

Narzędzia deep learning w systemie Esri ArcGIS




Analizy na sterydach

Pokutuje wciąż przekonanie, że wykorzystanie sztucznej inteligencji w przetwarzaniu danych przestrzennych to domena naukowców lub wysokiej klasy specjalistów. Tymczasem narzędzia te stały się proste w obsłudze i dostępne w popularnych aplikacjach „z półki”.

Michał Domański

Systemy informacji geograficznej (GIS) są obecne w wielu aspektach naszego codziennego życia, nawet wtedy, kiedy sobie tego nie uświadamiamy. Używając w smartfonie nawigacji w drodze do sklepu czy sprawdzając, gdzie w najbliższej okolicy można zjeść coś dobrego, często uruchamiamy „zaszytą” w aplikacji funkcję przeszukującą olbrzymią bazę danych (w tym przestrzennych) i po chwili otrzymujemy odpowiedź. Nierzadko sami zasilamy zwrotnie taką bazę, dzieląc się choćby swoją lokalizacją czy informacją o prędkości przemieszczania się. Dane zbierane od klientów przez sieci handlowe (np. częste pytanie przy kasie o kod pocztowy) służą między innymi do zbadania zasięgu danej placówki handlowej, czyli do wykonania analizy przestrzennej.

Dane stanowią zatem – oprócz oprogramowania, personelu i procedur przetwarzania – podstawowy element tworzący system informacji geograficznej. Można nawet zaryzykować twierdzenie, że to komponent najważniejszy, bo bez niego GIS staje się przecież bezużyteczny. Wybór optymalnych metod gromadzenia danych jest zatem szczególnie istotny. W artykule tym chciałbym skupić się na przeznaczonych do tego narzędziach, które pojawiły się stosunkowo niedawno – przynajmniej w porównaniu z innymi, stosowanymi od dziesięcioleci. Chodzi o rozwiązania, które do identyfikacji obiektów czy analizowania danych statystycznych wykorzystują sztuczną inteligencję (*artificial intelligence* – AI), a dokładniej złożone sieci neuronowe, czyli technologię *deep learning* (DL). I choć ona sama, a przynajmniej jej założenia nie są nowością, to rozwój narzę-



Rys. 1. Przykłady zastosowań wstępnie wytrenowanych modeli DL udostępnionych przez Esri

dzi wykorzystujących DL dostępnych dla „zwykłego użytkownika” systemów GIS jest zjawiskiem względnie nowym. Do jego upowszechnienia przyczynił się nie tylko rozwój oprogramowania, ale również dynamiczny wzrost możliwości obliczeniowych współczesnych komputerów.

• Moc zastosowań

Firma Esri już dawno dostrzegła olbrzymi potencjał technologii *deep learning* i dzięki temu narzędzia wykorzystujące AI można znaleźć w wielu modułach

systemu ArcGIS, poczynając od rozwiązania desktopowego ArcGIS Pro z rozszerzeniem ArcGIS Image Analyst, poprzez środowisko serwerowe ArcGIS Enterprise z ArcGIS Image Server, aż po portal „chmurowy” ArcGIS Online z ArcGIS Image for ArcGIS Online. Narzędzia dostępne we wspomnianych aplikacjach pozwalają m.in. na różnorodne analizy obrazowe, badanie danych statystycznych, automatyczne tworzenie nowych warstw tematycznych czy zasilanie tabel atrybutów na podstawie informacji zidentyfiko-

Źródło: opracowanie własne

wanych w analizowanych tekstach. Co ważne, sztuczna inteligencja nie stanowi w rozwiązaniach Esri osobnego produktu, ale jest rozproszona i występuje w różnych komponentach tego systemu.

Wiele spośród zastosowań modeli DL dotyczy pracy z danymi obrazowymi: wykrywania i identyfikowania obiektów, wykonywania klasyfikacji treści zobrazowań, tworzenia map pokrycia terenu czy analizowania zmian zachodzących na badanych obszarach (rys. 1). Druga grupa to przewidywanie i prognozowanie występowania różnych zjawisk na podstawie zbieranych danych wektorowych lub sygnałów pochodzących z różnorodnych sensorów. Należy tu zaliczyć między innymi narzędzia służące do przewidywania wystąpienia awarii sieci przesyłowych, monitorowania i predykcji stopnia zanieczyszczenia powietrza czy analizowania natężenia ruchu drogowego i przeciwdziałania powstawaniu zatorów komunikacyjnych. Ostatnia grupa to różnorodne analizy na zbiorach danych statystycznych: wykrywanie trendów lub anomalii, poszukiwanie wzorców zachowań i skupisk zjawisk znaczących statystycznie (np. natychmiastowe identyfikowanie pochodzących z ograniczonych obszarów połączeń z systemami alarmowymi czy śledzenie ognisk zakażeń).

• Trzy kroki do sprawnych analiz

Bez względu na to, do czego chcemy wykorzystać sztuczną inteligencję, ścieżka postępowania jest podobna. Przedstawię ją na przykładzie narzędzi Esri przeznaczonych do pracy z danymi rastrowymi. Pierwszym etapem jest przygotowanie zestawu danych przykładowych, tzw. etykiet (*labels*). To przykłady obiektów, które chcemy identyfikować na obrazach. Procedura ich tworzenia w ArcGIS Pro ogranicza się do zdefiniowania „schematu klasyfikacji”, czyli zestawu nazw klas/obiektów, które chcemy identyfikować, wskazania przykładowych obiektów (np. poprzez ich oznaczenie na ortofotomapie lub wykorzystanie do tego danych zapisanych wcześniej w warstwie wektorowej), a następnie do wyeksportowania zestawu danych służących do wytrenowania modelu. Ten ostatni krok to automatyczna procedura, która generuje zrozumiałe dla systemu zestaw „kafelków” obrazowych wraz z informacjami towarzyszącymi (tzw. *image chips*). Umożliwia on zidentyfikowanie cech wyróżniających interesujące użytkownika obiekty w kolejnym etapie procesu.

A jest nim trenowanie modelu DL – proces długotrwały, ale nieangażujący nadmiernie użytkownika. Jego rola



Rys. 2. Efekt działania modeli DL przeznaczonych do wykrywania obrysów budynków (fioletowe) oraz samochodów (wiśniowe). Warto zwrócić uwagę na samochody częściowo zasłonięte przez korony drzew, a mimo wszystko poprawnie zidentyfikowane (prawy dolny róg obrazu)

sprowadza się właściwie do wyboru typu modelu, który zostanie wykorzystany do wytrenowania. Obecnie istnieje 18 typów modeli i służą one np. do: wykrywania obiektów, klasyfikacji obiektów, klasyfikacji pikseli obrazu czy dopasowywania i opisywania obrazów (więcej informacji wraz z opisami dostępnych modeli można znaleźć na stronie pro.arcgis.com). Po wyborze typu modelu, bazując na przygotowanym wcześniej zestawie danych, realizuje się zaawansowany obliczeniowo proces, którego wynikiem jest wytrenowany model *deep learning* wraz z raportem o przebiegu procesu trenowania oraz spodziewanej dokładności otrzymanych wyników.

Ostatni etap pracy to stosowanie wytrenowanych modeli DL. Niepodważalną zaletą tej technologii jest możliwość wykorzystywania raz wytrenowanych modeli na wielu innych zestawach da-

nych, podobnych do tych, na bazie których przeprowadzono wcześniej proces trenowania. Oczywiście, jak w przypadku każdego procesu automatycznego, trudno spodziewać się 100% skuteczności, ale już osiągnięcie więcej niż 90% jest jak najbardziej możliwe. Ponadto jeżeli okaże się, że wyniki uzyskiwane po uruchomieniu modelu na jakimś zestawie obrazów nie są w pełni satysfakcjonujące, możliwe jest „dotrenowanie” modelu do konkretnych obrazów. Taki proces wymaga przygotowania pewnej liczby etykiet, ale może ona być znacząco mniejsza niż podczas wstępnego trenowania modelu.

• Z Esri jeszcze prościej

Przeglądając się opisanemu powyżej schematowi działania, nietrudno stwierdzić, że dwa pierwsze etapy procesu są tymi, które wymagają największego zaangażowania użytkownika. Zwłaszcza-



Rys. 3. Efekt działania modeli DL przeznaczonych do wykrywania paneli fotowoltaicznych (pomarańczowe) i samochodów (wiśniowe)



Opracowanie autora

Rys. 4. Efekt działania modeli DL przeznaczonych do wykrywania obrysów budynków (fioletowe), samochodów (wiśniowe) oraz obiektów liniowych (błękitne)

cza że poprawne wytrenowanie modelu DL wymaga zasilenia go bardzo dużą liczbą danych przykładowych (etykiet). Zdając sobie z tego sprawę, firma Esri rozpoczęła proces tworzenia i udostępniania swoim użytkownikom wstępnie wytrenowanych modeli *deep learning*, które pozwalają na przeprowadzenie określonych operacji. Obecnie umożliwiają one m.in.: identyfikację i tworzenie obrysów budynków (rys. 2), identyfikację pojazdów, paneli fotowoltaicznych (rys. 3) oraz odkrytych basenów na wysokorozdzielczych ortofotomapach lotniczych, wykrywanie typów pokrycia terenu i generowanie map pokrycia terenu na podstawie obrazów satelitarnych Landsat-8 i Sentinel-2, a także pozyskiwanie obiektów liniowych (np. siatki dróg – rys. 4) na zobrazeniach o terenowej wielkości piksela ok. 50 cm. Narzędzia te pozwalają również gromadzić dane atrybutowe. Przykładowo: dysponując poligonową warstwą działek oraz orto-

fotomapą lotniczą określonego obszaru, mamy możliwość automatycznego pozyskania wartości atrybutów opisowych mówiących o obiektach znajdujących się w obrębie poszczególnych nieruchomości (obecność zabudowy, basenów czy paneli fotowoltaicznych).

Warto również wspomnieć o modelach wytrenowanych do pozyskiwania danych na podstawie przetwarzania chmury punktów ze skanowania laserowego. Dostępne obecnie narzędzia pozwalają na klasyfikację punktów reprezentujących drzewa (rys. 5) oraz linie przesyłowe i słupy energetyczne.

Zbiór udostępnianych przez Esri wstępnie wytrenowanych modeli DL będzie systematycznie powiększany i udostępniany bezpłatnie na portalu ArcGIS Living Atlas of the World (livingatlas.arcgis.com). Aby je znaleźć, wystarczy wpisać hasło „*deep learning*” w pasku wyszukiwania. Oczywiście takie wstępnie wytrenowane modele DL również

można dotrenować, jeżeli uzyskiwane wyniki nie spełniają naszych wymagań.

Cały proces przetwarzania obrazów z wykorzystaniem technologii *deep learning* – poczynając od gromadzenia danych przykładowych, poprzez trenowanie modeli, a kończąc na ich wykorzystywaniu – jest obsługiwany z poziomu Skrzynki Narzędziowych (*Toolbox*) w ArcGIS Pro. Możliwa jest również praca z tymi narzędziami w środowisku serwerowym ArcGIS Enterprise (z ArcGIS Image Server) oraz uruchamianie ich z poziomu Python API. Rozwiązanie chmurowe ArcGIS Image for ArcGIS Online umożliwia dziś wyłącznie stosowanie wytrenowanych wcześniej modeli DL – trenowanie nie jest jeszcze dostępne w tej usłudze.


● To dopiero początek

Narzędzia wykorzystujące technologię *deep learning* to obecnie mocno rozwijana część systemu ArcGIS. Stwarzają one użytkownikom warunki do jeszcze większej automatyzacji i przyspieszenia procesów związanych na przykład z identyfikacją obiektów czy pozyskiwaniem określonych informacji na podstawie zobrażeń. Uniwersalność i możliwość wielokrotnego wykorzystania wytrenowanych modeli DL na różnych zbiorach danych sprawia, że w najbliższej przyszłości można się spodziewać prawdziwej eksplozji liczby użytkowników tej technologii, a dostępność coraz większej liczby wstępnie wytrenowanych modeli gotowych do wykorzystania „po kilku kliknięciach” z pewnością będzie temu sprzyjać.

Michał Domański

business development manager
ds. teledetekcji i fotogrametrii

w Dziale Technicznego Wsparcia Sprzedaży
firmy Esri Polska



Źródło: Esri Inc.

Rys. 5. Punkty na drzewach zidentyfikowane przez wytrenowany wstępnie model DL