych par (wektorów) uczących. Zamiast pojęcia funkcji celu spotyka się także pojęcie funkcji błędu jaki powstaje między poprawną wartością docelową komórek wyjściowych a aktualnie obliczoną odpowiedzią sieci dla tych komórek. Elementarne operacje zachodzące na poziomie neuronu jako komórki jednostkowej pokazano schematycznie na Rys.2.





Rys.2. Podstawowa jednostka sieci neuronowej i operacje zachodzące na jej poziomie; gdzie:  $NET = \sum(x_i w_i)$  dla wszystkich  $i$  od 1 do  $n$ ;  $f$  funkcja aktywacji.

Proces zmierzający do minimalizacji funkcji celu ma charakter iteracyjny. Dla przyspieszenia zbieżności procesu stosowane są różne techniki do których należy także technika zwana momentem. Polega ona na podaniu dodatkowego składnika proporcjonalnego do zmiany wartości wagi w poprzednim kroku. Działanie czynnika momentum jest bardzo istotne dla omijania licznych punktów występowania minimum lokalnego funkcji celu. Nie mniej ważny jest tzw. współczynnik szybkości trenowania (ang. learning rate), który decyduje o zbieżności algorytmu do minimum funkcji celu; zbyt mała wartość powoduje konieczność wykonania większej liczby iteracji a z kolei zbyt duża wartość na określonym etapie wytrenowania może spowodować przeskoczenie minimum funkcji celu i tym samym potrzebę dalszych iteracji.

Właściwie dobrane wartości parametrów sterujących znacznie przyspieszają proces uczenia i w efekcie uzyskanie minimum globalnego funkcji celu.

Podstawowe parametry mające bezpośredni związek z procesem wytrenowania sieci dla algorytmu Neural Network oprogramowania PCI (v6.3 EASI/PACE) to:

MOMEN - współczynnik momentum z przedziału [0.0, 1.0],

LEARN - współczynnik szybkości trenowania z przedziału [0.0, 1.0],

MAXTERR – dopuszczalny błąd całkowity maksimum, który po iteracji jest porównywany z wartością osiągniętą przez tzw. znormalizowany błąd całkowity określony jako:

$$\text{normalized total error} = 0.5 * (\text{sum of}(\text{individual error}^2)) / \text{Nsample} \quad [\text{PCI}, \text{v6.3 EASI/PACE}].$$

gdzie: individual error = sum of ( abs( target - output ) ) [PCI,v6.3 EASI/PACE].

target – wartość docelowa dla neuronu warstwy wyjściowej, output wartość aktywacji dla neuronu warstwy wyjściowej generowana przez sieć, Nsample - ilość pikseli pól treningowych.

MAXIERR – dopuszczalny błąd jednostkowy maksimum, który porównywany jest z kolei z określoną już powyżej wartością tzw. individual error

MAXIT – maksymalna liczba iteracji.

Proces wytrenowania kończy się z chwilą osiągnięcia którejs z wartości MAXTERR lub MAXIERR. Jeśli w zadanym cyklu osiągnięta zostanie tylko zadeklarowana ilość iteracji to konieczna jest kontynuacja procesu trenowania.

Po wytrenowaniu, zarówno struktura sieci jak i rozkład wag są zapisywane w segmencie DBNNS. Niezależnie od końcowego raportu generowany jest (w trakcie procesu wytrenowania) wykres zbieżności ilustrujący zmiany (po każdej iteracji) znormalizowanego błędu całkowitego (normalized total error).

### 3. Właściwa klasyfikacja.

Po wytrenowaniu sieć jest gotowa do wykonania zadania klasyfikacji. Jeśli celem jest wykonanie klasyfikacji pokrycia terenu to podstawowym produktem wyjściowym jest obraz tematyczny 'pokrycie terenu'. Bardzo przydatnym do wykonania wstępnej oceny rezultatu klasyfikacji może być obraz zawierający dla każdego piksela współczynniki pewności (odpowiednik prawdopodobieństwa). Obliczane są one jako stosunek (wyrażony w %) maksymalnej wartości aktywacji komórki warstwy wyjściowej, która to wartość przesądziła o atrybucie danego piksela, do sumy wszystkich aktywacji (z poszczególnych komórek warstwy wyjściowej) wygenerowanych przez dany piksel. W sensie znaczenia (a nie sposobu obliczenia) podobne są one do rozkładu prawdopodobieństw jaki uzyskuje się dla rezultatu klasyfikacji algorytmem maksymalne prawdopodobieństwo. Wyższe wartości współczynników oznaczają klasy dla których sieć jest dobrze wytrenowana. Współczynniki te są rozpatrywane relatywnie do uzyskanego przedziału wartości.

### 3. Obszar badań.

Obszar badań o wielkości ok. 480 km<sup>2</sup> zlokalizowany jest w swej przeważającej części (ok. 90%) w obrębie zlewni rzeki Krutyni położonej na Pojezierzu Mazurskim. Wraz z dopływami oraz połączonymi jeziorami Krutynia tworzy *system rzeczno-jeziorny* stanowiący z tego tytułu charakterystyczny układ krajobrazowy.

Urozmaicony krajobraz młodoglacjalny Krutyni jest w ogólności rezultatem akumulacyjnej i erozyjnej działalności lądolodu zlodowacenia bałtyckiego. Cechuje się występowaniem form pagórkowatych z licznymi zagłębieniami bezodpływowymi stanowiącymi naturalne jeziora lub torfowiska. Przeważa zdecydowanie krajobraz pagórkowaty pojezierny oraz sandrowy.

W obszarach gdzie gleby występują na glinach zwałowych prowadzone są uprawy rolnicze i tam też koncentrują się głównie osady wiejskie. Pierwotnie z reguły dominowały tam żyzne siedliska lasów liściastych z urozmaiconym składem drzewostanowym. Istniejące w obecnym kształcie lasy występują przeważająco na piaskach oraz żwirach zwałowych i wodnolodowcowych, obejmując głównie siedliska

borów mieszanych i lasów mieszanych. Zespoły borowe stanowią tu dominujący typ zbiorowisk leśnych. Stosunkowo mały udział w powierzchni lasów mają typowe lasy liściaste. Wśród nich przeważają grądy, które tworzą wielogatunkowy las liściasty z dominacją grabu i dębu, czasem z domieszkami buka, lipy i świerka, rzadziej jodły.

Charakterystycznym elementem krajobrazu roślinnego systemu rzeczno-jeziornego Krutynii są zbiorowiska ziołorośli nadrzecznych oraz półnaturalne i antropogeniczne zbiorowiska łąkowe i pastwiskowe. Z kolei zbiorowiska szuwaru turzycowego i zbiorowiska mszysto-turzycowe stanowią obok fitocenoz leśnych i zaroślowych podstawowy element roślinności brzegowej systemu rzeczno-jeziornego Krutyni. Zbiorowiska te tworzą zazwyczaj kilkudziesięciometrowej szerokości pasy w bezpośrednim sąsiedztwie powierzchni wodnych. Od łądu sąsiadują z fitocenozami łągowymi, olsowymi, zaroślowymi lub bezpośrednio z łąkami lub pastwiskami. Natomiast najpospolitszym zbiorowiskiem leśnym wchodzącym w skład roślinności brzegowej jest łąg olszowo-jesionowy, [Kłosowski i Tomaszewicz, 1996]. Fitocenozy łągowe stanowią obok zbiorowisk turzycowych podstawowy 'pasmowy' składnik krajobrazu (pełniący funkcję ekotonu woda-łąg) doliny Krutyni, zajmując gleby wilgotne w sąsiedztwie koryta rzeki (z niewielkimi przerwami na całej jego długości). Przy jeziorach, w szczególności w obniżeniach terenu (ale słabo podtopionych), łągi ustępują fitocenozom o cechach olsu.

Turystyka i zespolona z nią rozwijająca się infrastruktura, gospodarka leśna oraz rolnictwo to podstawowe formy aktywności gospodarczej w omawianym obszarze, który jest niezbyt gęsto zaludniony (wyjątek stanowi sezon wakacyjny). Ludność zamieszkuje w obszarach typowo wiejskich.

#### 4. Dane.

Wstępny zestaw danych cyfrowych do klasyfikacji, obejmuje dwa podstawowe zbiory:

1. dane o rozdzielczości 30m: kanały Landsat TM (1,2,3,4,5,7) oraz wskaźniki (składowe) transformacji *Tasseled Cap (brightness, greenness, wetness)* jak również znormalizowany wskaźnik *ndvi*, uzyskane w oparciu o kanały Landsat TM (sceny zarejestrowanej 02.04.90)
2. dane o rozdzielczości 10m: pseudokanały (hybrydy) uzyskane z połączenia według metody nawiązującej do formuły Price'a (Price, 1987) kanałów Landsat TM (1,2,3,4,5,7) ze SPOT Panchro (sceny zarejestrowanej 08.04.90) nazwane odpowiednio: *hybr1, hybr2, hybr3, hybr4, hybr5, hybr7* oraz wskaźniki (składowe) transformacji *Tasseled Cap (brightness, greenness, wetness)* i wskaźnik *ndvi* uzyskane w oparciu o powyższe hybrydy.

Ponadto wykorzystano materiały pomocnicze w postaci map topograficznych (w skali 1:50000), zdjęcia lotnicze barwne w podczerwieni (w skali 1:26000) dla wschodniej części obszaru oraz materiały z rekonesansu terenowego.



Biorąc pod uwagę datę zdjęcia Landsat TM oraz specyfikę badanego obszaru (obszary leśne, podmokłe), zdecydowano, iż składowe *Tasseled Cap*, a także znormalizowany wskaźnik roślinności, mogą być pomocne zarówno w przygotowaniu wartościowych kompozycji barwnych, jak również jako potencjalne kanały dla klasyfikacji.

## 5. Cyfrowa klasyfikacja pokrycia terenu z wykorzystaniem sieci neuronowych.

Zakres i szczegółowość klasyfikacji.

W oparciu o zgromadzone materiały kartograficzne, przetworzenia (jak kompozycje, wskaźniki roślinności) cyfrowych danych satelitarnych oraz przeprowadzony wywiad terenowy dokonano analizy obszaru badań i zdefiniowano ostatecznie 14 klas pokrycia terenu jako cel klasyfikacji cyfrowej. Tabl.1. zawiera wykaz przyjętych klas tematycznych.

Tabela 1.

Klasy tematyczne przyjęte w cyfrowej klasyfikacji pokrycia terenu.

Oznaczenie klasy tematycznej	Cechy Charakterystyczne
1. woda	Wody jezior, niektóre cieki.
2. wo_rsl	Zarośla trzciny, sitowia przyległe do jezior; styk woda/ląd.
3. b_msw	Las iglasty z przewagą siedlisk boru miesznego świeżego.
4. ml_sosn	Las iglasty z dominacją młodej sosny (do 40lat) w zwartych kompleksach.
5. b_sosn	Las iglasty z przewagą boru świeżego; dominuje starsza sosna w mniej zwartych kompleksach.
6. l_miesz	Las mieszany.
7. l_lisc	Las liściasty.
8. t_podm	Teren podmokły; podmokłe zarośla, zbiorowiska szuwarowe wzdłuż rzeki Krutyni, śródleśnie położone torfowiska, bagna.
9. poktrw	Pokrywa trawiasta; naturalne zbiorowiska murawowe w kompleksach leśnych, łąki ubogie, suche fragmenty łąk.
10. łąki	Łąki.
11. ozimin	Oziminy.
12. gl_odk	Gleby odkryte.
13. gl_odk_such	Gleby odkryte wyżej położone, okresowo suche
14. t_zabud	Tereny zabudowane

Ponieważ planowane wyniki klasyfikacji odnoszą się do zestawów wejściowych danych o różnej rozdzielczości przestrzennej to wiarygodne i pełne porównanie wyników wymagało uwzględnienia tego faktu na etapie wyboru pól treningowych jak również w dalszej kolejności dla wyłonienia pól testowych, co

zapewniono poprzez zaprojektowanie odpowiedniej w tym względzie procedury postępowania.

Wyboru kanałów spektralnych wchodzących bezpośrednio do klasyfikacji dokonano w oparciu o podstawowe statystyki (tj. sygnatury), wykorzystując również analizę dywergencji.

W optymalnym zestawie znalazły się kanały: *hybr4,5,7,hybr\_ndvi,hybr\_wetness* oraz odpowiednio dla podstawowej rozdzielczości '30': *tm4,5,7,ndvi,wetness*.

W optymalnym zestawie nie znajduje się żaden z kanałów spektralnych zakresu widzialnego. Stąd też zdecydowano, że dla celów porównawczych niezależnie od wyłonionego optymalnego zestawu będzie również przeprowadzona klasyfikacja dla zestawu kanałów *hybr3,4,5,7*.

Celem uzyskania optymalnego wyniku klasyfikacji wykonano wiele wariantów wytrenowania (uczenia) sieci przy różnych jej parametrach obejmujących liczbę warstw ukrytych oraz ilość neuronów w warstwie wejściowej i warstwach ukrytych. Dla realizacji zadań porównawczych wybrano sieci z architekturą o najlepszych wynikach uczenia, spełniające przyjęte progi dokładnościowe w procesie wytrenowania. Tabl.2 zawiera podstawową informację o strukturach sieci, które pozwoliły na uzyskanie dobrych wyników w zakresie dokładności klasyfikacji dla metody opartej na sieciach neuronowych.

Rys.3 ilustruje fragment wykresu zbieżności według wartości *normalized total error* dla DBNNS 18\_30.

Dla celów porównawczych wykonano również klasyfikację 'maksymalne prawdopodobieństwo' przy podobnych założeniach wejściowych (kanały wejściowe, pola treningowe) jak dla klasyfikacji z wykorzystaniem sieci neuronowych.

Tabela 2.

### Charakterystyka sieci NN wytrenowanych dla wykonania klasyfikacji.


*Dla wszystkich przypadków o pozytywnym zakończeniu procesu wytrenowania zadecydowało osiągnięcie wartości 'normalized total error' poniżej progu MAXTERR ustalonego na 0.01.*

*(\*) Kanały po nieliniowym rozciągnięciu kontrastu.*

NN Segment {DBNNS}	Kanały wejściowe	Ilość jednostek na 1 kanał wejściowy {NIUNIT}	Ilość warstw ukrytych i jednostek w warstwie {NHUNIT}	Liczba iteracji w procesie wytrenowania
Zestaw danych o rozdzielczości 30m				
17_30	TM4.5.7.v.br	3	15 15	209
18_30	TM4.5.7.v.w	3	15 15	126
19_30	TM4.5.7.v.w	3	15 15 15	195
20_30	TM4.5.7.v.br	3	15 15 15	137
21_30	TM4.5.7.v.w	3	15	1000
22_30	TM4.5.7.v.w	5	25	900
37_30	TM3.4.5.7	3	15 15	110
46_30	TM4.5.7.v.w (*)	3	15 15	137
Zestaw danych o rozdzielczości 10m				
17_10	Hybr4.5.7.v.w	3	15 15 15	57

18_10	Hybr4,5,7,v,w	3	15 15	47
19_10	Hybr4,5,7,v,br	3	15 15	71
20_10	Hybr3,4,5,7	3	15 15	55
21_10	Hybr4,5,7,v,w	5	25	350
23_10	Hybr4,5,7,v,w	3	15	140

Weryfikację map pokrycia terenu uzyskanych w różnych wariantach klasyfikacji cyfrowej przeprowadzono w oparciu o przygotowane pola testowe z rozdzielczością 10m.



Rys.3. Fragment wykresu wartości całkowitego błędu znormalizowanego uzyskany w procesie wytrenowania sieci dla *DBNNS 18\_30*.

Podstawą oceny dokładności i porównania wyników klasyfikacji są wskaźniki dokładności obliczone w oparciu o macierze błędów pozyskane dla obrazów wynikowych kolejnych klasyfikacji. Jako miary służące ocenie dokładności klasyfikacji przyjęto trzy wskaźniki (których podstawą do obliczenia jest macierz błędów:

- błąd z tytułu pominięcia {*ang. omission error*} oznaczony dalej jako ErrorO; wyraża stosunek liczby pikseli niepoprawnie sklasyfikowanych do

liczby pikseli tej klasy uzyskanej z danych ‘prawdziwych’ tj. sumy w odpowiadającej kolumnie.

- błąd z tytułu nadmiaru {ang. *commission error*} oznaczony dalej jako ErrorC; stosunek pikseli niepoprawnie sklasyfikowanych do pikseli klasyfikowanych w obrębie rozpatrywanej klasy.
- 'kappa' [Hudson & Ramm, 1987; Fenstermaker, 1994]; maksimum wartości wskaźnika wynosi 1 dla sytuacji kiedy występuje pełna zgodność między obrazem tzw. ‘prawdy terenowej’ czyli obrazem testowym a obrazem po klasyfikacji. Wartość 0 oznacza, iż uzyskana zgodność odpowiada poziomowi przypadkowej zgodności. Wskaźnik ‘kappa’ może być rozpatrywany jako ogólna miara dokładności (klasy łącznie), a także jako tzw. wskaźnik warunkowej zgodności jako miara dokładności w odniesieniu do każdej klasy z osobna.

Tabl.3. ilustruje macierz błędów uzyskaną dla zestawu kanałów hydr4,5,7,v,w (DBNS 18\_10).

Tabl.4. i Tabl.5. stanowią syntetyczne zestawienie uzyskanych dokładności według błędów odpowiednio ‘*commission*’ i ‘*omission*’ oraz *Kappa* dla najlepszych wariantów wykonanych klasyfikacji.

Tabela 3.

Macierz błędów dla wyniku klasyfikacji z wykorzystaniem sieci neuronowych na zestawie kanałów hydr4,5,7,v,w (DBNS 18\_10).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	Total	ErrorC	Kappa
1	67101	818	0	0	0	98	4	0	16	0	0	0	0	0	68037	0.0138	0.9586
2	2550	18115	668	0	0	0	0	0	0	0	0	0	60	0	21393	0.1532	0.8529
3	13	320	51527	182	9245	0	0	0	0	0	8	0	51	0	61346	0.1601	0.8892
4	0	0	8	65819	2397	0	0	5	175	0	1	0	0	4	68409	0.0379	0.9738
5	0	17	1752	1377	93705	3116	0	0	111	0	0	0	0	0	100078	0.0637	0.8529
6	0	0	1984	7	1493	46535	2724	48	46	0	4	8	567	113	53529	0.1307	0.8457
7	0	0	0	0	0	4352	44226	2073	186	0	1	1	0	628	51467	0.1407	0.9094
8	0	0	7	0	0	32	622	3773	3667	0	7	14	0	466	8588	0.5607	0.5735
9	0	0	0	0	0	0	21	39	31563	2	79	1174	272	1263	34413	0.0828	0.7439
10	0	0	0	0	0	0	0	0	250	28531	4628	0	172	1	33582	0.1504	0.9946
11	0	177	214	0	0	25	11	0	2135	145	29874	4	192	12	32789	0.0889	0.8225
12	0	0	0	0	0	0	0	0	192	0	4	40269	1018	0	41483	0.0293	0.9585
13	0	0	0	0	0	0	0	0	0	0	1292	18	14795	0	16105	0.0813	0.8601
14	0	1664	1069	0	0	0	618	573	3277	0	7	401	0	10866	18475	0.4119	0.8079
Total	69664	21111	57229	67385	106840	54158	48226	6511	41618	28678	35905	41889	17127	13353	609694		0.8858
ErrorC	0.0368	0.1419	0.0996	0.0232	0.1229	0.1408	0.0829	0.4205	0.2416	0.0051	0.1680	0.0387	0.1362	0.1863		0.1033	

Tabela 4.

Syntetyczne zestawienie (na podst. macierzy błędów) uzyskanych dokładności według błędu z tytułu nadmiaru *commission error* {ErrorC} oraz wskaźnika Kappa dla różnych wariantów klasyfikacji. {Wielkości w wierszu 'Total' w poszczególnych kolumnach 'ErrorC' oznaczają sumaryczny błąd z tytułu pominięcia i nadmiaru}.


Klasa	Mlc_tm457vw {30m}		Mlc_tm3457 {30m}		NN_DBNNS 18_30		Mlc_hybr457vw {10m}		Mlc_hybr3457 {10m}		NN_DBNNS 18_10	
	ErrorC	Kappa	ErrorC	Kappa	ErrorC	Kappa	ErrorC	Kappa	ErrorC	Kappa	ErrorC	Kappa
1 woda	0.0212	0.9574	0.0179	0.9503	0.0507	0.9745	0.0130	0.9797	0.0111	0.98	0.0138	0.9586
2 wo_rśl	0.1525	0.8341	0.1614	0.8352	0.1546	0.5520	0.0857	0.8788	0.0715	0.8289	0.1532	0.8529
3 b_mśw	0.2457	0.8223	0.2436	0.8162	0.3341	0.8634	0.1564	0.9650	0.1511	0.9634	0.1601	0.8892
4 mł_sosn	0.0626	0.8742	0.0621	0.8705	0.0513	0.6074	0.0320	0.9471	0.0287	0.9343	0.0379	0.9738
5 b_sosn	0.0743	0.7681	0.079	0.7718	0.2108	0.7374	0.0461	0.8685	0.0440	0.8908	0.0637	0.8529
6 l_miesz	0.2909	0.7216	0.2941	0.7313	0.2734	0.7197	0.1036	0.8531	0.1058	0.8668	0.1307	0.8457
7 l_liść	0.2936	0.7227	0.291	0.7109	0.3311	0.6962	0.1252	0.8856	0.1248	0.8761	0.1407	0.9094
8 t_podm	0.6138	0.5628	0.6232	0.5513	0.7709	0.5473	0.4552	0.6965	0.4869	0.6773	0.5607	0.5735
9 poktrw	0.2556	0.8031	0.259	0.7882	0.2732	0.6738	0.0682	0.8980	0.0893	0.8587	0.0828	0.7439
10 łąka	0.1869	0.9888	0.1796	0.9875	0.2028	0.9404	0.1269	0.9949	0.1333	0.9931	0.1504	0.9946
11 ozimina	0.0237	0.8510	0.0275	0.8573	0.1259	0.6966	0.0141	0.8542	0.0193	0.8478	0.0889	0.8225
12 gl_odkr	0.0518	0.9293	0.0528	0.9284	0.1208	0.9385	0.0358	0.9636	0.0377	0.9683	0.0293	0.9585
13 gl_odk_such	0.0439	0.7457	0.043	0.7615	0.0194	0.6945	0.0513	0.9247	0.049	0.9339	0.0813	0.8601
14 t_zabudow.	0.2943	0.8107	0.3458	0.7849	0.2418	0.7556	0.2368	0.8579	0.3189	0.7997	0.4119	0.8079
Total	0.1556	0.8283	0.1576	0.8260	0.2145	0.7628	0.0790	0.9124	0.0824	0.9089	0.1033	0.8858

Tabela 5.

Syntetyczne zestawienie (na podst. macierzy błędów) uzyskanych dokładności według błędu z tytułu pominięcia *omission error* {ErrorO} dla różnych wariantów klasyfikacji.

Warianty klasyfikacji	Klasy pokrycia terenu														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
ErrorO	Mlc_tm457vw {30m}	0.0379	0.1602	0.1591	0.1127	0.1967	0.2523	0.2541	0.4303	0.1821	0.0106	0.1413	0.0659	0.2487	0.1845
	Mlc_tm3457 {30m}	0.0442	0.1591	0.1648	0.116	0.1932	0.2431	0.2654	0.4416	0.1961	0.0118	0.1353	0.0668	0.2331	0.2094
	NN_DBNNS 18_30	0.0225	0.4377	0.1196	0.3635	0.2170	0.2548	0.2778	0.4409	0.3049	0.0563	0.2888	0.0570	0.2994	0.2390
	Mlc_hybr457vw {10m}	0.0180	0.1172	0.0312	0.0472	0.1100	0.1343	0.1052	0.2993	0.0952	0.0048	0.1383	0.0339	0.0733	0.1385
	Mlc_hybr3457 {10m}	0.0178	0.1657	0.0327	0.0587	0.091	0.1216	0.1139	0.3181	0.1322	0.0066	0.1444	0.0295	0.0642	0.1952
	NN_DBNNS 18_10	0.0368	0.1419	0.0996	0.0232	0.1229	0.1408	0.0829	0.4205	0.2416	0.0051	0.1680	0.0387	0.1362	0.1863





Rys.4. Porównanie wyników klasyfikacji: (I) 'maksymalne prawdopodobieństwo' na zestawie kanałów: a) TM4,5,7,v,w {30m}; c) hybr4,5,7,v,w {10m} i (II) z wykorzystaniem sieci neuronowych na zestawie kanałów: b) TM4,5,7,v,w {30m, DBNNS 18\_30}; d) hybr4,5,7,v,w {10m, DBNNS 18\_10}. Skala ok. 1:50000

## 6. Wnioski.

Wnioski z analizy tak uzyskanych wskaźników dokładności wskazują, iż klasyfikacja z wykorzystaniem sieci neuronowych dała ogólnie nieco słabsze wyniki w porównaniu z klasyfikacją maksymalne prawdopodobieństwo. Lepszy wynik klasyfikacji dla danych o rozdzielczości 30m uzyskano metodą 'maksymalne prawdopodobieństwo' na zestawie kanałów Landsat TM4,5,7,v,w. Podobnie dla rozdzielczości 10m metoda 'maksymalne prawdopodobieństwo' na zestawie hybr4,5,7,v,w dała najlepszy wynik. Rys.4. ilustruje porównanie określonych wyników na wybranym fragmencie obszaru (pole testowe 'Piecki').

Analiza wartości błędów z tytułu pominięcia i nadmiaru wyraźnie wskazuje we wszystkich wariantach klasyfikacji, iż najslabiej sklasyfikowane są klasy 'obszary podmokłe' oraz 'tereny zabudowane'. Klasa tematyczna 'obszary podmokłe' zawiera w dużym stopniu piksele, które w rzeczywistości należą do klas: las liściasty, mieszany oraz pokrywa trawiasta. Tak postrzegany błąd z tytułu nadmiaru (*commission error*) stanowi znacznie większy problem niż błąd z tytułu pominięcia (*omission error*). Podobne relacje zachodzą dla klasy 'tereny zabudowane' w obrębie której znalazło się dużo pikseli w rzeczywistości należących do lasu liściastego, pokrywy trawiastej oraz częściowo obszarów podmokłych.

Uzyskane wyniki wskazują na umiarkowaną przydatność zastosowanego algorytmu opartego na sieci neuronowej w cyfrowej klasyfikacji pokrycia terenu w dość trudnym i skomplikowanym krajobrazie, jakim cechuje się obszar badań.

## Literatura:

- Białko M., (2000); *Podstawowe właściwości sieci neuronowych i hybrydowych systemów ekspertowych*. Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin.
- Civco D.L., (1993); Artificial neural networks for land-cover classification and mapping. *Int. J. Geographical Information Systems*, Vol. 7, No. 2, pp. 173-186.
- Fenstermaker L.K., (editor), (1994); Remote Sensing thematic accuracy assessment: a compendium. *American Society for Photogrammetry and Remote Sensing*.
- Foody G.M., (1995); Land cover classification by artificial neural network with ancillary information. *International Journal of Geographic Information Systems*. Vol. 9, no. 5, pp. 527-542.
- Hudson W.D., Ramm C.W., (1987); Correct formulation of the kappa coefficient of agreement. *Photogrammetric Engineering and Remote Sensing*, Vol. 53, No. 4, pp. 421-422.
- Kanellopoulos I., Wilkinson G.G, (1997); Strategies and best practice for neural network image classification. *International Journal of Remote Sensing*. Vol. 18, No. 4, pp. 711-725.

- Kłosowski S., Tomaszewicz H., (1996); Zbiorowiska roślinności brzegowej systemu rzeczno-jeziornego Krutynii. W: Zeszyty Naukowe Komitetu „Człowiek i Środowisko” t. 13, str. 345-376.
- Mulawka J.J., (1997); *Systemy ekspertowe*. Wydawnictwa Naukowo-Techniczne, Warszawa.
- Osowski S., (1996); Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo Techniczne, Warszawa.
- Paola J.D., Schowengerdt R.A., (1995); A detailed comparison of backpropagation neural network and maximum likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 33. NO. 4, pp. 981-996
- PCI Geomatics, (1998); Using PCI Software. Richmond Hill, Ontario, Canada.
- Price, J. C., (1987); Combining panchromatic and multispectral imagery from dual resolution satellite instruments, *Remote Sensing of Environment*, Vol. 21, pp. 119-128.

Recenzowała: prof. dr hab. Aleksandra Bujakiewicz