

# Wstępnie wytrenowane modele Deep Learning w bibliotece ArcGIS Living Atlas

Biblioteka wstępnie wytrenowanych modeli Deep Learning (głębokiego uczenia) w ArcGIS Living Atlas znów się powiększyła! Bez konieczności posiadania ogromnych ilości danych szkoleniowych, zasobów obliczeniowych i rozległej wiedzy na temat sztucznej inteligencji (AI), użytkownicy mogą wykorzystywać wstępnie wytrenowane modele, aby przyspieszyć przepływy pracy związane z analizą danych geoprzestrzennych i wydobywać cenne informacje ze zdjęć.

Od września 2022 r. użytkownicy ArcGIS Living Atlas mogą wybierać spośród 43 wstępnie wytrenowanych modeli, dostępnych jako pakiety głębokiego uczenia (DLPK), których można używać z aplikacjami ArcGIS Pro, Image Server i ArcGIS API for Python.

Oto przegląd najciekawszych rozwiązań z ich użyciem:

## **Wyodrębnianie obszarów zbiorników wodnych**

Działania związane z gospodarką wodną, takie jak monitorowanie zmieniającego się biegu rzek i strumieni, czy zarządzanie przeciwpowodziowe, wymagają badań i planowania – w tym dokładnego mapowania zbiorników wodnych. Stąd wyodrębnianie powierzchni zbiorników wodnych z danych teledetekcyjnych jest kluczowe, by zarejestrować, jak wygląda dynamika zmian na przestrzeni czasu. Ten model głębokiego uczenia może być wykorzystany do zautomatyzowania zadania ekstrakcji

powierzchni zbiorników wodnych z obrazów radarowych SAR.

### **Pozyskiwanie obrysów budynków**

Digitalizacja obrysów budynków na podstawie zdjęć jest zadaniem czasochłonnym i często polega na ręcznym wyodrębnianiu obiektów. Przygotowany model głębokiego uczenia pozwala zautomatyzować ten proces, skracając czas potrzebny do pozyskania śladów budynków ze zdjęć o wysokiej rozdzielczości (15–25 cm).

### **Lokalizowanie drzew**

Wykrywanie drzew na zdjęciach może znaleźć zastosowanie w takich obszarach, jak zarządzanie roślinnością, leśnictwo, planowanie urbanistyczne itp. Ten model głębokiego uczenia jest używany do wykrywania drzew na zdjęciach z drona lub lotniczych o wysokiej rozdzielczości.

### **Analiza kolonii ptaków morskich**

Rybitwa królewska i rybitwa kaspijska to tylko dwa z ok. 350 gatunków ptaków morskich. Dorosłe rybitwy mogą mieć rozmiar 45-60 cm i ważyć 350-750 g. Ich wymiary stawiają je w kategorii małych obiektów, dlatego aby je wykryć, potrzeba zdjęć o bardzo wysokiej rozdzielczości. Ten model głębokiego uczenia pomaga zautomatyzować zadanie wykrywania ptaków morskich (rybitwy królewskiej i kaspijskiej) na podstawie zdjęć lotniczych o wysokiej rozdzielczości, aby pomóc w skutecznym mapowaniu obszarów ochrony ptaków morskich.

## **Lokalizowanie słońi**

Słonie to największy żyjący obecnie ssak lądowy, z wielu powodów zagrożony wyginięciem. Aby je chronić, bardzo ważne jest monitorowanie tego, gdzie się znajdują. Ten model głębokiego uczenia pomaga zautomatyzować lokalizowanie słońi na podstawie zdjęć lotniczych o wysokiej rozdzielczości.

## **Klasyfikacja pokrycia terenu**

Klasyfikacja pokrycia terenu jest zadaniem złożonym i trudnym do uchwycenia przy użyciu tradycyjnych środków. Dzięki przygotowanemu modelowi głębokiego uczenia się można zautomatyzować proces ręczny i znacznie skrócić potrzebny na jego realizację.

## **Pozyskiwanie danych na temat działania parku fotowoltaicznego**

Słońce dostarcza czystej energii. Aby zastąpić jej konwencjonalne źródła, należy skalować wytwarzanie energii słonecznej, co odbywa się poprzez tworzenie dużych farm fotowoltaicznych. Tradycyjne sposoby uzyskiwania informacji na temat tych farm są czasochłonne i podatne na błędy. Dzięki temu modelowi głębokiego uczenia się można zautomatyzować cały proces, a tym samym skrócić czas i zmniejszyć wysiłek wymagany do pozyskania informacji.

## **Przypisywanie adresów do konkretnych państw**

Dokładna lokalizacja osób lub interesujących miejsc jest ważna

dla prowadzenia działalności gospodarczej i usprawnienia usług administracji publicznej. Aby uzyskać dokładną lokalizację, konieczne jest prawidłowe geokodowanie adresów. Ten model głębokiego uczenia może być używany do klasyfikowania adresów do odpowiednich krajów. Kategoryzuje niekompletne adresy poprzez automatyczne przypisanie kraju, z którego pochodzą.

## **Rozpoznawanie wybranych jednostek**

Ten model głębokiego uczenia służy do identyfikacji lub kategoryzacji wybranych jednostek na podstawie tekstu. Dana jednostka może odnosić się do słowa lub sekwencji słów, takich jak nazwa organizacji, osoby, kraju, daty lub czasu w tekście. Ten wstępnie wytrenowany model wykrywa takie jednostki w tekście i przypisuje je do wcześniej ustalonej kategorii.

## **Generowanie maski chmur**

Satelitarne czujniki teledetekcyjne często napotykają zachmurzenie, przez co nie zbierają „czystych” obrazów Ziemi. Zachmurzone regiony powinny zostać wykluczone z analizy lub należy zastosować algorytmy usuwania chmur zanim obraz będzie mógł być użyty do analizy. Model ten może być wykorzystany do automatycznego generowania maski chmur z obrazów, dzieląc ich pokrywę na trzy klasy o różnej gęstości.

## **Standaryzacja adresów**

Wstępnie przeszkolony model standaryzacji adresów służy do przekształcania niepoprawnych i niestandardowych adresów w adresy standardowe. Ten model uczenia głębokiego został

przygotowany na zbiorze danych adresowych dostarczonym przez [openaddresses.io](https://openaddresses.io) i może być używany do standaryzacji adresów z 10 krajów.

Aby uzyskać dostęp do tych oraz wielu innych wstępnie wytrenowanych modeli głębokiego uczenia się odwiedź [ArcGIS Living Atlas](#) i wyszukaj „dlpk packages”. Każdy model zawiera pomocną dokumentację ułatwiającą rozpoczęcie pracy.