



Wykorzystanie danych LiDAR oraz metod AI do wykrywania lokalizacji grodopodobnych obiektów archeologicznych

Kamil Szczepanik

Opiekun naukowy: dr Krzysztof Podlaski, prof. UŁ
Uniwersytet Łódzki, Wydział Fizyki i Informatyki Stosowanej

Cała Polska jest już zeskanowana laserowo, a dane są bezpłatne i publiczne. Grodziska są na nich widoczne – ktoś musi je tylko zobaczyć.

Pytanie pracy: czy potrafi to zrobić sieć neuronowa – i czy wynik jest na tyle wiarygodny, by archeolog mógł z niego skorzystać?

198

zweryfikowanych lokalizacji – zbiór uczący
zbudowany od zera dla polskich danych LiDAR

0.793


F1 na terenie niewidzianym podczas treningu; 91%
wskazań modelu jest trafnych

~5 h

analiza obszaru 100×100 km na komputerze klasy
konsumenckiej – zamiast tygodni pracy

Plan prezentacji

1. Problem, cel pracy i stan badań
2. Dane: 198 lokalizacji z zasobów Geoportalu
3. Przetwarzanie: od chmury punktów LiDAR do obrazu rzeźby terenu
4. Augmentacja multi-azimuth – główny wkład metodyczny pracy
5. Trening modeli YOLO11 i wyniki na niezależnym zbiorze testowym
6. System automatycznej prospekcji dużych obszarów i wnioski



Grodzisko w Daleszynie – wały czytelne mimo lasu

Kontekst


- Cała Polska jest pokryta bezpłatnymi danymi lotniczego skanowania laserowego (LiDAR) z Geoportalu (GUGiK); dane uwidaczniają formy terenu ukryte pod roślinnością – w tym stanowiska archeologiczne
- Tradycyjna prospekcja archeologiczna wymaga tygodni ręcznej analizy map i pracy w terenie

Cel pracy

Zautomatyzowane wykrywanie **grodzisk** (umocnionych osad obronnych) w danych LiDAR z wykorzystaniem głębokich sieci neuronowych oraz ocena przydatności detekcji dla prospekcji archeologicznej

Stan badań i luka badawcza

- Detekcja obiektów archeologicznych w danych LiDAR: R-CNN w Holandii [1], Faster R-CNN w Norwegii (87% wykrytych obiektów) [2], YOLO w Portugalii [3], rastry wielokanałowe [4]
- **Luka:** polskie dane LiDAR nie były dotąd analizowane pod kątem automatycznej detekcji grodzisk; brak oceny praktycznej przydatności takich systemów dla archeologów



Chmura punktów LiDAR – grodzisko w Daleszynie

- **Znane grodziska:** 65 lokalizacji przekazanych przez Instytut Archeologii Uniwersytetu Łódzkiego oraz baza grody.zamkisp.pl (woj. śląskie, łódzkie, pomorskie)
- **Przykłady negatywne:** naturalne wzgórza, tereny leśne i płaskie – uczą model odróżniać grodziska od zwykłych form terenu
- Łącznie **198 zweryfikowanych wizualnie lokalizacji**

Dane LiDAR

- Źródło: Geoportal, pliki LAZ (skompresowane chmury punktów z klasyfikacją), gęstość 4-12 punktów/m²
- Wykorzystywane atrybuty: X, Y, Z, klasa punktu, numer odbicia, RGB

Zbiór uczący

- 3616 kafelków 1024×1024 px z adnotacjami obiektów (format YOLO)
- Podział train/val/test na poziomie **lokalizacji** – ten sam teren nigdy nie trafia do dwóch zbiorów (brak wycieku danych)



Chmura punktów – ruiny zamku w Gęsiach

Wejście: chmura punktów LAZ pobrana z Geoportalu dla zadanego obszaru

1. Ekstrakcja punktów klasy 2 (teren)

Usunięcie punktów odbitych od roślinności, zabudowy i szumu – zostaje wyłącznie powierzchnia gruntu

2. Interpolacja nearest neighbor

Z nieregularnej chmury powstaje regularna siatka wysokości – Numeryczny Model Terenu (NMT) o rozdzielczości **0.5 m/piksel**; najbliższy punkt wyszukiwany w strukturze cKDTree o złożoności $O(\log n)$


$$Z_{grid}(x, y) = Z_{nn}(x, y)$$

3. Maskowanie obszarów bez danych


Piksele odległe o ponad 10 m od najbliższego punktu terenu (woda, luki w danych) zastępowane jednolitą szarością – nie generują fałszywych struktur

$$mask_{void} = \{(x, y) : d_{nn}(x, y) > 10 \text{ m}\}$$

Udział punktów terenu w chmurze: średnio 37% (zakres 7.3-92.2%, mediana 32.8%) – nawet przy niskim udziale gęstość wystarcza do interpolacji NMT



Punkty klasy "teren" (Daleszyn)



NMT po interpolacji

1. Filtracja Gaussa ($\sigma = 0.5$) – opcjonalne wygładzenie szumu pomiarowego NMT

$$NMT'(x, y) = NMT(x, y) * G_{\sigma}(x, y)$$

2. Mapa nachyleń (slope) z pochodnych cząstkowych NMT; normalizacja i inwersja – obszary płaskie jasne, strome ciemne

$$S = \sqrt{\left(\frac{\partial z}{\partial x}\right)^2 + \left(\frac{\partial z}{\partial y}\right)^2}, \quad S_{inv} = \left(1 - \frac{S}{\max(S) + \varepsilon}\right)^2$$

3. Hillshade wg modelu odbicia Lamberta [5] – azymut 315° , wysokość źródła światła 25° , **z-factor 25** uwypuklający mikrorzeźbę

$$H = \cos(Z_s)\cos(S_{rad}) + \sin(Z_s)\sin(S_{rad})\cos(A_s - A)$$

Z_s – kąt zenitalny źródła światła, S_{rad} – nachylenie w radianach, A – ekspozycja stoku (aspect)

4. Fuzja hillshade + slope – cieniowanie uwypukla strukturę przestrzenną, slope – krawędzie i strome zbocza


$$I_{combined} = \alpha \cdot H_{gray} + (1 - \alpha) \cdot S_{inv}, \quad \alpha = 0.5$$

5. CLAHE [6] – adaptacyjna korekcja kontrastu w lokalnych oknach z przycięciem histogramu: czytelność w ciemnych (las) i jasnych (pola) partiach obrazu, bez przepaleń

$$I_{clahe} = \text{CLAHE}(I_{combined}, \beta = 0.03)$$

6. Maskowanie obszarów bez danych – warunek z poprzedniego slajdu

Wynik: obraz, na którym wały, fosy i nasypy są czytelne dla modelu detekcji



Daleszyn – widoczne wały obronne



Gęś – struktura pierścieniowa

Problem

Przy jednym kierunku oświetlenia (azymut 315°) struktury zorientowane równolegle do promieni światła nie rzucają cienia i stają się niewidoczne dla modelu

Rozwiązanie


- 5 wariantów hillshade tej samej lokalizacji jako niezależne przykłady treningowe: azymuty **315° , 45° , 135° , 225°** oraz **337.5°** (kierunek NNW o empirycznie potwierdzonej wyższej trafności percepcyjnej [7])
- NMT i mapa nachyleń liczone raz – generowany jest tylko hillshade
- Zbiór treningowo-walidacyjny: **3376** → **16 880 kafelków** bez dodatkowej akwizycji danych

Efekt (5-fold CV, YOLO11s)

mAP50: 0.631 → **0.686 (+5.5 punktu procentowego)** bez zmiany architektury ani hiperparametrów – wyłącznie przez lepszą reprezentację terenu, co ma istotne znaczenie przy małych zbiorach archeologicznych

Wariant treningu (YOLO11s)	mAP50	σ	mAP50-95
Jeden azymut (315°)	0.631	0.062	0.353
Pięć azymutów	0.686	0.056	0.394

Mniejsze odchylenie standardowe między foldami oznacza też stabilniejszy model



Kafelek treningowy 1024×1024 px z widocznym grodziskiem


Konfiguracja treningu

- Wstępna selekcja architektur: YOLO11 [8] wyraźnie przewyższa YOLOv8 – do dalszych badań wybrano **YOLO11n** i **YOLO11s**
- Walidacja krzyżowa **5-fold** z podziałem na poziomie lokalizacji, transfer learning ze zbioru COCO
- Obrazy 1024×1024 px, batch 8 (limit 8 GB VRAM), learning rate 0.0007 (dobrany eksperymentalnie), optymalizator AdamW
- Wariant multi-azimuth (5× większy zbiór): RTX 4090, ~47 h dla 5 foldów


Test na 19 lokalizacjach niewidzianych podczas treningu

Model	Precision	Recall	F1	TP	FP	FN
YOLO11s (finalny)	0.913	0.700	0.793	21	2	9
YOLO11n	0.462	0.400	0.429	12	14	18

- Gdy model wskazuje miejsce, w **91%** przypadków ma rację (2 fałszywe alarmy na 23 wskazania); wykrywa **7 na 10** obiektów, AUC-ROC = 0.862 przy progu pewności 0.62
- Klasyfikacja binarna kafelków: precyzja **100%** – każdy wskazany kafelek faktycznie zawiera obiekt
- Wybrano YOLO11s: mniejsza wariancja między foldami walidacji krzyżowej przełożyła się na znacznie lepszą generalizację (F1 **0.793** wobec 0.429 dla YOLO11n)



Batch treningowy z augmentacjami



Predykcje na zbiorze walidacyjnym

[8] Jocher i Qiu, Ultralytics YOLO11, 2024

Strumieniowy potok przetwarzania


- 10 równoległych pobrań plików LAZ z Geoportalu
- 10 procesów generujących wizualizacje hillshade
- Cache wizualizacji na dysku, kafelkowanie w RAM, detekcja na GPU
- Pliki LAZ usuwane po przetworzeniu – stałe zużycie dysku

Wydajność dla obszaru 100×100 km


- Pierwsza analiza: **~5 godzin**, powtórna (z cache): **~30 minut**
- Wymagania: GPU 6 GB VRAM, 16 GB RAM, ~100 GB dysku

Rezultat analizy produkcyjnej

470 kandydatów ze współrzędnymi geograficznymi, oceną pewności i wizualizacją z ramką detekcji; wyniki przekazano do konsultacji archeologom Uniwersytetu Łódzkiego



Wykryta struktura pierścieniowa



Forma terenowa z wyraźnymi wałami

0.793

F1 na niezależnym zbiorze testowym – precyzja 91.3%, wykrywalność 70%

+5.5 pp

wzrost mAP50 dzięki augmentacji multi-azimuth – bez zmiany architektury

470


kandydatów wskazanych w analizie produkcyjnej, przekazanych archeologom UŁ

Wnioski

- Automatyczna detekcja grodzisk w polskich danych LiDAR jest skuteczna i powtarzalna – potwierdzona walidacją krzyżową i testem na terenie niewidzianym podczas treningu
- Główny wkład metodyczny – augmentacja multi-azimuth – poprawia wynik wyłącznie przez zmianę reprezentacji wizualnej terenu, co ma znaczenie przy każdym małym zbiorze danych przestrzennych
- Powstał kompletny system: od surowych plików LAZ z Geoportalu do listy kandydatów ze współrzędnymi

Znaczenie praktyczne i kierunki rozwoju

- Zero kosztów akwizycji danych; potencjał dla ewidencji AZP, wojewódzkich konserwatorów zabytków i analiz przedinwestycyjnych
- Narzędzie **wspomaga, nie zastępuje** archeologa: 9% wskazań to fałszywe alarmy, 30% obiektów pozostaje niewykrytych, weryfikacja terenowa jest konieczna
- Dalej: nowe regiony i klasy obiektów (kurhany, cmentarzyska), walidacja terenowa, wielokanałowe reprezentacje terenu



Kandydat wskazany przez system – do weryfikacji terenowej

Dane od dawna są publiczne i bezpłatne. Od teraz jest też narzędzie, które potrafi je przejrzeć – i wskazać archeologowi, gdzie warto pojechać.