



Uniwersytet
Wrocławski



Wieloatrybutowa klasyfikacja rzeźby terenu z wykorzystaniem danych rastrowych i sztucznych sieci neuronowych

Małgorzat Wieczorek¹, Wojciech Przybył²

¹ *Uniwersytet Wrocławski, Instytut Geografii i Rozwoju Regionalnego*

² *Wojskowy Instytut Techniki Inżynieryjnej im. Prof. Józefa Kosackiego we Wrocławiu*

Plan prac badawczych


porównanie wyników automatycznej kategoryzacji form terenu przeprowadzonej w trybie grupowania bez nadzoru i z nadzorem z ekspercką (manualną) klasyfikacją geomorfologiczną.

Zastosowano algorytmy:

- k-median z metryką Manhattan
- sztuczne sieci neuronowe (SSN)

Obszar badań

- Fragment Gór Bystrzyckich
- Rozdzielczość 25 m
- Obszar 9150 m x 6875 m
- Zmienne morfometryczne:
 - wysokość n.p.m.
 - **wysokość względna (w oknie 125 m)**
 - nachylenie,
 - ekspozycja,
 - krzywizna planarna
 - krzywizna profilowa
 - **litologia**
 - **grupowanie k-median**




Elevation a.s.l. [m]



0 1 2 km

Obszar badań

➤ Mapa eksperta (Piotr Migoń)



(7) powierzchnia płaska o dużej wysokości, w większości kontrolowana


(2) inne powierzchnie o niskiej rzeźbie

(6) skarpy generowane przez uskoki

(9) skarpy o kontrolowanej wytrzymałości skał



(3) szerokie wypukłe arzbietv



(8) pedymenty, lokalnie z pokrywą głazów



(4) suche doliny i niecki



(5) czoło doliny

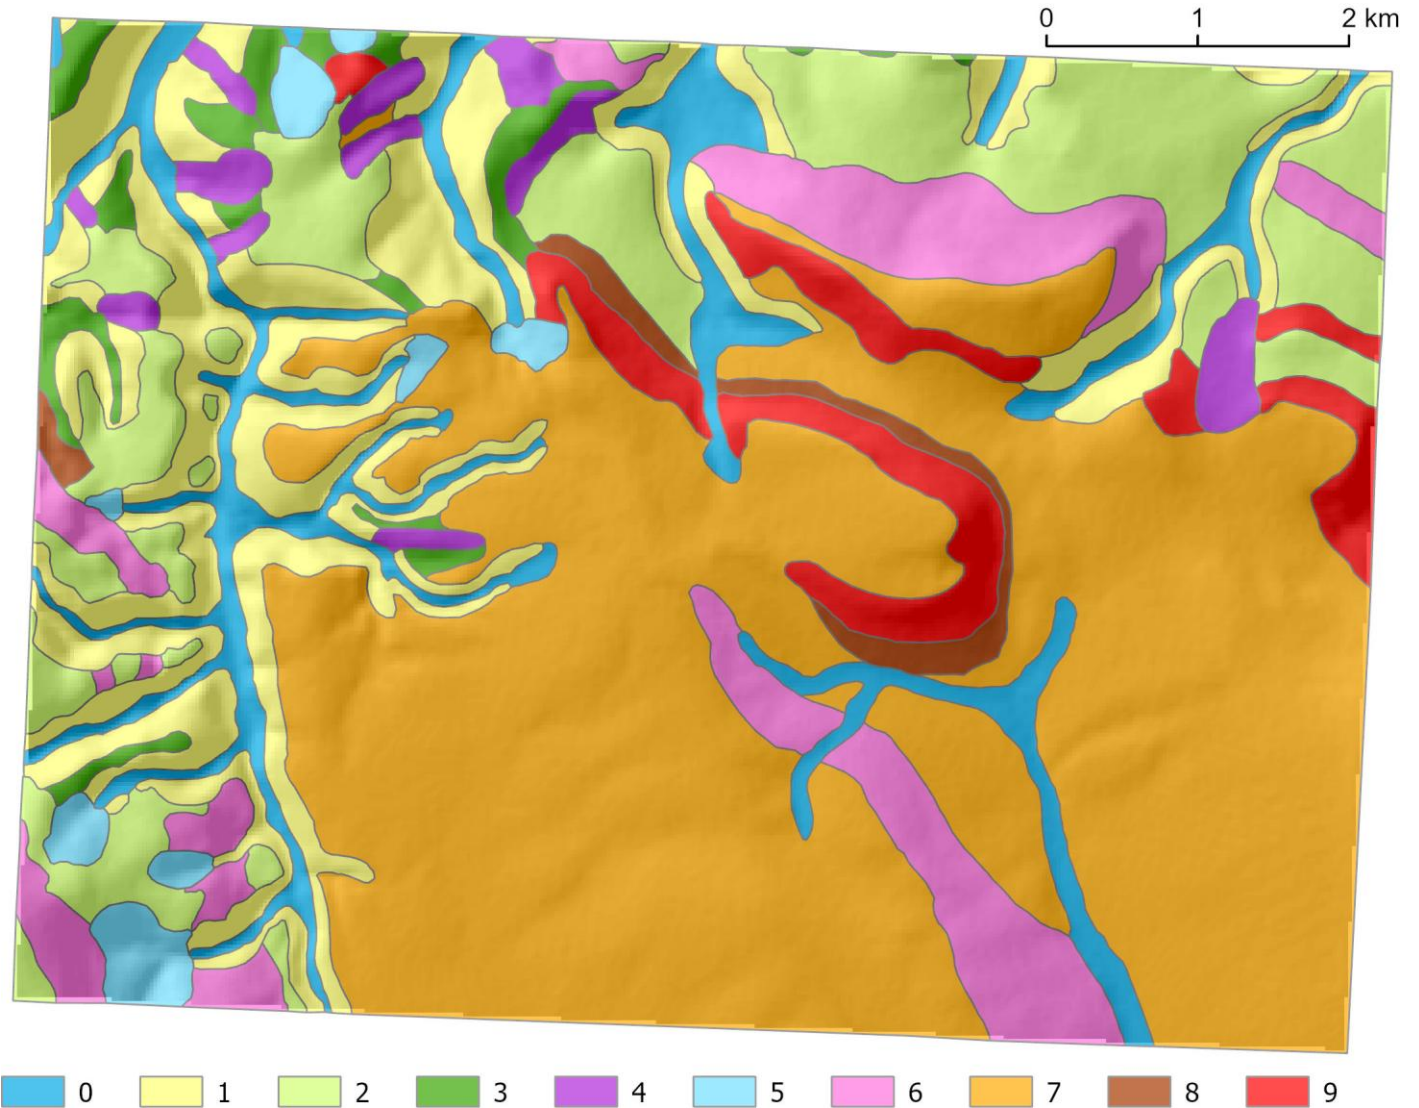


(0) aluwialne dna dolin

(1) strome zbocza dolin, lokalnie z wyłaniającymi się wychodniami skalnymi


Mapa eksperta

1. Wektoryzacja
2. Zakodowanie opisu wydzieleni



Mapa eksperta


1. Wektoryzacja
2. Zakodowanie opisu wydzieleni
3. Zamiana na raster



Dane jakościowe

Litologia (Milena Różycka)

Rezultat klasyfikacji metodą k-median
(k = 6)




Dane jakościowe

Litologia (Milena Różycka)

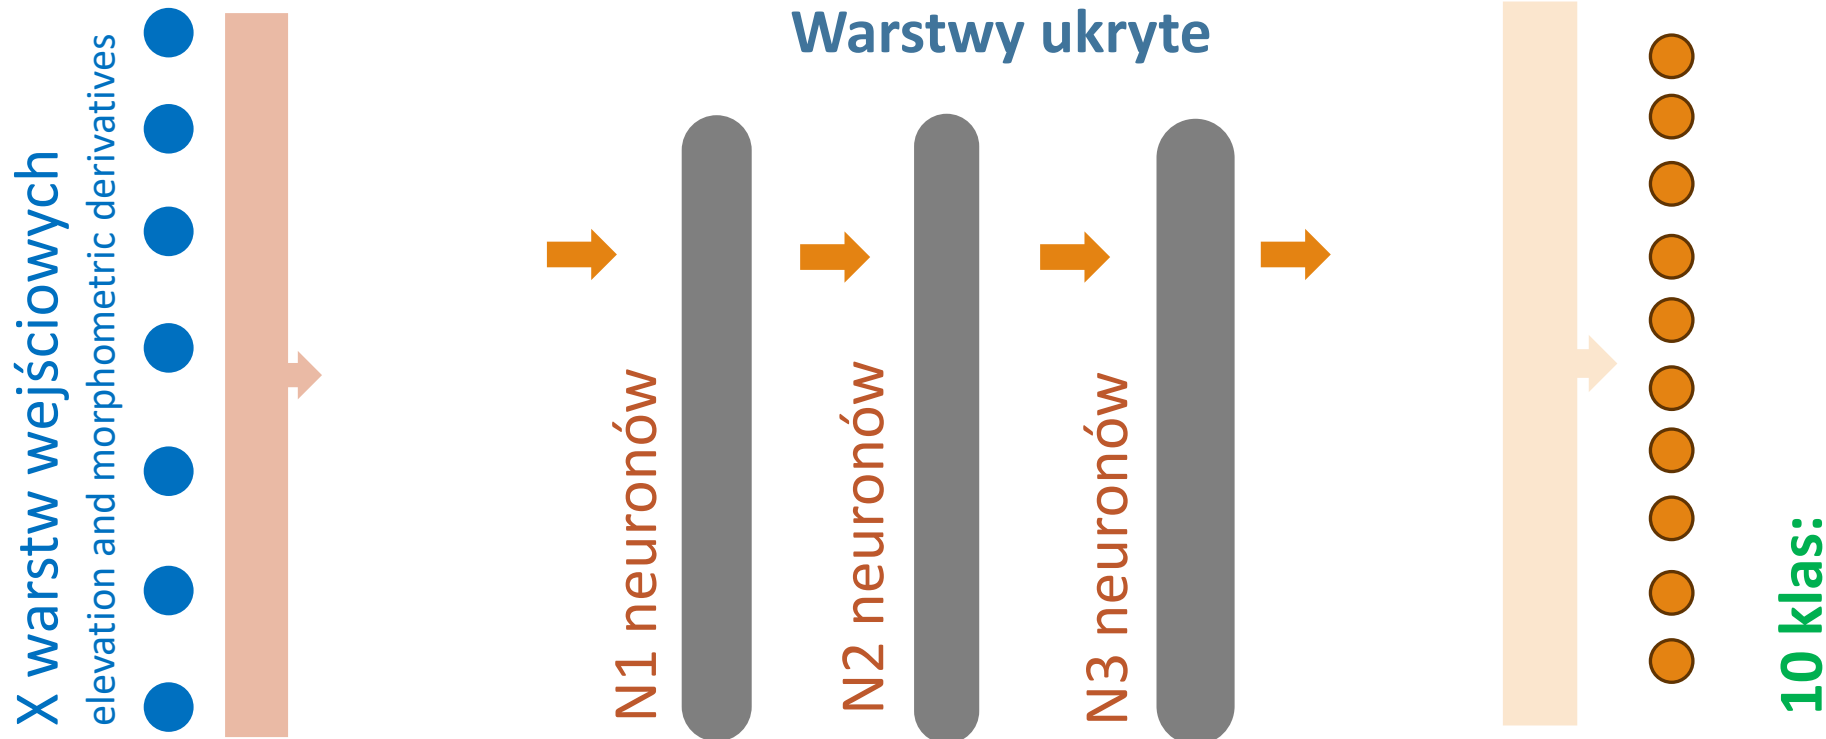
**Rezultat klasyfikacji metodą k-median
(k = 6)**

Klasyfikacja nienadzorowana zgodnie z algorytmem *k*-median w podziale na **6 grup** jako najlepsza opcja zgodnie z wynikami eksperymentów

Dane wchodzące do algorytmu *k*-median:
DEM, wysokość względna, nachylenie, ekspozycja, krzywizna planarna i profilowa




Klasyfikacja oparta na sieci neuronowej (SSN) z wykorzystaniem wysokości i pochodnych morfometrycznych (DEM, wysokość względna, nachylenie, ekspozycja, krzywizna planarna i profilowa) oraz litologii, *k*-median, mapy referencyjnej eksperta



Eksperymentalnie dobieramy architekturę sieci

(proces uczenia: minimalizacja strat i maksymalizacja dokładności)

wysokość n.p.m., wysokość względna, nachylenie, ekspozycja, krzywizna planarna i profilowa, litologia, k-median



80% losowo wybrane punkty – zbiór treningowy;
20% zbiór walidacyjny

Liczba warstw, neuronów,
współczynnik uczenia, liczba epok,
warstwy wchodzące do modelu,
sąsiedztwo przestrzenne

Określanie optymalnej liczby warstw ukrytych i neuronów na warstwę

SSN była trenowana dla 5 epok ze współczynnikiem uczenia wynoszącym 0.001.

Architektura sieci	Training loss	Validation loss	Dokładność
[32]	0.921	0.915	0.690
[64]	0.857	0.853	0.719
[64 32]	0.772	0.729	0.749
[128 64]	0.688	0.645	0.772
[128 64 32]	0.656	0.613	0.786
[256 128 64]	0.604	0.566	0.798
[64 256 128]	0.581	0.528	0.809

Najlepsza architektura **[64 256 128]**

Sprawdź, czy regularyzacja dropout – wyłączenie określonego odsetka neuronów – poprawia wynik

SSN była trenowana dla 5 epok ze współczynnikiem uczenia wynoszącym 0.001.
Architektura [64 256 128]

Współczynnik regularyzacji dla wszystkich warstw	Koszt zbioru uczącego	Koszt zbioru walidacyjnego	Dokładność
0.0	0.581	0.528	0.809
0.1	0.702	0.611	0.782
0.2	0.777	0.667	0.766
0.4	0.919	0.789	0.725

Wniosek: regularyzacja warstw **nie polepsza** uczenia

Analiza wpływu cech wejściowych

SSN była trenowana dla 5 epok ze współczynnikiem uczenia wynoszącym 0.001.
Architektura [64 256 128]

Wyłączona zmienna wejściowa	Koszt zbioru uczącego	Koszt zbioru walidacyjnego	Dokładność
– DTM	0.734	0.725	0.740
– ekspozycja	0.718	0.690	0.747
– Litologia	0.691	0.641	0.767
– wysokość względna	0.602	0.578	0.789
– nachylenie	0.616	0.569	0.792
– k-median	0.614	0.564	0.796
– krzywizna planarna	0.578	0.532	0.803
– krzywizna profilowa	0.570	0.528	0.808

Wniosek: Największy wpływ ma DEM i ekspozycja, najmniejszy Plan i Profile
Jednak najlepsze wyniki, gdy wszystkie zmienne wchodzi do zbioru uczącego

Badanie wpływu liczby epok i tempa uczenia się, a także potencjalnego nadmierne dopasowania

Liczba epok, współczynnik uczenia	Koszt zbioru uczącego	Koszt zbioru walidacyjnego	Dokładność
5 epochs, learning rate 1e-3	0.581	0.528	0.809
5 epochs, learning rate 1e-4	0.804	0.769	0.746
10 epochs, learning rate 1e-3	0.505	0.471	0.828
10 epochs, learning rate 1e-4	0.698	0.658	0.775
15 epochs, learning rate 1e-3	0.479	0.440	0.835
15 epochs, learning rate 1e-4	0.651	0.626	0.783
20 epochs, learning rate 1e-3	0.428	0.430	0.838
25 epochs, learning rate 1e-3	0.421	0.404	0.849

Optymalna liczba epok wynosi ok. 20;
przy 25 może wystąpić nadmierne dopasowanie (utrata walidacji < strata uczenia)

Wpływ sąsiedztwa – wykorzystanie danych wejściowych z lokalizacji docelowej i jej otoczenia


Sąsiedztwo	Koszt zbioru uczącego	Koszt zbioru walidacyjnego	Dokładność
–	0.581	0.528	0.809
1	0.664	0.712	0.782
2	0.756	0.88	0.731
3	0.887	0.939	0.730
4	1.111	0.191	0.664

Dodanie bezpośrednich informacji z sąsiednich pikseli nie poprawia wyniku. Informacje o sąsiedztwie są już osadzone w pochodnych geomorfometrycznych. Dodatkowo, całkowita ilość danych ulega zmniejszeniu, ponieważ piksele z sąsiedztwa nie są już wykorzystywane do dalszego trenowania.

Porównanie R1 i R2

Opracowanie klasyfikatora poprzez trenowanie sieci neuronowej (ANN) o wybranej architekturze i parametrach, na podstawie wysokości i jej pochodnych z badanego obszaru, z wyłączeniem pól R1 i R2

- ✓ Dane wejściowe: wysokość n.p.m., wysokość względna, nachylenie, ekspozycja, krzywizna planarna i profilowa, litologia, k-median
- ✓ Liczba klas referencyjnych (10);
- ✓ Współczynnik regularyzacji = 0;
- ✓ Brak sąsiedztwa;
- ✓ Liczba epok = 20;
- ✓ architektura [64 256 128]






Mapa eksperta

k-median, k=10

SSN [64 256 128]
20 epok

SSN [128 64 32], 20 epok
Dropout = 0.3, sąsiedztwo = 3

R 1







Dokładność

23.5%

50.5%

54.4%

R 2



Dokładność

18.5%

53.2%

59.5%




Mapa eksperta

k-median, k=10

SSN [64 256 128]
20 epok

SSN [128 64 32], 20 epok
Dropout = 0.3, sąsiedztwo = 3

R 1






Dokładność

23.5%

50.5%

54.4%

R 2



Dokładność

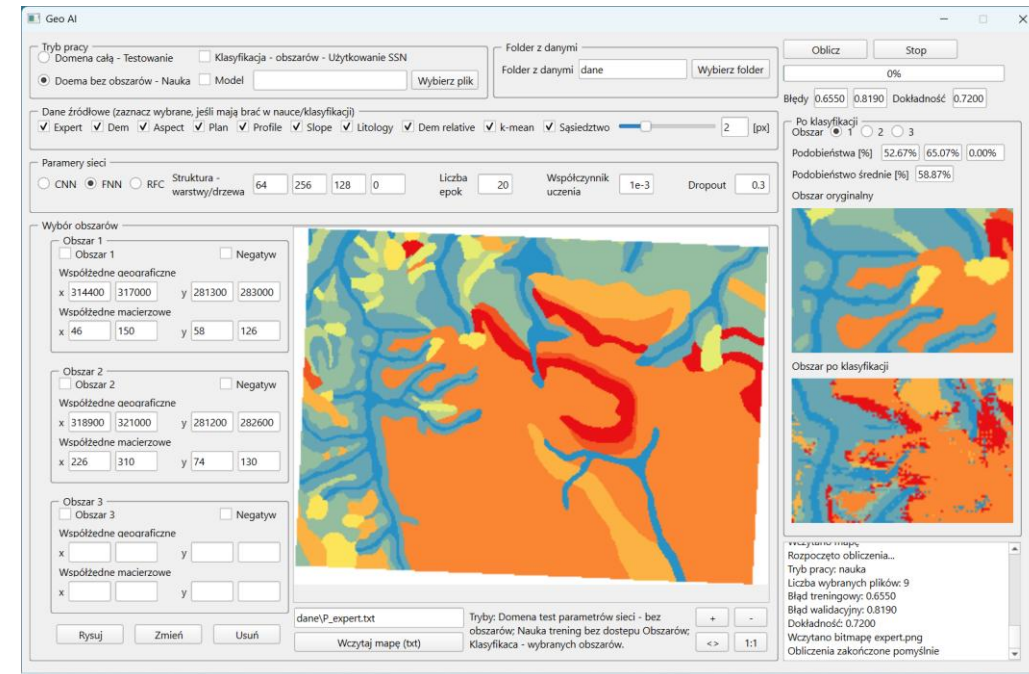
18.5%

53.2%

59.5%

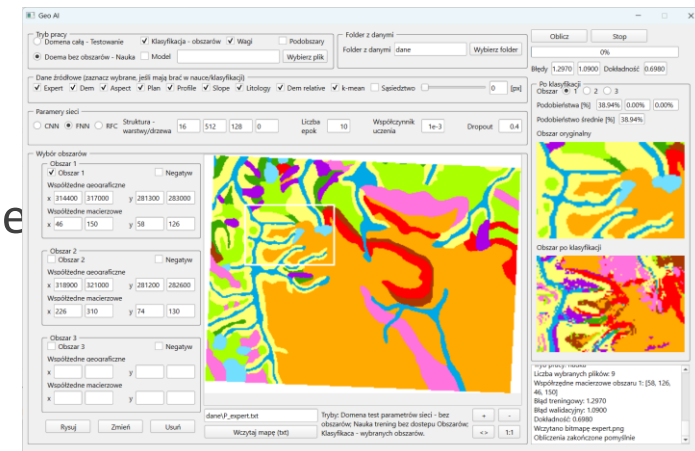
Wnioski

1. Sieci neuronowe (ANN) dają lepsze wyniki niż klasteryzacja k-medianowa.
2. Dodanie litologii i danych k-medianowych poprawia ANN, ale nieznacznie.
3. Sieć powinna zostać ponownie wytrenowana przy użyciu większego i bardziej reprezentatywnego zbioru danych.



Wnioski końcowe

1. Obiecująco zapowiada się wykorzystanie alternatywnych algorytmów, t.j. las losowy (Random Forest Classifier - RFC) czy konwolucyjne sieci neuronowe (Convolutional Neural Networks - CNN).
2. Zastosowane metody są w stanie dokonać częściowej replikacji eksperckich map geomorfologicznych, ale w nowym obszarze metody działają tylko wtedy, gdy charakterystyki geomorfologiczne na przewidywanym obszarze są podobne do tych w zbiorze danych treningowych.
3. Stąd pracujemy nad rozszerzeniem badań o inne obszary, dla których dysponujemy opracowaniem geomorfologicznym, by lepiej dopracować się i uczynić ją bardziej uniwersalną.



Dziękuję za uwagę 😊