

Wykorzystanie technologii AI w poszukiwaniach średniowiecznych umocnień obronnych miasta Elbląga

Henryk Olszewski¹, Patryk Redziński², Maciej Sieradzki²

¹ University of Applied Sciences in Elbląg, Krzysztof Brzeski Institute of Applied Informatics, Poland
Wojska Polskiego 1, 82-300 Elbląg
e-mail: h.olszewski@ans-elblag.pl

² University of Applied Sciences in Elbląg, Krzysztof Brzeski Institute of Applied Informatics, Poland
Wojska Polskiego 1, 82-300 Elbląg

Streszczenie: Technologia AI w mapowaniu terenów automatyzuje procesy, które wcześniej wymagały pracy ludzkiej oraz umożliwia tworzenie dokładniejszych i bardziej zaawansowanych map, modeli 3D w krótszym czasie. Drony umożliwiają rejestrację wielkich zbiorów danych: zdjęć, filmów, danych telemetrycznych, które następnie są analizowane przez algorytmy AI podczas tworzenia modeli 3D, segmentacji i klasyfikacji obiektów oraz wykrywania anomalii. Algorytmy AI automatycznie łączą zdjęcia, korelują punkty charakterystyczne i usuwają zniekształcenia obrazów. Automatycznie rozpoznają i klasyfikują obiekty, takie jak budynki, drogi, linie kolejowe, rzeki, napowietrzne linie energetyczne. Proces mapowania staje się dokładniejszy, a mapy i modele 3D stają się bardziej dokładne i dostosowane do potrzeb odbiorcy. Algorytmy AI segmentują obrazy zarejestrowane przez kamery pokładowe dronów na różne klasy, umożliwiając generowanie map zagrożeń środowiskowych, map rolniczych oraz map terenów miejskich. Technologia AI analizuje dane z różnych okresów i automatycznie wykrywa zmiany w wyodrębnionych obszarach

Słowa kluczowe: Sztuczna inteligencja; Uczenie maszynowe; Fotogrametria; Mapowanie terenów; Przeloty fotogrametryczne; Klasyfikatory;

The use of AI technology in the search for medieval defensive fortifications in the city of Elbląg

Abstract: AI technology in terrain mapping automates processes that previously required human work and enables the creation of more accurate and advanced maps, 3D models in a shorter time. Drones enable the recording of large data sets: photos, videos, telemetry data, which are then analyzed by AI algorithms during the creation of 3D models, segmentation and classification of objects and detection of anomalies. AI algorithms automatically combine photos, correlate characteristic points and remove image distortions. They automatically recognize and classify objects such as buildings, roads, railway lines, rivers, overhead power lines. The mapping process becomes more accurate, and 3D maps and models become more accurate and tailored to the needs of the recipient. AI algorithms segment images recorded by drone on-board cameras into different classes, enabling the generation of environmental hazard maps, agricultural maps and urban area maps. AI technology analyzes data from different periods and automatically detects changes in isolated areas.

Keywords: Artificial intelligence; Machine learning; Photogrammetry; Area mapping; Photogrammetric flights; Classifiers;


1. Wprowadzenie

Technologia AI pomogła w identyfikacji przebiegu średniowiecznych umocnień obronnych miasta Elbląga. Pod koniec średniowiecza (XV wiek) Elbląg z 10 tys. mieszkańców był czwartym, po Gdańsku (35 tys. mieszkańców), Krakowie (10 tys. mieszkańców, zaś z Kazimierzem i Kleparzem 20 tys. mieszkańców), Poznaniu (10 ÷ 12.5 tys. mieszkańców), miastem Polski. Liczba mieszkańców Elbląga była więc porównywalna

z Krakowem i większa od Lwowa (8 ÷ 10 tys. mieszkańców), Lublina i Braniewa (5 tys. mieszkańców) oraz Warszawy (tylko 4.5 tys. mieszkańców). Wysoka liczba mieszkańców wskazuje na dużą powierzchnię średniowiecznego Elbląga oraz znaczne oddalenie zapomnianych umocnień obronnych od jego centrum. Pojawił się więc pomysł przeprowadzenia ich poszukiwań [2, 4].

Mury obronne średniowiecznych miast były kluczowym elementem ich systemów obronnych. Miały za zadanie

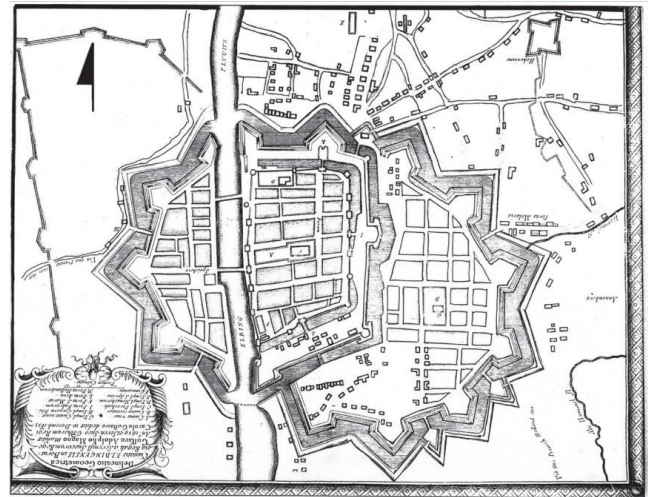
uniemożliwienie wrogom dostępu do wnętrza miasta oraz zapewnienie obrońcom przewagi. W drugiej połowie XV wieku Elbląg składał się z trzech części: zamku krzyżackiego, Starego Miasta wraz z przedmieściami, Nowego Miasta i Wyspy Spichrzów, na co wskazują prace Hauke, Stobbe [1] – rysunek 1. Przeszkodą w stworzeniu jednolitego miasta były średniowieczne mury obronne, stąd władze Elbląga przystąpiły do ich przebudowy [2].



Rysunek 1. Części miasta Elbląga około 1400 roku: A – Stare Miasto, B – Nowe Miasto, C – Wyspa Spichrzów, D – zamek krzyżacki, E – przedmieścia [1]

System umocnień obronnych miasta tworzyły wały ziemne, mokre fosy oraz bastiony, które otaczały Stare Miasto z przedmieściami, Nowe Miasto, Wyspę Spichrzów. Umocnienia przetrwały do lat 70-tych XVIII wieku. Po włączeniu miasta Elbląga w granice państwa pruskiego, w lipcu 1773 roku Rada Miasta uzyskała zgodę na likwidację fortyfikacji, niwelacji wałów ziemnych i zasypywania fos miejskich. Na obszarze Wyspy Spichrzów i przedmieść otaczających Elbląg dotychczas nie realizowano żadnych prac wykopaliskowych.

Celem przeprowadzanych prac było odnalezienie i rekonstrukcja zapomnianych umocnień znajdujących się w lewobrzeżnej części Elbląga, poza fortyfikacjami bastionowymi. Znaczne oddalenie średniowiecznych umocnień od fortyfikacji bastionowych z mokrymi fosami spowodowało rozwój osadnictwa na lewobrzeżnych przedmieściach, które co raz bardziej odsuwało się od centrum miasta. Podstawą poszukiwań była plan miasta Elbląga z 1655 roku przedstawiony na rysunku 2.



Rysunek 2. Plan miasta Elbląga z 1655 roku [1]


2. Materiał i metody

Sztuczna inteligencja AI odgrywa coraz większą rolę w rozwoju dronów. Pozwala na automatyzację realizowanych zadań oraz zwiększenie precyzji wykonywanych misji. AI umożliwia realizację lotów autonomicznych bez potrzeby ciągłej ingerencji ze strony operatora. Wykorzystując algorytmy sztucznej inteligencji drony mogą omijać przeszkody, planują trasy przelotów i dostosują się do zmieniających się warunków w czasie rzeczywistym. Algorytmy uczenia maszynowego ML (ang. *Machine Learning*) przetwarzają dane z czujników dronów, takich jak: kamery pracujące w różnych zakresach promieniowania, skanery LiDAR, radary. Dzięki AI drony przetwarzają obrazy i materiał wideo w czasie rzeczywistym, w celu rozpoznawania i śledzenia zadanych obiektów. Technologia AI wspiera również tworzenie map 3D terenów.


Plany przelotów dronów definiowane były w oparciu o cyfrowe modele wysokościowe DEM (ang. *Digital Elevation Model*) miasta Elbląga, będące cyfrową reprezentacją ukształtowania terenu. Cyfrowe modele wysokościowe DEM pobrano z serwisu Geoportal (www.geoportal.gov.pl). Wyróżniamy dwa rodzaje modeli DEM: cyfrowe modele terenu DTM (ang. *Digital Terrain Model*) i cyfrowe modele powierzchni DSM (ang. *Digital Surface Model*) [8].

Cyfrowe modele terenu DTM stanowią trójwymiarową reprezentację powierzchni ziemi przedstawiającą naturalną topografię terenu, po usunięciu wszelkich elementów

znajdujących się nad powierzchnią ziemi. Modele DTM dostarczają informacje dotyczące rzeczywistych wysokości i ukształtowania gruntu [8]. Na rysunku 3 pokazano cyfrowy model terenu rejonu poszukiwań średniowiecznych umocnień obronnych Elbląga. Rysunek 4 przedstawia cyfrowy model terenu DTM z nałożonym planem Elbląga z 1655 roku.




Rysunek 3. Cyfrowy model terenu DTM rejonu poszukiwań średniowiecznych umocnień obronnych Elbląga
Źródło: opracowanie własne na podstawie [14]




Rysunek 4. Cyfrowy model terenu DTM rejonu poszukiwań średniowiecznych umocnień obronnych z nałożonym planem Elbląga z 1655 roku
Źródło: opracowanie własne na podstawie [1, 14]

W odróżnieniu od cyfrowych modeli terenu DTM, cyfrowe modele powierzchni DSM uwzględniają wszystkie obiekty znajdujące się na powierzchni ziemi, w tym roślinność,

zarówno niską, jak i wysoką, budynki, mosty i inne obiekty, stworzone przez człowieka. Modele DSM przedstawiają wysokość wszystkich widocznych elementów zarówno naturalnych, jak i nienaturalnych [8, 13].



Rysunek 5. Cyfrowy model powierzchni DSM rejonu poszukiwań średniowiecznych umocnień obronnych Elbląga
Źródło: opracowanie własne na podstawie [14]




Rysunek 6. Porównanie cyfrowego modelu terenu DTM z cyfrowym modelem powierzchni DSM rejonu poszukiwań średniowiecznych umocnień obronnych Elbląga
Źródło: opracowanie własne na podstawie [14]

Na rysunku 5 przedstawiono model DSM rejonu badań, zaś na rysunku 6 porównano cyfrowy model terenu DTM z cyfrowym modelem powierzchni DSM. Rysunek 7 przedstawia cyfrowy model powierzchni DSM z nałożonym planem Elbląga z 1655 roku.

Cyfrowy model terenu przedstawia rzeźbę terenu. Nie uwzględnia on obiektów antropogenicznych i roślinności.


Obiektami antropogenicznymi nazywamy elementy krajobrazu, które zostały stworzone, zmienione lub wpłynęły na nie działania człowieka. Zaliczamy do nich domy, bloki mieszkalne, stanowiące podstawowe elementy krajobrazu miejskiego: drogi, autostrady, mosty, linie kolejowe, obiekty przemysłowe, obiekty rolnicze (pola uprawne, stawy rybne, zbiorniki retencyjne, ogrody), parki, ogrodzenia [8, 13].



Rysunek 7. Cyfrowy model powierzchni DSM rejonu poszukiwań średniowiecznych umocnień obronnych z nałożonym planem Elbląga z 1655 roku

Źródło: opracowanie własne na podstawie [1, 14]

W poszukiwaniach średniowiecznych umocnień wykorzystano również ortofotomapy powstałe z przetworzenia serii zdjęć lotniczych i obrazów satelitarnych, dostępne na serwisie internetowym Geoportal. Ortofotomapy charakteryzują się brakiem zniekształceń terenu, jednorodną tonacją kolorów oraz jednolitą skalą dla całego obszaru przedstawionego na obrazie – rysunek 8. Parametrem określającym jakość ortofotomapy jest wielkość piksela terenowego GSD (ang. *Ground Sampling Distance*). Ortofotomapa powstaje w wyniku procesu ortorektyfikacji polegającego na ortogonalnym (prostokątnym) przetworzeniu zdjęć lotniczych lub satelitarnych. Obiekty znajdujące się na ortofotomapie zostają odwzorowane w rzucie ortogonalnym, a nie środkowym [13]. Na rysunku 8 przedstawiono ortofotomapę rejonu poszukiwań z nałożonym planem miasta Elbląga z 1655 roku.




Rysunek 8. Ortofotomapa rejonu poszukiwań średniowiecznych umocnień obronnych z nałożonym planem Elbląga z 1655 roku
Źródło: opracowanie własne na podstawie [1, 14]


3. Wyniki wykorzystania technologii AI w planowaniu przelotów fotogrametrycznych

Już na etapie planowania przelotów fotogrametrycznych korzystano ze sztucznej inteligencji. Algorytmy AI narzędzia Plan Mission programu Agisoft Metashape Professional umożliwiły wyznaczenie optymalnych tras przelotu, które omijały przeszkody i spełniały założenia misji. W celu wygenerowania szczegółowych planów misji wykonano proste przeloty nad obszarem poszukiwań i wygenerowano uproszczony model 3D analizowanego terenu. W przelotach nad terenem poszukiwań użyto skośne ustawienie osi kamer pokładowych drona. Zarejestrowane zdjęcia zaimportowano do programu Agisoft Metashape Professional. Zdjęcia były rejestrowane z zadaniem pokryciem wzdłużnym i poprzecznym, równym 80%. Zostały one poddane procesowi wyrównywania, w wyniku którego wyznaczono pokrywające się punkty charakterystyczne występujące we wspólnych obszarach kolejnych zdjęć. Punkty te składają się na pierwszy, wygenerowany produkt fotogrametryczny – rzadką chmurę punktów wiążących zdjęcia. Oszacowano położenia i orientacje kamery pokładowej drona dla każdego zdjęcia [7]. Następnie określono region rekonstrukcji terenu poszukiwań oraz wygenerowano model 3D terenu łącznie z przeszkodami na nim występującymi. W otrzymanym modelu 3D określono punkt odpowiadający miejscu startu i lądowania drona oraz określono strefy zakazu lotów, a także strefę rekonstrukcji terenu poszukiwań. Korzystając


z narzędzi AI wykryto w strefie rekonstrukcji terenu poszukiwań napowietrzne linie energetyczne zapisane następnie w postaci wielolinii w modelu 3D. Obszary wokół linii energetycznych zostały dołączone do obszarów zamkniętych, w których lot drona jest zabroniony. Dostępny w programie Agisoft Metashape klasyfikator linii energetycznych (ang. *Power Lines Classifier*) umożliwia określenie wysokości linii nad powierzchnią terenu, stąd linie ogrodzenia zostaną pominięte – rysunki 9 ÷ 13.



Rysunek 9. Wykryte przez klasyfikator napowietrzne linie energetyczne średniego napięcia i lokalne linie niskiego napięcia
Źródło: opracowanie własne




Rysunek 10. Wykryte przez klasyfikator napowietrzne linie energetyczne średniego napięcia i lokalne linie niskiego napięcia
Źródło: opracowanie własne



Rysunek 11. Wykryte przez klasyfikator napowietrzne linie energetyczne średniego napięcia i lokalne linie niskiego napięcia
Źródło: opracowanie własne

Klasyfikator napowietrznych linii energetycznych przeprowadza analizę kształtów identyfikowanych w chmurze punktów, rozkładu wysokości punktów nad powierzchnią terenu oraz wzorców typowych dla napowietrznych linii energetycznych, wyodrębniając punkty, które reprezentują cienkie, długie obiekty,

przebiegające na określonej wysokości nad ziemią, takie jak przewody, z chmury punktów, pomijając jednocześnie inne struktury (roślinność, drzewa, budynki, powierzchnia gruntu). Klasyfikator filtruje dane, usuwając punkty z chmury punktów, które nie spełniają kryteriów dotyczących wysokości, kształtu oraz wzajemnego położenia, stąd punkty znajdujące się blisko powierzchni ziemi oraz punkty tworzące nieregularne kształty są wykluczane jako potencjalne elementy linii energetycznych. Klasyfikator analizuje poszczególne segmenty linii, zidentyfikowane przez grupy tworzących „liniowe” kształty punktów, które są zbieżne z oczekiwanymi przebiegami przewodów. Klasyfikator linii energetycznych wykrywa zarówno linie wysokiego napięcia, średniego napięcia, jak i lokalne linie niskiego napięcia. W terenie, w którym występuje gęsta roślinność, szczególnie wysoka roślinność, klasyfikator potrafi odseparować przewody linii energetycznych od drzew, nawet w przypadku, gdy drzewa rosną blisko przewodów, na podstawie analizy wysokości punktów i ciągłości rekonstruowanych linii. W obszarach zurbanizowanych linie energetyczne mogą przebiegać wzdłuż ulic, w pobliżu budynków. Klasyfikator musi być w stanie odróżnić linie energetyczne od pobliskich obiektów o podobnym kształcie, od słupów lamp, barier, itp. Klasyfikacja jest procesem iteracyjnym, w którym punkty chmury są wielokrotnie analizowane, w wyniku jego działania są stopniowo poprawiane, w oparciu o przyjęte parametry klasyfikatora.



Rysunek 12. Wykryte przez klasyfikator napowietrzne linie energetyczne średniego napięcia
Źródło: opracowanie własne



Rysunek 13. Wykryte przez klasyfikator napowietrzne linie energetyczne średniego napięcia
Źródło: opracowanie własne

W rezultacie, korzystając z narzędzia Plan Mission, wygenerowano plany misji dostępne w postaci torów przelotu, które następnie zostały wyeksportowane w formacie zgodnym z oprogramowaniem nadajnika RC sterującego dronami. Narzędzie Plan Mission programu Agisoft Metashape Professional pomaga stworzyć optymalne trasy przelotów dronów zapewniające wysokiej jakości modele 3D terenu poszukiwań archeologicznych. Wykorzystanie AI do wykrywania napowietrznych linii energetycznych dodatkowo zapewnia bezpieczeństwo realizowanych przelotów w obszarach miejskich.

4. Dyskusja o generowaniu produktów fotogrametrycznych rejonu poszukiwań

Mury obronne Elbląga zidentyfikowano przy wykorzystaniu fotogrametrii bliskiego zasięgu, analizując produkty fotogrametryczne wygenerowane na podstawie zdjęć zarejestrowanych przez kamerę drona. Zdjęcia zarejestrowane przez kamerę pokładową drona posłużyły do wygenerowania szczegółowych ortofotomap rejonów poszukiwań średniowiecznych umocnień obronnych – rysunek 14. Zdjęcia zostały przetworzone do rzutów ortogonalnych, w rezultacie uzyskano ortoobrazy (ortofotografie). W trakcie tworzenia ortoobrazów ze zdjęć lotniczych usunięto pozorne przemieszczenia nieruchomych obiektów, spowodowane zmianami wysokości terenu (deniwelacją terenu) oraz pochyleniem osi optycznej obiektywu kamery pokładowej. W kolejnym etapie obliczeń ortofotomap wygenerowano ortomozaiki łącząc poszczególne ortoobrazy (ortofotografie) w większe obrazy. Generowane ortomozaiki obejmowały również korekcję radiometryczną ortoobrazów, w trakcie której obrazy zostały wyrównane tonalnie. Korekcja radiometryczna pozwala na uzyskanie spójnych i porównywalnych

obrazów usuwając lub minimalizując błędy na nich występujące. Powyższe błędy obejmują zmiany w oświetleniu terenu poszukiwań, atmosferyczne rozpraszanie światła oraz wpływ cieni. Dokonano korekcję kalibracji matrycy kamery pokładowej drona oraz przeprowadzono korekcję radiometryczną. Korekcja radiometryczna obejmuje korekcję ciemnych pikseli (ang. *Dark Pixel Correction*), polegającą na eliminacji szumu związanego z tzw. „ciemnym prądem” (ang. *Dark Current*), który jest rejestrowany nawet wtedy, gdy matryca nie odbiera żadnego światła. Ciemny prąd jest generowany w matrycy CCD lub CMOS w wyniku termicznego wzbudzenia elektronów, niezależnie od ilości padającego światła, co powoduje rejestrowanie w każdym pikselu minimalnej wartości sygnału, nawet gdy piksel nie jest oświetlony. Na zarejestrowanym obrazie pojawia się wówczas tło, które nie jest związane z rzeczywistym wyglądem sceny. Ciemny prąd wprowadza zniekształcenia, szczególnie w przypadku słabego oświetlenia terenu/obiektu (przy długich czasach naświetlania), zmniejszając różnice pomiędzy jasnymi i ciemnymi obszarami [12].

Na korekcję kalibracji matrycy składa się korekcja zniekształceń (dystorsji) optycznych oraz kalibracja winietowania, polegająca na usunięciu zniekształceń jasności obrazu, spowodowanych przez nierównomierne oświetlenie matrycy. Efekt winietowania obrazu jest zjawiskiem optycznym, w którym jasność obrazu maleje w kierunku jego krawędzi. Efekt ten jest spowodowany przez fizyczne cechy obiektywu (zwłaszcza szerokokątnego), właściwości matrycy, niewłaściwe ustawienie przysłony lub zamontowane filtry optyczne [12].

Do wygenerowania ortofotomapy, przedstawionej na rysunku 14, wykorzystano cyfrowe modele powierzchni DSM, utworzone z gęstej chmury punktów (ang. *Dense Point Cloud*) przez algorytm rekonstrukcji 3D Structure from Motion SfM. Algorytm SfM przetwarza serię zdjęć tego samego obszaru posiadających zadane pokrycie wzdłużne i poprzeczne, co oznacza, że każdy punkt rejestrowanego terenu jest widoczny na co najmniej kilku zdjęciach lotniczych. Na zdjęciach algorytm SfM identyfikuje punkty charakterystyczne (ang. *Keypoints*) występujące w miejscach, w których następują gwałtowne zmiany stopni szarości (przetwarzane zdjęcia są w pierwszej kolejności przekształcane w swoje monochromatyczne odpowiedniki), które można określić na wielu obrazach. Podczas porównywania kolejnych obrazów, na których występują pokrywające się obszary, zastosowano algorytm Scale-Invariant Feature Transform SIFT umożliwiający identyfikację punktów

charakterystycznych niezależnie od zmian skali, kąta orientacji osi optycznej kamery oraz od oświetlenia (niewielkich zmian). Algorytm SIFT został opracowany przez Davida Lowe'a w 1999 roku [3]. W pierwszym kroku algorytm SIFT wykrywa punkty charakterystyczne w wyniku analizy przestrzeni skali. Algorytm tworzy tzw. piramidę obrazów, w której na każdym poziomie znajduje się obraz wykonany w innej skali. Następnie na każdym poziomie piramidy stosowane jest różnicowanie Gaussa DoG (ang. *Difference of Gaussian*) w celu wyznaczenia lokalnych ekstremów skali szarości występujących w różnych skalach. Powyższe ekstrema reprezentują potencjalne punkty charakterystyczne. W kolejnym kroku algorytm SIFT analizuje potencjalne punkty charakterystyczne pod kątem ich stabilności. Punkty niestabilne, czyli punkty o małym kontraście lub punkty leżące bezpośrednio na krawędziach, są odrzucane. Pozostałe punkty są przyjmowane jako punkty charakterystyczne. Dla każdego punktu charakterystycznego algorytm SIFT określa jego orientację, stąd jest on odporny na zmiany obrotu osi optycznej obiektywu kamery. Orientacja punktów charakterystycznych jest określana na podstawie analizy gradientów jasności w macierzy 3 x 3 punktów (pikseli) wokół punktu charakterystycznego. Algorytm tworzy opis sąsiedztwa (ang. *Descriptor*) dla każdego punktu charakterystycznego, w którym zapisany zostaje lokalny wzór gradientów jasności w sąsiedzie punktu. Opis sąsiedztwa jest wektorem o stałej liczbie elementów równej 128, co pozwala na porównywanie punktów charakterystycznych pomiędzy obrazami. Opisy sąsiedztwa punktów charakterystycznych występujących na dwóch kolejnych obrazach, na których występują wspólne obszary (przy pokryciu wzdużnym i/lub poprzecznym) umożliwiają ich dopasowanie. Algorytm SIFT wykorzystuje metrykę, czyli odległość euklidesową (odległością między dwoma punktami w przestrzeni euklidesowej) pomiędzy wektorami opisów sąsiedztwa, w celu wyznaczenia pary punktów, które są prawdopodobnie tym samym punktem na dwóch sąsiednich obrazach [3].

Po wyznaczeniu punktów charakterystycznych na kolejnych obrazach, algorytm SfM oblicza położenie punktów w przestrzeni 3D. Wykorzystuje on zasady geometrii epipolarniej i rzutu perspektywicznego, które umożliwiają rekonstrukcję trójwymiarowego terenu/obiektu na podstawie zdjęć stanowiących dwuwymiarowe projekcje. W przypadku dwóch zdjęć tego samego wycinka terenu/obiektu wykonanych z różnych pozycji drona, punkty jednego obrazu będą miały odpowiadające im punkty na drugim obrazie, które leżą na linii prostej zwanej

linią epipolarną. Przebieg tej linii można wyznaczyć w oparciu o orientację i wzajemne położenie kamery pokładowej w kolejnych miejscach rejestracji zdjęć. Geometria epipolarna posługuje się pojęciami epipoli, linii epipolarniej, macierzy fundamentalnej i macierzy esencjonalnej. Epipola jest punktem obrazu, w którym linia epipolarna przecina się z odpowiadającym mu punktem na drugim obrazie. Jest to więc punkt, z którego widzimy rzutowane obrazy. Linie epipolarne upraszczają proces dopasowywania kolejnych obrazów, ograniczając liczbę miejsc, w których mogą znajdować się odpowiadające sobie punkty charakterystyczne. Macierz fundamentalna opisuje relację pomiędzy dwoma kolejnymi obrazami (relację epipolarną). Macierz zawiera informacje o wzajemnej orientacji i położeniu kamery podczas rejestracji kolejnych obrazów. Macierz fundamentalną wyznacza się na podstawie odpowiadających sobie punktów charakterystycznych znajdujących się na obu kolejnych obrazach. Macierz esencjonalna jest podobna do macierzy fundamentalnej, ale w odróżnieniu od niej uwzględnia kalibrację kamery. Macierz esencjonalna używana jest do wyznaczenia relacji geometrycznych między dwoma kolejnymi obrazami w przestrzeni trójwymiarowej [3]. Podczas rekonstrukcji 3D terenu poszukiwań obliczono również pozycje i orientacje kamer pokładowych dla każdego analizowanego zdjęcia. Zapisane w zdjęciach pozycje (odczytane przez czujnik GPS) i orientacje kamer pokładowych (odczytane przez czujniki gimbała) posłużyły do zwiększenia dokładności generowanej rzadkiej chmury punktów, która obejmuje punkty charakterystyczne jedynie w pokrywających się obszarach zdjęć. W kolejnym etapie, algorytm SfM korzysta z techniki Multi-View Stereo MVS, w celu wygenerowania gęstej chmury punktów odwzorowującej powierzchnię terenu/obiektu z większą dokładnością, niż rzadka chmura punktów. Algorytm Multi-View Stereo MVS zestawia zdjęcia tego samego wycinka terenu/obiektu wykonane w różnych pozycjach drona. Im więcej zdjęć obejmuje analizowany wycinek terenu/obiektu, tym większa jest możliwość dokładnej rekonstrukcji szczegółów. Algorytm MVS oblicza mapę głębokości zawierającą informacje o odległości każdego punktu terenu/obiektu od kamery na podstawie dopasowanych punktów charakterystycznych występujących w kolejnych obrazach. W odróżnieniu od techniki dopasowania stereo (ang. *stereo matching*), która wyznacza głębokości punktów w wyniku porównania dwóch kolejnych obrazów tego samego wycinka terenu/obiektu, algorytm MVS wyznacza mapę głębokości w wyniku porównania większej liczby obrazów [3, 12].


Technologia AI umożliwiła skupić się na obszarach, które wcześniej zostały przeoczone. Powyższa technologia umożliwiła rozpoznanie średniowiecznych umocnień obronnych miasta Elbląga, na podstawie ich kształtu i rozmieszczenia – rysunki 15, 16.



Rysunek 14. Ortofotomapa rejonu poszukiwań z wykrytymi średniowiecznymi umocnieniami Elbląga
Źródło: opracowanie własne



Rysunek 15. Ortofotomapa rejonu poszukiwań z fragmentem wykrytych średniowiecznych umocnień Elbląga
Źródło: opracowanie własne



Rysunek 16. Ortofotomapa rejonu poszukiwań z fragmentem wykrytych średniowiecznych umocnień Elbląga
Źródło: opracowanie własne


W pracy wykorzystano algorytmy AI automatycznie wykrywające anomalie do detekcji ukrytych struktur archeologicznych. Dostępne w programie Agisoft Metashape klasyfikatory umożliwiają przypisanie punktów gęstej chmury punktów do różnych kategorii. Program Agisoft udostępnia szereg klasyfikatorów, w tym klasyfikator gruntu (ang. *Ground Classifier*), klasyfikator roślinności (ang. *Vegetation Classifier*), klasyfikator budynków (ang. *Buildings Classifier*), klasyfikator niskiej roślinności (ang. *Low Point Classifier*) oraz klasyfikator ogólny (ang. *Generic Classifier*), umożliwiającą przeprowadzenie złożonej klasyfikacji punktów

charakterystycznych terenu/obiektu w zależności od potrzeb projektu. Klasyfikator ogólny pozwala na zdefiniowanie niestandardowych kryteriów klasyfikacji, na podstawie kątów nachylenia powierzchni terenu/obiektu, wysokości punktów lub innych parametrów chmury punktów. Klasyfikator gruntu służy do identyfikacji punktów należących do powierzchni gruntu terenu poszukiwań, umożliwiając oddzielenie powierzchni ziemi od roślinności, budynków i innych obiektów. Klasyfikator gruntu analizuje nachylenie powierzchni terenu/obiektu i rozmieszczenie punktów, w celu zidentyfikowania tych, które prawdopodobnie znajdują się na powierzchni ziemi. Punkty te zostają przypisane do klasy Ground.


Klasyfikator roślinności służy do identyfikacji punktów związanych z roślinnością, zarówno wysoką – drzewa, jak i niską – krzewy i trawa. Klasyfikator wykorzystuje wysokość punktów gęstej chmury punktów określoną względem wcześniej zidentyfikowanej powierzchni gruntu. Punkty znajdujące się powyżej określonego poziomu są klasyfikowane jako należące do roślinności. Klasyfikator budynków umożliwia identyfikację punktów należących do powierzchni zewnętrznych budynków, takich jak ściany i dachy. Klasyfikator korzysta z informacji o kształtach i strukturach identyfikowanych w gęstej chmurze punktów. Klasyfikator punktów niskiej roślinności identyfikuje punkty należące do niskiej roślinności, takiej jak trawa lub krzewy. Klasyfikator identyfikuje punkty znajdujące się bezpośrednio nad powierzchnią gruntu, ale nie na tyle wysoko, by uznane zostały za wysoką roślinność lub budynki. Program Agisoft Metashape udostępnia również klasyfikator punktów niskiej jakości (ang. *Low Point Classifier*) identyfikujący punkty, które mogą być szumem lub błędnymi danymi. Punkty te mogą być wynikiem odbić, błędów w rejestracji zdjęć przez kamery pokładowe dronów oraz problemów z teksturami rekonstruowanego terenu/obiektu. Klasyfikator analizując gęstą chmurę punktów identyfikuje punkty, które znacznie odbiegają od reszty punktów pod względem ich wysokości lub gęstości. Punkty niskiej jakości przypisywane są do klasy Low Point. Na rysunku 17 przedstawiono gęstą chmurę punktów poddaną klasyfikacji. Poszukiwano obiekty znajdujące się na granicach zidentyfikowanych klas punktów. Wykryto je na granicach punktów gruntu (zidentyfikowanych przez klasyfikator gruntu), punktów niskiej roślinności (zidentyfikowanych przez klasyfikator niskiej roślinności) i punktów roślinności (zidentyfikowanych przez klasyfikator roślinności). Wyniki identyfikacji umocnień obronnych na granicach klas punktów przedstawiono na rysunkach 18 i 19.



Rysunek 17. Gęsta chmura punktów poddana klasyfikacji
Źródło: opracowanie własne



Rysunek 18. Identyfikacja średniowiecznych umocnień obronnych na granicach klas punktów: kolor czarny – grunt, kolor brązowy – niska roślinność, kolor zielony – roślinność
Źródło: opracowanie własne



Rysunek 19. Identyfikacja średniowiecznych umocnień obronnych na granicach klas punktów: kolor czarny – grunt, kolor brązowy – niska roślinność, kolor zielony – wysoka roślinność
Źródło: opracowanie własne

5. Wnioski

Wykorzystanie sztucznej inteligencji w mapowaniu archeologicznym umożliwia szybkie, efektywne i dokładne przeszukiwanie rozległych obszarów podczas detekcji archeologicznych artefaktów, ukrytych pod gęstą roślinnością, piaskiem, a nawet terenami miejskimi.

Algorytmy uczące się na zbiorach danych z już odkrytych stanowisk archeologicznych mogą identyfikować wyuczone wzorce w nieprzebadanych obszarach. Algorytmy te są również pomocne w priorytetyzacji oraz ocenie ryzyka wykopalisk. Analizując dostępne dane, pomagają w określeniu obszarów, które powinny być badane w pierwszej kolejności, co jest szczególnie pomocne w przypadku ograniczonych zasobów. Określenie obszaru wykopalisk wiąże się również z oceną ryzyka uwzględniającą takie czynniki, jak stabilność gruntu, dostępność, potencjalne zagrożenia dla operatorów dronów oraz odkrytych struktur archeologicznych.

Technologia AI stosowana w dronach jest stale rozwijana i testowana w różnych warunkach środowiskowych, czyniąc drony bardziej autonomicznymi, wydajnymi i zdolnymi do realizacji coraz to bardziej złożonych zadań. Algorytmy AI odgrywają kluczową rolę w archeologii, umożliwiając odkrywanie i badanie średniowiecznych struktur w sposób bardziej efektywny i mniej inwazyjny, niż tradycyjne metody. Połączenie technologii analizy danych, rozpoznawania wzorców i sztucznej inteligencji pozwala na lepsze zrozumienie dziedzictwa kulturowego

Literatura

1. Hauke K., Stobbe H. „Die Baugeschichte und die Baudenkmäler der Stadt Elbing”. Stuttgart 1964.
2. Jagodziński M. „Osadnictwo w okresie wczesnodziejowym”. [w:] Historia Elbląga, t.1 (do 1466 r.), red. S. Gierszewski, A. Groth, s. 17–59, Gdańsk 1993.
3. Kraus K. „Photogrammetry. Geometry and Laser Scans (Second Edition)”. Walter de Gruyter, Berlin, New York 2007
4. Nawrońska G. „Rozwój przestrzenny Elbląga w średniowieczu i okresie wczesnonowożytnym”. *Archaeologia Historica Polona*, tom 23, 2015.
5. Orengo H.A., Garcia-Molsosa A. „A brave new world for archaeological survey: Automated machine learning based potsherd detection using high-resolution drone imagery”. *Journal of Archaeological Science* 112, 2019.
6. Poirier N., Baleux F., Calastrenc C. „The mapping of forested archaeological sites using UAV LiDAR. A feedback from a south-west France experiment in settlement & landscape archaeology”. ISTE Ltd. London (UK) 2020.
7. Remondino F., Campana S. „3D Recording and Modelling in Archaeology and Cultural Heritage Theory and best practices”. *BAR International Series* 2598, Italy 2014.
8. Tapete D. „Remote Sensing and Geosciences for Archaeology”. *Journal Geosciences*, MDPI AG, Basel (Switzerland) 2018.
9. Tiwari A., Silver M., Karnieli A. „A deep learning approach for automatic identification of ancient agricultural water

- harvesting systems”. *International Journal of Applied Earth Observation and Geoinformation* 118, 2023.
10. Willis M.D., Koenig C.W., Black S.L., Castañeda A.M. „Archeological 3D Mapping: The Structure from Motion Revolution”. *Journal of Texas Archeology and History*, V. 3:1-36, USA 2016.
 11. Wright D.J., Harder Ch. „GIS for Science Applying Mapping and Spatial Analysis”. Esri Press, Redlands (USA) 2019.
 12. Zachar L., Horňák M., Novaković P. „3D Digital Recording of Archeological, Architectural and Artistic Heritage”. CONPRA Series, Vol. 1, University of Ljubljana Press, Ljubljana (Slovenia) 2017.
 13. Zakrzewski P. „Geodesy and photogrammetry in archaeology. Advanced documentation methods used by the Kuwaiti–Polish Archeological Expedition. Stories told around the fountain. Papers offered to Piotr Bieliński on His 70th Birthday Polish Centre of Mediterranean Archaeology”. University of Warsaw Press, Warsaw (Poland) 2019.
 14. www.geoportal.gov.pl