

Widzieć więcej niż oko: AI w walce o zdrowe lasy

Zmiany klimatu przestały być nierealnym scenariuszem rodem z filmu science-fiction. Od połowy XIX wieku średnia temperatura Ziemi wzrosła o około 1°C, a wzrost ten przyspiesza w ostatnich dekadach. Modele klimatyczne prognozują dalszy wzrost nawet o 1,6-5°C do 2100 roku. Skutkami są m.in. topnienie lodowców, wzrost poziomu mórz oraz częstsze ekstremalne zjawiska pogodowe. Zmiany te wpływają na ekosystemy, rolnictwo i zdrowie ludzi, zwiększając ryzyko susz, powodzi i chorób. Są również coraz częściej zauważalne w krajobrazie. Widać je w przesuszonych siedliskach, w rozregulowanych cyklach fenologicznych oraz w drzewostanach, które jeszcze dekadę temu uchodziły za stabilne, a dziś wykazują oznaki stresu i stopniowego zamierania.

W polskich lasach jednym z najbardziej wrażliwych gatunków pozostaje świerk pospolity – gatunek o dużym znaczeniu gospodarczym, ale jednocześnie silnie uzależniony od odpowiednich warunków siedliskowych. Przez wiele lat świerk, ze względu na walory drewna, był sadzony w miejscach znajdujących się poza jego naturalnym zasięgiem. Często były to siedliska mniej wilgotne, niż ten gatunek preferuje. Rosnące temperatury oraz coraz częstsze i dłuższe susze sprawiają, że takie drzewostany stają się szczególnie podatne na osłabienie, a co za tym idzie na gradacje szkodników i procesy zamierania.

Jednak negatywnych skutków doświadcza nie tylko świerk. Sosna zwyczajna doświadcza spadków przyrostu i zamierania w wyniku susz i wysokich temperatur, które zaburzają jej gospodarkę wodną. Szczególnie dotkliwe jest to na najżyźniejszych siedliskach, gdzie drzewa rosną wysokie i grube. Dzieje się tak ponieważ w miejscach, gdzie zawsze był łatwy dostęp do wody i składników pokarmowych sosny (i nie tylko) nie były

przyzwyczajone do braków, dlatego nie wykształciły mechanizmów zwiększających odporność na czynniki stresowe. Osobniki, które od początku rosną na ubogich i suchych siedliskach są wykazują lepsze przystosowanie do braku zasobów wodnych. Ich energia od początku była inwestowana w rozbudowę systemów korzeniowych, aby mogły one sięgać głębiej, gdzie znajduje się woda. Skala problemu jest tak dotkliwa, ponieważ dorosłe drzewo nie ma już odpowiedniej elastyczności i możliwości znaczącej rozbudowy systemu korzeniowego.

Zmiany klimatu wciąż się nasilają, dlatego odporność drzew ulega osłabieniu. Osobnik z zachwianą odpornością zaczyna inwestować energię w przetrwanie. Ceną tego jest opuszczenie tarczy w postaci naturalnych mechanizmów obronnych zabezpieczających przez infekcją szkodników i chorób wtórnych (czyli takich, które atakują osłabione drzewa). Przykładem takiego szkodnika wtórnego jest kornik drukarz, który już prawie dekadę temu wywołał spore zamieszanie w Białowieskim Parku Narodowym atakując ogromne ilości świerków, które uległy masowemu zamieraniu.


Stojące martwe drzewo, które jest zasiedlone przez szkodliwe owady w leśnictwie określane jest terminem „posusz czynny”. Pełni on istotną rolę ekologiczną jako siedlisko dla wielu organizmów oraz element obiegu materii, jednak ze względu na konieczność przeciwdziałania gradacjom owadów oraz rozprzestrzenianiu się chorób wynikającą z przepisów prawnych i zasad prowadzenia gospodarki leśnej, Lasy Państwowe dążą do usuwania takich drzew w ramach prowadzonych zabiegów sanitarnych.

Skala tego zjawiska wykracza jednak daleko poza pojedyncze przypadki występowania martwych drzew. Jak wskazują wyniki badań z ostatnich lat, ryzyko zamierania drzewostanów dotyczy wielu gatunków drzew i lokalnie osiąga bardzo wysoki poziom. Oznacza to, że proces zamierania przestaje być incydentem, a staje się jednym z kluczowych czynników kształtujących współczesne lasy. Wraz z prognozowanym dalszym wzrostem

temperatur i nasilaniem się deficytu wody można spodziewać się, że zjawisko to będzie się pogłębiać, wpływając nie tylko na kondycję pojedynczych drzew, ale na funkcjonowanie całych ekosystemów leśnych. Właśnie w tym kontekście powstała praca inżynierska pani Natalii Rębisz pt. „Detekcja martwych drzew świerka pospolitego na terenie Nadleśnictwa Giżycko w oparciu o ortofotomapy lotnicze oraz wysokościowy model koron drzew” zrealizowana na Wydziale Leśnym Uniwersytetu Rolniczego im. Hugona Kołłątaja w Krakowie pod opieką dra inż. Pawła Hawryła. Celem tej pracy było stworzenie narzędzia do automatycznej detekcji stojących martwych drzew na podstawie wysokorozdzielczych danych lotniczych. Do zrealizowania tego zadania wykorzystano metody głębokiego uczenia (ang. deep learning) stanowiące element sztucznej inteligencji. Projekt ten stał się jednocześnie studium integracji klasycznych narzędzi GIS z zaawansowaną analizą obrazów opartą na sztucznej inteligencji.


Zobaczyć niewidoczne – rola kompozycji CIR w ocenie zdrowotności drzewostanów

Podstawą analiz była tzw. prawdziwa ortofotomapa (ang. true orthophoto) lotnicza w kompozycji CIR (ang. Color Infrared), wykonana z pikselem terenowym 0,25 m. Taka rozdzielczość pozwala analizować pojedyncze korony drzew, ich strukturę, teksturę oraz zróżnicowanie barwne. W przeciwieństwie do klasycznego obrazu RGB kompozycja CIR zawiera kanał bliskiej podczerwieni (NIR, ang. near infrared), który jest szczególnie wrażliwy na stan fizjologiczny roślinności.



Martwe drzewo (na środku grafiki) w otoczeniu zdrowych na obrazowaniu w kompozycji z kanałem bliskiej podczerwieni. Widoczna jest diametralnie inna barwa korony.

Zdrowa roślinność silnie odbija promieniowanie w zakresie bliskiej podczerwieni (NIR) i pochłania promieniowanie w zakresie światła czerwonego, natomiast drzewa osłabione lub martwe wykazują wyraźnie odmienną sygnaturę spektralną. Dzięki temu możliwe jest identyfikowanie zagrożonych drzewostanów z wyprzedzeniem w stosunku do tradycyjnej inwentaryzacji terenowej, co daje szansę na szybszą reakcję i lepsze monitorowanie zmian zachodzących w lasach.



Różnice w odbiciu promieniowania przez igły sosny zdrowej i martwej – widoczny wyraźny wzrost odbicia w zakresie światła czerwonego (0,62-0,78μm) dla roślinności martwej, wykorzystywany w analizach teledetekcyjnych (Źródło: Geomatyka w Lasach Państwowych. Część I. Podstawy)

Ortofotomapa CIR została opracowana na podstawie zdjęć pozyskanych kamerą Leica DMC III, a następnie ograniczona przestrzennie do granic drzewostanów Nadleśnictwa Giżycko. Już na tym etapie system GIS odegrał istotną rolę. Konieczne było bowiem połączenie danych rastrowych z warstwami wektorowymi wydzieleni leśnych, kontrola zgodności układów współrzędnych, a także przygotowanie środowiska analitycznego umożliwiającego dalsze przetwarzanie.

Równolegle przygotowano wysokościowy model koron drzew (CHM, ang. Canopy Height Model), który posłużył do weryfikacji skuteczności modelu na późniejszym etapie prac. Powstał on poprzez odjęcie numerycznego modelu terenu od modelu pokrycia terenu wygenerowanego metodą automatycznego dopasowania zdjęć lotniczych. W efekcie uzyskano informację o względnej

wysokości obiektów ponad poziomem gruntu. Ten element okazał się kluczowy na późniejszym etapie filtrowania wyników.

Integracja ortofotomapy, modelu wysokościowego oraz warstw wektorowych w jednym środowisku GIS stworzyła fundament dla dalszych analiz. Bez tej spójności przestrzennej i kontroli jakości danych wejściowych nie byłoby możliwe wiarygodne wykorzystanie metod głębokiego uczenia.

Cyfrowe oko leśnika: Jak deep learning rozpoznaje martwe drzewa?

Głębokie uczenie jako element sztucznej inteligencji, która w swojej idei służy do automatyzacji ludzkiego procesu myślowego, jest obecnie jednym z najbardziej zaawansowanych narzędzi analizy obrazów, umożliwiając automatyczne wykrywanie złożonych wzorców, które są trudne do uchwycenia tradycyjnymi metodami. W przeciwieństwie do klasycznych podejść, w których człowiek musi sam zdefiniować cechy obiektów (np. kolor czy kształt), modele uczenia głębokiego w postaci tzw. sieci konwolucyjnych uczą się ich samodzielnie na podstawie dużych zbiorów danych. Dzięki temu są w stanie rozpoznawać subtelne różnice w strukturze koron drzew, ich barwie czy teksturze, co ma kluczowe znaczenie w identyfikacji drzew osłabionych i martwych. W kontekście leśnictwa oznacza to możliwość automatyzacji analiz, które dotychczas wymagały czasochłonnej pracy terenowej lub manualnej interpretacji zobrazowań.


Jednym z najważniejszych modeli wykorzystanych w tego typu analizach jest Mask R-CNN – zaawansowana architektura sieci neuronowej służąca do detekcji obiektów i ich segmentacji. W odróżnieniu od prostszych modeli, które jedynie wskazują lokalizację obiektu na obrazie, Mask R-CNN potrafi dokładnie wyznaczyć jego kształt, przypisując każdy piksel do konkretnej klasy. W praktyce oznacza to, że model nie tylko identyfikuje obecność martwego drzewa, ale również precyzyjnie odwzorowuje zasięg jego korony. Takie podejście znacząco zwiększa

dokładność analiz, szczególnie w warunkach leśnych, gdzie korony drzew często nachodzą na siebie, a ich granice są trudne do jednoznacznego określenia.

Natywne uczenie głębokie w ArcGIS Pro – praktyczna realizacja modelu

Cały proces tworzenia modelu został zrealizowany w środowisku ArcGIS Pro (z rozszerzeniem Image Analyst), które stanowiło centralne narzędzie integrujące zarówno przygotowanie danych, jak i trenowanie oraz wdrożenie modelu głębokiego uczenia. Prace rozpoczęły się od przygotowania danych wejściowych – do projektu zaimportowano ortofotomapę w kompozycji CIR oraz warstwy wektorowe wydzieleni leśnych, dbając o ich zgodność przestrzenną i układ współrzędnych.

Kolejnym etapem było przygotowanie danych treningowych, które stanowią fundament działania modeli predykcyjnych. Na podstawie ortofotomapy manualnie zdigitalizowano lokalizacje martwych drzew, tworząc warstwę wektorową punktów, a następnie – z wykorzystaniem narzędzi segmentacyjnych – wygenerowano poligony odpowiadające zasięgom ich koron. Na tej podstawie, przy użyciu narzędzia Export Training Data for Deep Learning, wygenerowano zestaw próbek treningowych w postaci kafelków rastrowych oraz odpowiadających im masek, które jednoznacznie wskazywały piksele należące do martwych drzew.




Maska binarna (po prawej) segmentu korony martwego drzewa (po lewej)

Następnie przystąpiono do właściwego etapu uczenia modelu, wykorzystując wbudowane w ArcGIS Pro narzędzie *Train Deep Learning Model*. W tym kroku skonfigurowano architekturę Mask R-CNN, określono parametry treningu (takie jak liczba epok, wielkość partii danych czy funkcje straty), a następnie przeprowadzono proces uczenia, podczas którego model iteracyjnie analizował dane i dostosowywał swoje wagi w celu jak najlepszego rozpoznawania martwych drzew. Po zakończeniu treningu uzyskano gotowy model zapisany w formacie zgodnym z ArcGIS.

Dzięki natywnej integracji z bibliotekami głębokiego uczenia, ArcGIS Pro umożliwił bezpośrednie wdrożenie architektury Mask R-CNN, co wyeliminowało konieczność korzystania z zewnętrznych skryptów i pozwoliło na pełną kontrolę nad procesem segmentacji koron martwych drzew.

W kolejnym kroku model został wykorzystany do detekcji obiektów na całej ortofotomapie za pomocą narzędzia *Detect Objects Using Deep Learning*. Wynikiem były poligony wskazujące potencjalne lokalizacje martwych drzew. Uzyskane rezultaty

poddano następnie analizie i filtracji – szczególnie z wykorzystaniem modelu wysokościowego koron drzew (CHM), co pozwoliło odrzucić obiekty niespełniające kryteriów wysokościowych i ograniczyć liczbę błędnych detekcji.



Fragment ortofotomapy z wykrytymi koronami martwych drzew

Skuteczny model to elastyczny model

Wyniki detekcji nie zostały przyjęte bezkrytycznie. Kolejnym etapem była analiza przestrzenna w środowisku GIS, mająca na celu redukcję fałszywych detekcji. Wykorzystując wysokościowy model koron, odrzucono obiekty o wysokości poniżej 8 metrów, które najczęściej stanowiły błędy klasyfikacji.

Dodatkowo przeanalizowano relacje przestrzenne z siecią dróg, aby uzyskać precyzyjne porównanie z obszarem testowym, dla którego nie posiadano modelu wysokościowego. Jasne powierzchnie odsłoniętego gruntu mogły być mylnie interpretowane jako martwe korony. Usunięcie obiektów

przecinających się z warstwą dróg znacząco poprawiło jakość wyników.

Osiągnięty wynik F1-score na poziomie 0,77 wskazał na wysoką skuteczność detekcji, szczególnie biorąc pod uwagę złożoność tła leśnego. W praktyce oznacza to, że model w większości przypadków poprawnie wskazywał martwe drzewa i jednocześnie stosunkowo rzadko „mylił się”, oznaczając jako martwe te, które w rzeczywistości były zdrowe – im bliżej jedynki jest wartość F1, tym lepiej algorytm radzi sobie z takim wyważeniem trafień i pomyłek.

Model został następnie przetestowany na niezależnym obszarze znajdującym się w Nadleśnictwie Krynki. Proces ten przeprowadzono w celu sprawdzenia możliwości aplikacyjnej algorytmu oraz uniwersalności opracowanego rozwiązania. W tym celu gotowy plik definicji modelu, opracowany w kroku *Train Deep Learning Model* wykorzystano jako *Pre-trained model*, wcześniej dorysowując po 10 segmentów. Porównano to z zastosowaniem modelu bez dotrenowania na obszarze testowym. Wartość współczynnika F1 wzrosła z 0,31 do 0,74 znacząco zbliżając się do pierwotnej wersji modelu.

Polski debiut w ArcGIS Living Atlas: Pierwszy taki model w światowych zasobach

Plik z wytrenowanym modelem w formacie .dlpk został udostępniony w zasobach ArcGIS Living Atlas of the World stając się pierwszym modelem głębokiego uczenia z Polski dostępnym na tej platformie. Jednak zanim to nastąpiło konieczne było przejście formalnych procedur, w których pliki dodawane do zasobów są oceniane w skali 0-100. Wśród elementów oceny znalazły się informacje dotyczące profilu właściciela – konieczne było dodanie zdjęcia profilowego, notki biograficznej oraz zmiana widoczności profilu na publiczny.

Pod uwagę brane było również określenie warunków użytkowania oraz źródła lub podziękowania dla organizacji. Plik modelu musiał być widoczny publicznie oraz zabezpieczony przed przypadkowym usunięciem. Jednak najważniejszym elementem był tutaj dokładny opis, w którym zostały zawarte szczegółowe informacje o zastosowaniu, danych wykorzystanych do trenowania oraz wynikach oceny dokładności. Następnie model został poddany formalnej weryfikacji przez specjalistów zajmujących się sztuczną inteligencją i teledetekcją w firmie Esri Inc. Proces ten trwał około 4 tygodni. Pozytywny wynik został przekazany drogą mailową. Model dostępny jest pod tym linkiem.

Dzięki takiemu udostępnieniu model może być łatwo wykorzystywany przez użytkowników Esri, w szczególności przez jednostki zajmujące się prowadzeniem gospodarki leśnej – Biuro Urządzania Lasu i Geodezji Leśnej oraz Lasy Państwowe.



Widok okna Esri Living Atlas of the World z udostępnionym modelem do wykrywania koron martwych drzew

Potencjalne zastosowania obejmują monitoring szkód, planowanie cięć sanitarnych, ocenę ryzyka pożarowego czy wsparcie inwentaryzacji terenowej. Automatyczna detekcja nie eliminuje potrzeby kontroli w terenie, ale pozwala znacząco zawęzić obszar poszukiwań i skoncentrować zasoby tam, gdzie są rzeczywiście potrzebne.

W obliczu dynamicznych zmian klimatycznych i rosnących wymagań raportowych wobec sektora leśnego, integracja danych lotniczych, GIS i sztucznej inteligencji przestaje być

eksperymentem badawczym. Staje się elementem nowoczesnego zarządzania przestrzenią.

Technologia jako wsparcie decyzji

Realizacja tej pracy inżynierskiej pokazuje, że GIS nie jest wyłącznie narzędziem mapowym. Jest platformą integrującą dane rastrowe i wektorowe, modele wysokościowe, algorytmy uczenia maszynowego oraz analizy przestrzenne. To środowisko, w którym dane przestają być jedynie obrazem, a stają się informacją wspierającą decyzje.

W dobie cyfrowej transformacji leśnictwa szczególnego znaczenia nabiera umiejętność łączenia kompetencji przyrodniczych z technologicznymi. Wiedza o ekologii gatunku, jego wymaganiach siedliskowych i dynamice zamierania musi iść w parze z umiejętnością pracy na dużych zbiorach danych i wykorzystania narzędzi analitycznych.

Algorytm nie zastępuje leśnika. Może jednak stać się jego wsparciem – cyfrowym asystentem, który przegląda tysiące hektarów w czasie, w którym człowiek byłby w stanie ocenić jedynie fragment takiego obszaru.