

Paweł Buchwald¹

Akademia WSB Dąbrowa Górnicza

ORCID: 0000-0003-2537-7085

Dawid Jurczyński²

Akademia WSB Dąbrowa Górnicza

ORCID: 0009-0005-7362-9779

**Analiza zdjęć satelitarnych z wykorzystaniem metod
sztucznej inteligencji i systemów informatycznych
pod kątem oceny utrzymania bezpieczeństwa infrastruktury
przeciwpowodziowej**

Analysis of satellite images using artificial intelligence methods
and IT systems to assess the maintenance of flood protection
infrastructure

Wprowadzenie

Bezpieczeństwo infrastruktury przeciwpowodziowej, w tym wałów przeciwpowodziowych i polderów, odgrywa kluczową rolę w ochronie ludności, mienia oraz środowiska naturalnego w obszarach zagrożonych powodzią. Efektywne utrzymanie tych struktur wymaga systematycznego monitoro-

1 Paweł Buchwald: dr inż., Akademia WSB w Dąbrowie Górniczej, e-mail: pbuchwald@wsb.edu.pl

2 Dawid Jurczyński: mgr inż., Akademia WSB w Dąbrowie Górniczej, e-mail: ajurczyński@wsb.edu.pl

wania ich stanu technicznego oraz wczesnego wykrywania wszelkich anomalii, które mogą prowadzić do osłabienia ich skuteczności. Jednym z istotnych czynników wpływających na stan infrastruktury przeciwpowodziowej jest rozwój roślinności – zarówno naturalnej, jak i inwazyjnej – która może oddziaływać na stabilność wałów oraz przepustowość terenów retencyjnych.

Nadmierna lub niekontrolowana roślinność na koronach i skarpach wałów może prowadzić do degradacji ich struktury przez osłabienie spójności gruntu, zwiększenie infiltracji wody oraz utrudnienia w prowadzeniu przeglądów technicznych. Z kolei nieodpowiednio utrzymana roślinność w polderach może wpływać na zmniejszenie ich pojemności retencyjnej oraz ograniczenie efektywności odpływu wód. Z tego względu kluczowe staje się opracowanie narzędzi umożliwiających szybkie i precyzyjne wykrywanie zmian pokrycia terenu, w tym stopnia zarastania roślinnością.

W niniejszym artykule przedstawiono podejście badawcze oparte na wykorzystaniu zdjęć satelitarnych w połączeniu z metodami sztucznej inteligencji i nowoczesnymi systemami informatycznymi w celu oceny stanu utrzymania infrastruktury przeciwpowodziowej. Zastosowanie technik przetwarzania obrazów i uczenia maszynowego pozwala na automatyzację procesu klasyfikacji pokrycia terenu, identyfikację niepożądanych zmian roślinnych oraz wspomaganie decyzji zarządczych w zakresie konserwacji i modernizacji obiektów hydrotechnicznych. Podejście to wpisuje się w szerszy kontekst rozwoju systemów monitoringu środowiskowego oraz inteligentnego zarządzania infrastrukturą krytyczną.

Przegląd literatury przedmiotu na temat zastosowania monitoringu satelitarnego i systemów sztucznej inteligencji w obszarze bezpieczeństwa przeciwpowodziowego

Przeprowadzone badania literaturowe dowodzą rosnącej roli sztucznej inteligencji i monitorowania satelitarnego w ocenie stanu infrastruktury przeciwpowodziowej. Szczególnie ważne jest śledzenie rozwoju roślinności, która może wpływać na stan wałów – i to zarówno w sensie wykrywania erozji, jak i zmian w retencji. Technologie obejmujące monitorowanie wizyjne infra-

struktury, w połączeniu z technologią radarową (*Synthetic Aperture Radar*), oraz zbieranie danych bezpośrednio przez osoby nadzorujące, w połączeniu ze sztuczną inteligencją dają dobre efekty w wykrywaniu sytuacji zagrażających prawidłowemu funkcjonowaniu infrastruktury przeciwpowodziowej. Na tym polu coraz częściej wykorzystuje się systemy satelitarne.

W swoim opracowaniu Lee i Li (2025) prezentują szeroki przegląd zastosowań GeoAI do mapowania zasięgu powodzi za pomocą satelitów SAR i multispektralnych. Omawiają dostępne zestawy danych, jak Sen1Floods11, DigiFlood i FloodNet, oraz stosowane architektury CNN i Vision Transformer (ViT). Przedstawiono również techniki redukcji wpływu chmur (np. *cloud augmentation*) i podejścia hybrydowe łączące AI z modelami hydrodynamicznymi. Autorzy zwracają uwagę na potencjał wykonywania obliczeń bezpośrednio na pokładzie satelitów (*onboard processing*). Podkreślają potrzeby standaryzacji formatów danych, adaptacji do lokalnych warunków i zapewnienia odporności systemów w długiej perspektywie. Wskazują także kierunki rozwoju, takie jak integracja różnych sensorów i analiza zmian w roślinności powodziowej.

Z kolei Meng, Xu i Zhu (2025) przedstawiają wyniki badań, w których przeprowadzili porównanie wydajności modeli ViT, DeepLabV3, U-Net i Random Forest na zestawie Sen1Floods11 dla Rio Colima. ViT osiągnął dokładność 94%, IoU 88,7%, przewyższając inne modele. Zaprezentowano techniki augmentacji na danych multispektralnych i SAR, ze szczególnym naciskiem na integrację różnych częstotliwości fal oraz wzmocnienie detekcji obszarów zalewowych. Analiza obejmowała również wpływ parametrów treningu, takich jak liczba epok czy wielkość batcha. Na podstawie wyników autorzy rekomendują stosowanie ensemble'ów i automatycznych algorytmów dedykowanych tagowaniu danych terenowych. Uzasadniają to potrzebą elastyczności względem warunków lokalnych.

Shafiei et al. (2024) przedstawili ramy głębokiego uczenia dla szybkiego mapowania powodzi z użyciem obrazowania multispektralnego (Sentinel-2). Wykorzystali U-Net i DeepLabV3+ oraz wdrożyli maskowanie i uzupełnianie luk spowodowanych przez chmury. Walidacja była prowadzona na siedmiu regionach azjatyckich, osiągnięto dokładność powyżej 92% i AUC ~0,95.

System generuje mapy zalania z niskim odsetkiem fałszywych alarmów, co wspiera działania służb. Przemysłano także implementację w czasie rzeczywistym, stanowiąc bezpośrednie narzędzie dla reagowania kryzysowego.

W opracowaniu autorstwa Gupty i Khana (2024) przedstawiono przegląd obejmujący metody AI stosowane w zarządzaniu ryzykiem powodzi, włączając analizę danych hydrologicznych, satelitarnych i meteorologicznych. Autorzy omawiają wykorzystanie AI do prognozowania powodzi, określania zasięgu i intensywności. Zaprezentowano hybrydowe modele predykcyjne, które łączą modele statystyczne z głębokim uczeniem. Przedyskutowano przeszkody, takie jak brak danych historycznych, zagadnienie interpretowalności (*explainability*) i adaptację modeli do różnych obszarów klimatycznych. Wskazano również na znaczenie integracji społeczności lokalnych i crowdsource'ringu dla poprawy modeli ryzyka.

Smith et al. (2025) przedstawili badanie, które dotyczy narzędzi AI i teledetekcji do wykrywania defektów wałów w USA. Korzystano z obrazu satelitarnego o wysokiej rozdzielczości (WorldView-3) i obrazów SAR. AI wykrywa pęknięcia, erozję, wzrost roślinności powyżej określonego progu oraz osłabienia struktury. Wyniki: redukcja pominięć wad o 35% i skrócenie czasu inspekcji o 60%. Autorzy proponują integrację satelitów, dronów i przeglądów terenowych w krajowych programach monitoringu infrastruktury.

W 2025 roku ukazał się raport opisujący platformę Farmonaut Engine do monitoringu wałów, wykorzystującą satelity Sentinel-2, Landsat 8 i drony UAS. Analiza multispektralna i RGB z zastosowaniem AI umożliwia klasyfikację pokrycia terenu oraz wykrywanie anomalii takich jak osuwiska, przerost roślinności, nieszczelności. Testy w Polsce, Niemczech i Francji wykazały skuteczność w identyfikacji roślinności powyżej 10 cm i szybkie raportowanie. System sprzyja planowaniu prac konserwacyjnych i skraca czas reakcji służb (Farmonaut, 2025).

Kołodziejczyk i Zieliński (2025) dokonali przeglądu zastosowań obrazowania satelitarnego wysokiej rozdzielczości do analizy zniszczeń powodziowych w regionach górskich. Szczególny nacisk położono na zmiany w roślinności, morfologii terenu i osuwiskach. Wykorzystano Sentinel-1/Sentinel-2 i PlanetScope, analizując zarówno pory monsunowe, jak i epizody intensyw-

nych opadów. Wyniki wskazują, że wzrost roślinności na skarpach i wałach jest jednoznacznym wskaźnikiem destabilizacji i powinna towarzyszyć temu dokładna kontrola infrastruktury przeciwpowodziowej.

Praca Torres i Martíneza (2023) skupia się na mapowaniu powodzi globalnych przy użyciu optycznego teledetekcji. Autorzy przedstawiają metody użycia indeksów roślinnych (NDVI, NDWI, SAVI) i technik radiometrycznych dla oceny pokrycia roślinnego i wilgotności gleby. Wykorzystali dane Sentinel-2, Landsat 8 i PlanetScope. Analiza trwała kilka lat i obejmowała obszary rzeczne. Wskazano, że zmiany w roślinności na wałach przeciwdziałają ich skuteczności i mogą oznaczać początkowe fazy erozji. Pracę zamyka rekomendacja regularnego monitoringu i tworzenia progowych wartości wskaźników roślinnych.

Huang i Silva (2024) przedstawiają integrację danych satelitarnych z „social sensing” (posty, zdjęcia od mieszkańców) do szybkiej identyfikacji powodzi. Obrazy optyczne i SAR wspierane były przez informacje od społeczności lokalnej. Wyniki systemu wykazywały poprawę czasową detekcji powodzi o 30% w porównaniu do samych danych satelitarnych oraz lepsze pokrycie obszarów trudno dostępnych. Przykładowo, wzrost roślinności na wałach zgłoszony przez mieszkańców pozwolił wcześniej wykryć potencjalne osłabienia niż narzędzia teledetekcyjne.

Ivanov et al. (2025) przeprowadzili przegląd zastosowań głębokiego uczenia w zarządzaniu katastrofami naturalnymi: powodzią, huraganami i pożarami. Omówiono modele CNN, RNN, GAN i techniki transfer learningu. Szczególną uwagę poświęcono wskaźnikom roślinności jako wskaźnikom zmian środowiskowych. Podkreślili istotność monitorowania rozrostu roślinności wzdłuż wałów powodziowych jako wczesnego sygnału osłabień. Rekomendują połączenie danych teledetekcyjnych z modelami fizycznymi i EOS.

W szerokim przeglądzie AI w obserwacji Ziemi autorstwa Tuia et al. (2023) autorzy omawiają modele CV i ML, integrację wiedzy fizycznej i *explainable* AI. Poruszane są zastosowania w monitoringu roślinności i deforestacji, dzięki czemu możliwe jest adaptowanie tych modeli do oceny stanu wałów. Podkreślają potrzebę standaryzacji i interoperacyjności systemów danych.

Omawiane trendy to hybrydowe sieci i transfer learning oraz federacyjne rozwiązania *privacypreserving*.

Jiang et al. (2023) zaprezentowali metodę generowania corocznych map wysokości roślinności (10 m resolution) na terenach alpejskich, używając Sentinel-2 i głębokich sieci. Metody walidowano porównując z danymi LIDAR i pomiarami in-situ. Uzyskane wyniki z RMSE $\sim 1,2$ m pozwalają wykryć przyrost drzew/traw w różnym stopniu. W artykule argumentują, że analogiczne podejście może służyć do oceny wałów przeciwpowodziowych, gdzie znaczna wysokość roślin wskazuje na brak konserwacji. Proponują kwartalne monitorowanie i włączenie wskaźnika wysokości roślinności do systemów oceny bezpieczeństwa infrastruktury.

W świetle rosnących zagrożeń klimatycznych oraz postępującego starzenia się infrastruktury hydrotechnicznej wykorzystanie nowoczesnych technologii – w szczególności sztucznej inteligencji i zdjęć satelitarnych – staje się nie tylko uzasadnione, ale wręcz konieczne. Zastosowanie algorytmów uczenia maszynowego w analizie danych teledetekcyjnych pozwala na automatyczne i regularne monitorowanie stanu wałów przeciwpowodziowych, polderów oraz otaczającej ich roślinności. Takie podejście umożliwia wczesne wykrywanie zagrożeń, skrócenie czasu reakcji służb technicznych i optymalizację działań konserwacyjnych. Opisywane metody wpisują się w globalne trendy cyfrowej transformacji zarządzania ryzykiem powodziowym oraz inteligentnego nadzoru nad infrastrukturą krytyczną, co potwierdzają liczne badania z ostatnich lat. W efekcie rozwój i wdrażanie tego typu rozwiązań stanowi kierunek o wysokim potencjale naukowym, praktycznym i społecznym.

Możliwości akwizycji danych satelitarnych przydatnych w zadaniu monitorowania infrastruktury przeciwpowodziowej

Współczesne podejście do monitorowania infrastruktury przeciwpowodziowej coraz częściej wykorzystuje dane satelitarne jako podstawowe źródło informacji przestrzennej. W obliczu rosnących zagrożeń klimatycznych, częstych zjawisk ekstremalnych oraz starzejącej się infrastruktury hydrotechnicznej, konieczne jest wdrażanie rozwiązań umożliwiających bieżące i obiektywne

monitorowanie wałów, polderów i innych obiektów ochrony przeciwpowodziowej. Szczególnie istotne jest wykorzystywanie danych z satelitów Sentinel-1 i Sentinel-2, które oferują dostęp do wysokiej jakości danych radarowych i optycznych o różnej rozdzielczości, spektralności oraz częstotliwości aktualizacji. Dane z misji Sentinel-1, realizowanej przez Europejską Agencję Kosmiczną w ramach programu Copernicus, obejmują radarowe zobrazowania SAR (*Synthetic Aperture Radar*) rejestrowane w paśmie C. Ich niewątpliwą zaletą jest niezależność od warunków pogodowych oraz możliwość pozyskiwania danych zarówno w dzień, jak i w nocy. Pozwala to na prowadzenie ciągłego nadzoru nad stanem technicznym wałów przeciwpowodziowych, szczególnie w okresach intensywnych opadów i podtopień. Technika interferometrii radarowej (InSAR), bazująca na analizie różnic fazowych między kolejnymi obrazami, umożliwia detekcję nawet kilkumilimetrowych przemieszczeń pionowych gruntu. To z kolei pozwala na wykrycie potencjalnych deformacji, osiadania lub innych anomalii strukturalnych, zanim jeszcze staną się one zauważalne w terenie (Bamler, Hartl, 1998).

Dzięki bardzo dobrej zdolności penetrowania warstwy roślinnej i detekcji zmian wilgotnościowych, dane SAR mogą być wykorzystywane do identyfikacji obszarów, w których występuje nieprawidłowy rozwój roślinności w obrębie pasów wałowych. Nagromadzenie biomasy w koronach wałów może bowiem świadczyć o braku regularnej pielęgnacji oraz o ryzyku powstawania zagrożeń strukturalnych. W połączeniu z analizą zjawisk takich jak przesiąki, przewilgocenia oraz nierównomierne osiadanie wałów, możliwe jest stworzenie kompleksowego obrazu sytuacji hydrotechnicznej danego obszaru. Obrazy Sentinel-1 mogą być również przetwarzane z wykorzystaniem algorytmów klasyfikacji tekstur (np. GLCM), które umożliwiają detekcję mikroskopijnych zmian w strukturze powierzchni wałów, co wspiera działania konserwacyjne.

Uzupełnieniem danych radarowych są obrazy optyczne pochodzące z satelitów Sentinel-2. Dzięki zastosowaniu 13 kanałów spektralnych oraz rozdzielczości przestrzennej do 10 metrów, możliwe jest dokładne monitorowanie pokrycia terenu oraz zmian w szacie roślinnej, które mogą świadczyć o nieprawidłowościach w funkcjonowaniu infrastruktury. Szczególne znacze-

nie mają tu wskaźniki takie jak NDVI (*Normalized Difference Vegetation Index*) czy NDWI (*Normalized Difference Water Index*), które wykorzystywane są do oceny stanu roślinności i poziomu uwilgotnienia gruntu. Nadmierna lub inwazyjna roślinność porastająca korony wałów może prowadzić do ich osłabienia, dlatego też systematyczne analizowanie zmian tych wskaźników jest niezbędne dla zapewnienia ich stabilności (Gorelick et al., 2017; Huang, Silva, 2024).

Obrazy Sentinel-2 dostępne są w wersji przetworzonej (Level-2A), co oznacza, że poddano je już wstępnej korekcji atmosferycznej. Pasma B8A, B11 i B12 wykazują szczególną przydatność w analizach związanych z monitorowaniem wilgotności gleby oraz oceną warunków roślinnych. Pasma te odpowiadają bowiem zakresom widma bliskiej i krótkiej podczerwieni, które są wrażliwe na zmiany zawartości wody w glebie oraz strukturę roślinną. W wielu przypadkach zastosowanie indeksów takich jak SAVI (*Soil-Adjusted Vegetation Index*) czy EVI (*Enhanced Vegetation Index*) pozwala na uzyskanie bardziej precyzyjnych wyników niż klasyczny NDVI, zwłaszcza w obszarach o dużym udziale powierzchni nieporośniętych.

Warto podkreślić, że zarówno dane z Sentinel-1, jak i Sentinel-2 są ogólnodostępne i darmowe, co umożliwia ich wykorzystanie w szerokim zakresie zastosowań – od projektów badawczych po operacyjne systemy wspomagania decyzji. Przykładem może być platforma Google Earth Engine, która pozwala na przetwarzanie i analizę dużych zbiorów danych satelitarnych w czasie rzeczywistym. Narzędzie to umożliwia wykonywanie złożonych analiz zmian pokrycia terenu oraz automatyczne generowanie map zagrożeń powodziowych. W literaturze przedmiotu podkreśla się rosnące znaczenie integracji danych satelitarnych z algorytmami sztucznej inteligencji, co pozwala na automatyzację procesów klasyfikacyjnych oraz szybsze wykrywanie nieprawidłowości w strukturach hydrotechnicznych (Raspini, Bianchini, Moretti, 2018; Shafiei et al., 2024).

Dane satelitarne mogą być łączone z obserwacjami pozyskiwanymi z bezzałogowych statków powietrznych (UAV), co pozwala na uzyskanie jeszcze wyższej dokładności i rozdzielczości analiz terenowych. W przypadku obiektów hydrotechnicznych trudno dostępnych zastosowanie dronów wyposażo-

nych w sensory optyczne lub hiperspektralne umożliwia uzyskanie danych uzupełniających w zakresie kilku centymetrów na piksel. Dzięki połączeniu danych UAV i zobrazowań satelitarnych możliwe jest tworzenie modeli przestrzennych i ortofotomap, które stanowią podstawę do dokładnej inwentaryzacji obiektów ochrony przeciwpowodziowej. Tego rodzaju podejście stosowano w projektach realizowanych na obszarze Niemiec, Holandii i Polski, gdzie dane Sentinel służyły jako podkład do automatycznego wykrywania stref narażonych na erozję i przesiąki.

Poza misjami Sentinel znaczącą rolę odgrywają również amerykańskie satelity Landsat 8 i 9, które oferują obrazy multispektralne o większym zakresie spektralnym, choć z mniejszą częstotliwością aktualizacji. W praktyce łączenie danych z różnych źródeł pozwala na tworzenie modeli hybrydowych, które zwiększają dokładność i wiarygodność analiz. Coraz częściej wykorzystuje się również dane z platform komercyjnych, takich jak PlanetScope czy Maxar, które dostarczają zobrazowań o rozdzielczości submetrycznej. Choć dostęp do tych danych wiąże się z kosztami, w wielu przypadkach – zwłaszcza w kontekście infrastruktury o znaczeniu strategicznym – ich wykorzystanie okazuje się uzasadnione (Smith et al., 2025).

Dodatkowo, dane satelitarne mogą być wykorzystywane do analizy długoterminowych trendów zmian pokrycia terenu, co pozwala na ocenę skuteczności działań konserwacyjnych i inwestycyjnych. Przykładowo, porównanie serii czasowych NDVI i NDWI pozwala na wykrycie miejsc, gdzie doszło do zmian w zagęszczeniu roślinności lub pojawienia się niekontrolowanego zalewu. Tego rodzaju analizy wspierają również procesy decyzyjne w zakresie planowania rewitalizacji wałów, modernizacji przepustów wodnych czy budowy nowych zbiorników retencyjnych.

Jednym z istotnych aspektów procesu akwizycji danych satelitarnych jest ich wstępne przetwarzanie (*preprocessing*), obejmujące m.in. korekcję atmosferyczną, usuwanie chmur, kalibrację radiometryczną i geometryczną oraz dopasowanie czasowe. W przypadku danych optycznych szczególnie dużym wyzwaniem jest obecność chmur, które mogą znacząco obniżyć jakość obrazów. W tym celu stosuje się specjalistyczne algorytmy, takie jak Sen2Cor czy Fmask, które umożliwiają identyfikację i maskowanie obszarów pokrytych za-

chmurzeniem oraz interpolację brakujących danych. W przypadku danych radarowych kluczowa jest z kolei kalibracja interferometryczna, która warunkuje poprawność analiz deformacyjnych (Wegmüller et al., 2010).

Rosnącą popularność zyskują również metody fuzji danych, polegające na łączeniu różnych typów informacji (SAR, optyka, dane lidarowe, dane społecznościowe) w celu uzyskania pełniejszego obrazu sytuacji. Przykładem mogą być systemy monitoringu wykorzystujące dane społecznościowe (*social sensing*), takie jak zdjęcia geotagowane lub raporty mieszkańców, które mogą wspierać dane satelitarne poprzez dostarczanie informacji lokalnych, trudnych do uchwycenia z orbity. W przyszłości przewiduje się rozwój zintegrowanych platform monitorujących w czasie rzeczywistym, które będą łączyły dane z satelitów, dronów, sensorów naziemnych oraz danych crowdsourcingowych (Xie, Sha, Yu, 2020).

Współczesne możliwości akwizycji danych satelitarnych w kontekście monitorowania infrastruktury przeciwpowodziowej są szerokie i dynamicznie się rozwijają. Ich dostępność, różnorodność oraz integracja z nowoczesnymi metodami analizy danych, w tym algorytmami sztucznej inteligencji, stanowią podstawę nowoczesnych systemów zarządzania ryzykiem powodziowym. Inwestycje w rozwój takich rozwiązań są w pełni uzasadnione z punktu widzenia zarówno inżynierii, jak i polityki publicznej. Zastosowanie danych satelitarnych pozwala na podniesienie poziomu bezpieczeństwa ludności, zwiększenie efektywności działań prewencyjnych oraz redukcję kosztów związanych z usuwaniem skutków powodzi.

Biblioteki programistyczne, serwisy i narzędzia umożliwiające dostęp do danych satelitarnych dla potrzeb monitorowania infrastruktury przeciwpowodziowej

Współczesne systemy zarządzania ryzykiem powodziowym w coraz większym stopniu opierają się na analizie danych teledetekcyjnych, pozyskiwanych z różnorodnych satelitarnych platform obserwacyjnych. Aby skutecznie wykorzystać potencjał tych danych, niezbędne jest posługiwanie się nowoczesnymi narzędziami informatycznymi, które umożliwiają ich wyszukiwanie,

przetwarzanie i analizę. Narzędzia te obejmują zarówno biblioteki programistyczne wykorzystywane w językach Python i R, jak i odpowiednie serwisy internetowe i platformy analityczne wspomagające działania instytucji odpowiedzialnych za utrzymanie infrastruktury przeciwpowodziowej. Jednym z najważniejszych i najbardziej elastycznych narzędzi umożliwiających pracę z danymi satelitarnymi jest Google Earth Engine (GEE). Jest to platforma chmurowa oferująca dostęp do petabajtów danych z misji Sentinel, Landsat, MODIS oraz wielu innych. Google Earth Engine umożliwia programistyczne zapytania i analizy danych z wykorzystaniem języka JavaScript lub Python, a także pozwala na tworzenie złożonych aplikacji webowych służących do analizy pokrycia terenu, detekcji zmian wilgotności oraz oceny stanu roślinności na wałach przeciwpowodziowych. Istotnym atutem GEE jest możliwość tworzenia skalowalnych analiz czasowych, np. wykrywania anomalii NDVI w pasach wałowych lub lokalizacji podtopień. Kolejnym narzędziem godnym uwagi jest platforma Sentinel Hub, która umożliwia przeglądanie i pobieranie danych z satelitów Sentinel-1, Sentinel-2, Landsat i MODIS. Sentinel Hub oferuje narzędzie EO Browser, które pozwala w sposób interaktywny analizować dane optyczne i radarowe oraz generować własne skrypty w języku Evalscript do wyświetlania wskaźników (np. NDVI, NDWI, Moisture Index). Platforma ta może być wykorzystywana do szybkiej identyfikacji obszarów o wysokim zagrożeniu erozją lub wzmocnionym przyroście roślinności na wałach, co może świadczyć o braku konserwacji. W kontekście bardziej zaawansowanych analiz przestrzennych dużą rolę odgrywają biblioteki programistyczne w języku Python, takie jak:

- Rasterio – do odczytu i zapisu danych rastrowych (GeoTIFF, NetCDF),
- GDAL/OGR – fundament operacji na danych geograficznych,
- xarray i rioxarray – do obsługi danych wielowymiarowych z satelitów,
- Sentinelsat – biblioteka do wyszukiwania i pobierania danych z portalu Copernicus Open Access Hub (dawniej SciHub),
- Pyproj – do transformacji współrzędnych przestrzennych,
- scikit-image, OpenCV, scikit-learn, TensorFlow – do analiz obrazu, klasyfikacji i implementacji algorytmów uczenia maszynowego.

Dla użytkowników preferujących pracę z narzędziami typu „point-and-click” wartościowym źródłem danych jest platforma Copernicus Data Space Ecosystem – oficjalny serwis Europejskiej Agencji Kosmicznej umożliwiający dostęp do danych Sentinel-1, -2, -3 i -5P, z możliwością tworzenia własnych zapytań przestrzennych i czasowych. Alternatywnie, amerykańska platforma USGS Earth Explorer pozwala na pobieranie danych z satelitów Landsat, ASTER czy MODIS, co może stanowić uzupełnienie danych europejskich o obserwacje wieloletnie. Na szczególną uwagę zasługuje również platforma Planet.com, która oferuje dostęp do komercyjnych danych satelitarnych o bardzo wysokiej rozdzielczości przestrzennej (do 50 cm/piksel) i wysokiej częstotliwości aktualizacji (do kilku razy dziennie). Firma Planet dostarcza dane z konstelacji satelitów Dove i SkySat, które mogą być szczególnie użyteczne w zadaniach wymagających precyzyjnego monitoringu wałów, np. w sytuacjach powodziowych, kiedy szybka detekcja uszkodzeń i przesiąków ma kluczowe znaczenie. Planet oferuje API do integracji danych z systemami GIS, a także narzędzia webowe do przeglądania i zamawiania zobrazowań archiwalnych i bieżących. W ramach współpracy z instytucjami publicznymi i naukowymi (np. w programie NICFI – wspierającym monitoring wylesiania) możliwy jest także bezpłatny dostęp do wybranych danych.

Tabela 1. Porównanie usług i narzędzi akwizycji danych satelitarnych w środowisku Internet

Serwis/ Narzędzie	Rodzaj danych	Rozdzielczość	Częstotliwość	Dostępność
Google Earth Engine	Sentinel, Landsat, MODIS i inne	10–30 m	codzienna	darmowa
Sentinel Hub	Sentinel-1, 2, MODIS, Landsat	10 m	kilka dni	darmowa i komercyjna
Planet.com	komercyjne VHR	0,5–3 m	codzienna (nawet 5x dziennie)	komercyjna, częściowo darmowa (NICFI)

Copernicus Data Space Ecosystem	Sentinel-1, 2, 3, 5P	10–60 m	5–10 dni	darmowa
USGS Earth Explorer	Landsat, ASTER, MODIS	15–30 m	16 dni	darmowa
GEP (ESA)	InSAR z Sentinel-1	do 10 m (przetworzone)	6 dni	darmowa
QGIS + SCP	różne źródła (Sentinel, Landsat)	10–30 m	zmienna	darmowa
Open Data Cube	zróżnicowane (NDVI, pokrycie)	do 10 m	zmienna	open-source
Descartes Labs	komercyjne i meteorologiczne	zmienna	zmienna	komercyjna
UP42	komercyjne i Sentinel	zmienna	zmienna	komercyjna

Źródło: opracowanie własne

W praktyce działania monitorujące infrastrukturę hydrotechniczną wymagają nie tylko dostępu do zobrazowań, ale także ich integracji z danymi meteorologicznymi, hydrologicznymi i topograficznymi. W tym celu często korzysta się z usług agregujących, takich jak Open Data Cube, TerrSet, QGIS z wtyczkami Semi-Automatic Classification Plugin lub narzędzia ILWIS, rozwijanego przez ITC na Uniwersytecie Twente. QGIS oferuje możliwość automatyzacji analizy serii czasowych NDVI, importu danych z Sentinel Hub, integracji z Pythonem i wizualizacji danych przestrzennych na poziomie lokalnym. Niektóre z platform pozwalają również na monitorowanie deformacji terenu z wykorzystaniem technik InSAR. Przykładem może być GEP (*Geohazards Exploitation Platform*), stworzona przez ESA, która oferuje przetworzone produkty deformacyjne na podstawie danych z Sentinel-1. Tego typu dane są kluczowe przy ocenie stabilności podłoża pod wałami, a ich analiza umożliwia przewidywanie miejsc potencjalnych awarii i lokalnych zapadlisk. W ostatnich latach rośnie również rola usług opartych na sztucznej inteligencji i automatycznym wykrywaniu zmian. Przykładem może być

platforma Descartes Labs, która umożliwia klasyfikację obrazów satelitarnych w czasie rzeczywistym oraz budowanie własnych modeli predykcyjnych z wykorzystaniem danych satelitarnych i meteorologicznych. Podobnie Satelligence czy UP42 oferują narzędzia analityczne do wykrywania zagrożeń hydrologicznych, detekcji obiektów oraz monitorowania zmian użytkowania terenu z wykorzystaniem metod głębokiego uczenia.

Autorski system informatyczny wspomagający ocenę zagrożeń dla infrastruktury przeciwpowodziowej

W obliczu rosnących zagrożeń klimatycznych oraz wzrastającej częstotliwości występowania zjawisk ekstremalnych, takich jak intensywne opady i powodzie, konieczne staje się wdrażanie zaawansowanych systemów monitorowania infrastruktury hydrotechnicznej. W szczególności dotyczy to wałów przeciwpowodziowych, polderów oraz innych elementów zabezpieczających tereny zamieszkałe i rolnicze. Tradycyjne metody inspekcji, oparte na przeglądach wizualnych, są czasochłonne, kosztowne i nie zapewniają wystarczającej częstotliwości kontroli. Dlatego coraz większą rolę w tym obszarze odgrywają dane satelitarne, które umożliwiają monitorowanie dużych obszarów w sposób zdalny, powtarzalny i obiektywny.

Projektowany system ma na celu stworzenie kompleksowego rozwiązania informatycznego wspomagającego ocenę stanu technicznego infrastruktury przeciwpowodziowej w oparciu o zobrazowania satelitarne oraz metody sztucznej inteligencji. Kluczowym elementem tej architektury jest integracja z systemem dostępu do danych oferowanym przez firmę Planet Labs, który został wybrany jako główne źródło zobrazowań ze względu na wyjątkowe parametry rozdzielczości przestrzennej i częstotliwości akwizycji. Satelity Dove i SkySat zapewniają dostęp do danych o rozdzielczości od 0,5 do 3 metrów oraz mogą wykonywać zdjęcia danego obszaru nawet kilka razy dziennie. Taka jakość i częstotliwość zobrazowań pozwalają na szybkie wykrycie zmian na powierzchni wałów, takich jak pęknięcia, przesiąki, erozja czy niekontrolowany przyrost roślinności.

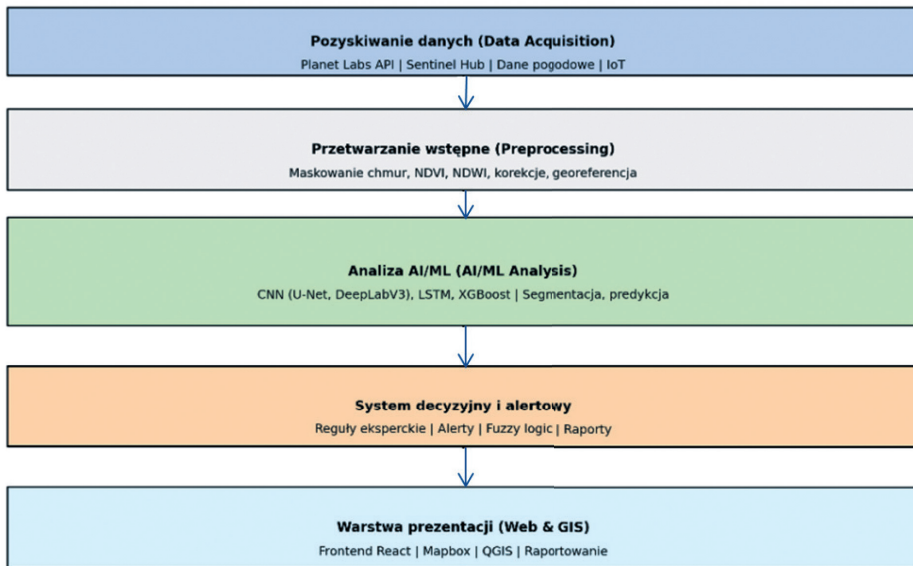
Architektura systemu została zaprojektowana w sposób modułowy i składa się z pięciu głównych warstw funkcjonalnych. Pierwszą z nich jest warstwa pozyskiwania danych, której zadaniem jest automatyczne pobieranie obrazowań z serwisu Planet Labs poprzez dostępne API. System umożliwia definowanie obszarów zainteresowania (AOI), harmonogramowanie zapytań oraz filtrowanie obrazów pod względem jakości (np. stopień zachmurzenia). Dodatkowo dane mogą być uzupełniane o obrazowania z misji Sentinel-1 (SAR) i Sentinel-2 (optyka), które stanowią uzupełnienie niskokosztowe i dostępne publicznie. Możliwe jest również pozyskiwanie danych meteorologicznych (opady, wilgotność powietrza) z serwisów typu OpenWeatherMap lub danych z lokalnych czujników IoT, które mogą zostać zintegrowane z systemem. Kolejnym komponentem jest warstwa przetwarzania wstępnego, odpowiedzialna za przygotowanie danych do dalszej analizy. Dane są przekształcane do spójnych układów współrzędnych oraz cięte przestrzennie według obszarów analizowanych (np. poszczególne odcinki wałów). Serce systemu stanowi warstwa analityczna, oparta na metodach sztucznej inteligencji i uczenia maszynowego. Do analizy danych obrazowych wykorzystywane są sieci konwolucyjne (CNN), np. architektury typu U-Net lub DeepLabV3, które pozwalają na segmentację obszarów zagrożonych oraz detekcję anomalii (np. miejsc przesiąków, deformacji, zmian tekstury powierzchni). Dodatkowo, sieci rekurencyjne (np. LSTM) są stosowane do analizy serii czasowych wskaźników roślinnych i wilgotnościowych, co umożliwia wykrywanie długofalowych zmian. Modele klasyfikacyjne, takie jak XGBoost czy Random Forest, służą do przypisywania poziomów ryzyka danemu odcinkowi infrastruktury na podstawie zestawu cech wejściowych (m.in. NDVI, NDWI, nachylenie terenu, intensywność zmian pokrycia).

Model może być trenowany lokalnie przy użyciu danych referencyjnych z inspekcji terenowych lub raportów historycznych. Warstwa systemu decyzyjnego pełni funkcję ekspercką i służy do generowania alertów oraz interpretacji wyników modeli AI. Obejmuje ona reguły eksperckie (np. „NDVI > 0,7 przez 3 tygodnie na koronie wału” → wysoki poziom ryzyka), system rozmyty oceniający kombinację różnych czynników (np. wilgotność + pokrycie + deformacje) oraz silnik wnioskowania logicznego. Alerty są generowane auto-

matycznie i mogą być przesyłane do użytkowników końcowych (inżynierów, zarządców infrastruktury, służb kryzysowych) w formie powiadomień e-mail, SMS lub notyfikacji systemowych. Możliwe jest również przygotowywanie raportów okresowych w formacie PDF lub GeoPDF oraz eksport danych przestrzennych jako warstw WMS lub GeoJSON do systemów GIS. Ostatnią warstwą jest warstwa prezentacji wyników, która oferuje użytkownikom dostęp do interfejsu webowego oraz narzędzi GIS. Interfejs systemu oparty jest na nowoczesnych technologiach wizualizacyjnych i pozwala na interaktywną analizę danych przestrzennych – np. kliknięcie na odcinek wału wyświetla historię zmian NDVI, lokalne alerty oraz przewidywane trendy. System umożliwia również generowanie map zagrożeń, które mogą być publikowane jako dynamiczne warstwy mapowe. Dla zaawansowanych użytkowników dostępny jest panel administracyjny pozwalający na konfigurowanie parametrów detekcji, progów alarmowych oraz planowania inspekcji terenowych.

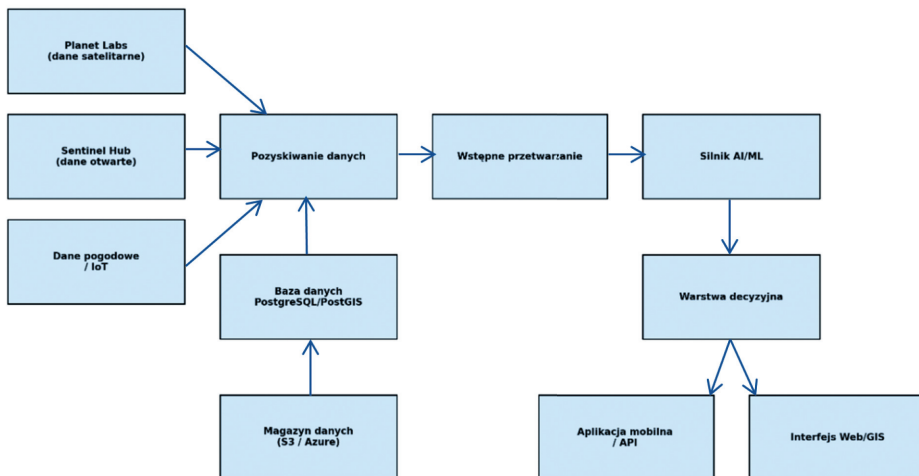
Całość architektury jest oparta na podejściu mikrousługowym, w którym każdy komponent działa jako niezależna jednostka obsługiwana przez kontener (*Docker*). Usługi komunikują się ze sobą poprzez API REST, a dane są przetwarzane zarówno w trybie wsadowym (*batch*), jak i strumieniowym (*streaming*) z wykorzystaniem Apache Kafka i Airflow. Dane obrazowe przechowywane są w repozytorium plików (np. Amazon S3 lub Azure Blob), natomiast metadane, alerty i konfiguracje użytkowników – w relacyjnej bazie danych PostgreSQL z rozszerzeniem przestrzennym PostGIS. System może być wdrożony w chmurze publicznej, prywatnej lub jako instalacja lokalna w strukturze zarządzania kryzysowego. Dodatkową wartością systemu może być jego integracja z urządzeniami mobilnymi (np. aplikacja dla inspektorów terenowych), które umożliwią lokalne potwierdzanie lub weryfikację alarmów wykrytych automatycznie. Możliwe jest także wdrożenie komponentów rozszerzonej rzeczywistości (AR) dla wizualizacji danych na miejscu. System może być sukcesywnie rozszerzany o dodatkowe dane (np. z UAV lub lidar) oraz nowe funkcjonalności analityczne, dzięki modularnej strukturze.

II. 1. Sekwencja przetwarzania danych w autorskim oprogramowaniu



Źródło: opracowanie własne.

II. 2. Modułowa architektura systemu



Podsumowując, architektura systemu AI łączy w sobie zalety danych satelitarnych wysokiej rozdzielczości oferowanych przez Planet Labs z nowoczesnymi metodami analizy danych i uczenia maszynowego. Tego typu rozwiązanie wpisuje się w aktualne trendy cyfryzacji zarządzania infrastrukturą krytyczną oraz wykorzystania Earth Observation w zarządzaniu ryzykiem. System może znacząco przyczynić się do zwiększenia skuteczności monitoringu wałów przeciwpowodziowych, szybszego reagowania na zagrożenia oraz optymalizacji działań konserwacyjnych. Sekwencje przetwarzania danych w autorskim oprogramowaniu przedstawiono na ilustracji 1, natomiast jego podział na odpowiednie moduły przedstawia ilustracja 2.

Podsumowanie

Zaproponowane w artykule podejście do wspomagania monitorowania bezpieczeństwa infrastruktury przeciwpowodziowej przy wykorzystaniu zdjęć satelitarnych i metod sztucznej inteligencji potwierdza zasadność integracji nowoczesnych źródeł danych z algorytmami uczenia maszynowego. Zaprezentowany w artykule system, dzięki wielowarstwowej architekturze uwzględniającej moduły pozyskiwania, przetwarzania i analizy danych oraz warstwę prezentacyjną i decyzyjną, stanowi potencjalne narzędzie wspierające jednostki odpowiedzialne za utrzymanie infrastruktury hydrotechnicznej, takich jak wały przeciwpowodziowe czy poldery. Pomimo pozytywnych wyników testów i wysokiego stopnia automatyzacji procesu, należy zaznaczyć, że system znajduje się obecnie na etapie koncepcyjnym lub pilotażowym. W związku z tym konieczne są dalsze badania obejmujące jego długoterminowe wdrożenie i obserwację w warunkach rzeczywistych. Szczególnie istotne będzie śledzenie skuteczności działania systemu w różnych warunkach sezonowych, przy zróżnicowanej dynamice roślinności oraz zmienności hydrologicznej. Dodatkowo, niezbędna jest analiza stabilności działania algorytmów uczenia maszynowego w czasie, w szczególności w kontekście ich adaptacyjności do zmieniających się danych wejściowych. Zasadna wydaje się także dalsza rozbudowa systemu o dodatkowe źródła danych – takie jak dane radarowe o wysokiej rozdzielczości (np. z satelitów TerraSAR-X), dane z naziemnych

czujników hydrometrycznych czy dane meteorologiczne w czasie rzeczywistym. Integracja z systemami predykcji meteorologicznej lub hydrologicznej mogłaby zwiększyć skuteczność i precyzję generowanych alertów. Rozbudowa modułu decyzyjnego o bardziej zaawansowane techniki logiki rozmytej, modele probabilistyczne lub systemy wspierające podejmowanie decyzji mogłaby również umożliwić generowanie bardziej złożonych scenariuszy oceny ryzyka. W kontekście użytkowym system może być rozwijany w kierunku dostosowania interfejsu do potrzeb różnych grup użytkowników – od służb zarządzania kryzysowego, przez administrację lokalną, aż po rolników i użytkowników indywidualnych zagrożonych powodzią. Warto także rozważyć zastosowanie systemu w szerszym kontekście środowiskowym – m.in. do monitorowania terenów podmokłych, retencji wód lub zmian pokrycia terenu. Podsumowując, opracowane rozwiązanie stanowi solidną podstawę do dalszych prac badawczo-rozwojowych, a jego pełne wdrożenie wymaga wieloetapowych testów, walidacji i integracji z innymi systemami informacji przestrzennej oraz zarządzania ryzykiem powodziowym.

Streszczenie: W artykule przedstawiono autorski system wspomagający ocenę bezpieczeństwa infrastruktury przeciwpowodziowej z wykorzystaniem danych satelitarnych oraz metod sztucznej inteligencji. Zaprojektowana architektura integruje dane z serwisów takich jak Planet Labs i Sentinel Hub, przetwarza je za pomocą zaawansowanych algorytmów przetwarzania obrazu i uczenia maszynowego, a następnie przekazuje wyniki do modułu decyzyjnego. Celem systemu jest identyfikacja zmian roślinności oraz deformacji strukturalnych w obrębie wałów i polderów, które mogą wskazywać na ryzyko obniżenia ich skuteczności. Artykuł omawia również możliwości dalszego rozwoju rozwiązania, w tym jego testowanie w rzeczywistych warunkach, integrację z danymi hydrologicznymi i meteorologicznymi oraz dostosowanie do potrzeb użytkowników instytucjonalnych i lokalnych społeczności.

Abstract: The article presents a proprietary system supporting the assessment of flood protection infrastructure safety using satellite data and artificial intelligence methods. The designed architecture integrates data from services such as Planet Labs and Sentinel Hub, processes it using advanced image processing and machine learning algorithms, and then transmits the results to a decision-making module. The aim of the system is to identify changes in vegetation and structural deformations within embankments and polders that may indicate a risk of reduced effectiveness. The article also discusses the possibilities for further development of the solution, including testing it in real conditions, integrating it with hydrological and meteorological data, and adapting it to the needs of institutional users and local communities.

Słowa kluczowe: sztuczna inteligencja, infrastruktura przeciwpowodziowa, zdjęcia satelitarne, Planet Labs, Sentinel, monitoring roślinności, analiza ryzyka, systemy GIS

Keywords: artificial intelligence, flood infrastructure, satellite imagery, Planet Labs, Sentinel, vegetation monitoring, risk analysis, GIS systems

Bibliografia

- Bamler, R., Hartl, P. (1998). Synthetic aperture radar interferometry, *Inverse Problems*, 14(4), R1.
- Farmonaut. (2025). *Utilize Farmonaut Engine to Monitor Levees Efficiently*. Farmonaut Platform Report.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone, *Remote Sensing of Environment*, 202, 18–27.
- Gupta, S., Khan, M. (2024). Artificial intelligence for flood risk management, *Journal of Environmental Informatics*, 9(2).
- Huang, X., Silva, M. (2024). Integrating remote sensing and social sensing for flood mapping, *Journal of Flood Risk Science*, 12(1).
- Ivanov, P., et al. (2025). Deep Artificial Intelligence Applications for Natural Disaster Management, *Environmental Informatics Reports*, 5(2).
- Jiang, Y., Rüetschi, M., Sainte Fare Garnot, V., et al. (2023). Accuracy and Consistency of Space-based Vegetation Height Maps for Forest Dynamics in Alpine Terrain, *arXiv preprint*, arXiv:2309.01797.
- Kołodziejczyk, P., Zieliński, T. (2025). A comprehensive review of flood damage in mountainous regions, *Environmental Reviews*, 8(3).
- Lee, H., Li, W. (2025). Geospatial Artificial Intelligence for Satellite-based Flood Extent Mapping: Concepts, Advances, and Future Perspectives, *arXiv preprint*, arXiv:2504.02214.1.
- Meng, B., Xu, C., Zhu, Y. (2025). *Flood Detection Modeling: Leveraging The SEN-FLOOD11 Dataset for The Rio Colima River*. ICLR 2025 Conference Proceedings.
- Raspini, F., Bianchini, S., Moretti, S. (2018). Multi-temporal InSAR analysis of deformation phenomena in urban areas, *Remote Sensing*, 10(1), 76.
- Shafiei, A., et al. (2024). A Deep Learning framework for rapid flood mapping using optical satellite imagery, *Scientific Reports*, 14, 69977.
- Smith, J., et al. (2025). Enhancing Levee Inspections with Advanced Technology, *Geomatics in Infrastructure Safety Journal*.
- Torres, R., Martínez, L. (2023). Optical Remote Sensing for Global Flood Disaster Mapping, *Remote Sensing*, 17(11), 1886.

- Tuia, D., Schindler, K., Demir, B., et al. (2023). Artificial intelligence to advance Earth observation: A review of models, recent trends, and pathways forward, *arXiv preprint*, arXiv:2305.08413.
- Wegmüller, U., Walter, D., Spreckels, V., Werner, C. (2010). Nonuniform ground motion monitoring with TerraSAR-X persistent scatterer interferometry, *IEEE Transactions on Geoscience and Remote Sensing*, 48(2), 895–904, <https://doi.org/10.1109/TGRS.2009.2030792>.
- Xie, Y., Sha, Z., Yu, M. (2020). Remote sensing imagery in vegetation mapping: a review, *Journal of Plant Ecology*, 13(1), 1–12.