

Z góry widać więcej – jak AI pozwala analizować parkowanie pojazdów

Wyzwania współczesnego parkowania

Każdy, kto próbował znaleźć miejsce parkingowe w zatłoczonym mieście, w godzinach szczytu wie, że jest to doświadczenie wymagające niemałej dawki czasu i cierpliwości. Niedobór miejsc parkingowych to problem, z którym zmagają się niemal wszyscy kierowcy poruszający się po centrach dużych ośrodków miejskich. W miarę rozwoju aglomeracji wzrasta także liczba samochodów, a metody planowania przestrzennego wykorzystywane do tej pory takie jak: modelowanie 3D, inteligentne miasto (*ang. smart city*), okazują się być niewystarczające. Wysokie koszty wykorzystywanych oprogramowań i aplikacji oraz duże zapotrzebowanie na specjalistów powodują, że nie wszystkie miasta mogą pozwolić sobie na efektywne wykorzystywanie takich rozwiązań. To powoduje, że władze miast nie są w stanie skutecznie sprostać potrzebom mieszkańców, a wyzwania, jak zbyt ciasne miejsca parkingowe lub za mała ich ilość, stają się codziennością kierowców i prowadzą do rozwoju utrudnień w postaci nieprawidłowego parkowania, co przedstawiono na rys. 1.

Sztuczna inteligencja i ortofotomapy w urbanistyce

W odpowiedzi na powyższe problemy, urbanistyka sięga po nowoczesne technologie, coraz częściej wykorzystując algorytmy sztucznej inteligencji (*ang. Artificial Intelligence*) oraz metody głębokich sieci neuronowych (*ang. Deep Learning*) w procesie planowania przestrzeni. Dzięki detekcji obiektów tzn.

wykrywaniu na podstawie cech, AI potrafi z dużą dokładnością identyfikować i klasyfikować elementy miejskiego krajobrazu (budynki, samochody, drzewa), bazując na ortofotomapach, czyli rastrowych obrazach powierzchni terenu powstałych w wyniku przetworzenia zdjęć lotniczych lub satelitarnych. W artykule przyjrzymy się, jak widok z lotu ptaka w połączeniu z inteligentnymi algorytmami może realnie wpłynąć na poprawę jakości życia w mieście oraz omówimy badanie, w którym podjęto próbę zlokalizowania samochodów na fotografii lotniczej, obejmującej Śródmieście Szczecina.

Dzięki wykorzystaniu narzędzi w programie ArcGIS Pro takich jak: „Wykrywaj obiekty metodą Deep Learning (*ang. Detect Objects Using Deep Learning*)” i „Wybierz według położenia (*ang. Select Layer By Location*)” możliwe stało się określenie usytuowania pojazdów i podziału ich na zaparkowane prawidłowo oraz na te, które utrudniały ruch drogowy. Analiza rezultatów w przyszłości mogłaby ułatwić kontrolę przestrzegania zasad ruchu drogowego, pomóc kierowcom w łatwym znajdowaniu miejsc parkingowych oraz pozytywnie wpłynąć na komfort poruszania się po mieście.



Rysunek 1 Przykład sytuacji, o której mowa w artykule (Źródło)

Studium przypadku – analiza parkowania w centrum Szczecina

Do przeprowadzenia badania wykorzystano ortofotomapę wybranego obszaru Szczecina – Śródmieścia, udostępnioną w formacie rastrowym. Mapa przedstawiała rzut lotniczy terenu w jego naturalnych barwach, co pozwoliło na łatwiejszą identyfikację obiektów tj. drogi, tereny zielone oraz istniejące miejsca parkingowe – parkingi naziemne, zatoki czy przestrzenie międzyblokowe. Przez wzgląd na duże zagęszczenie zabudowy, wzmożony ruch miejski oraz niski stosunek liczby miejsc parkingowych do liczby pojazdów, Śródmieście Szczecina (rys.2) okazało się być idealną dzielnicą do przeprowadzenia obserwacji. Dzięki ograniczeniu zakresu przestrzennego czas obliczeń został znacznie skrócony, a także możliwe stało się skupienie na tych fragmentach miasta, w których badany problem jest najbardziej dotkliwy dla mieszkańców.



Rysunek 2 Ortofotomapa Śródmieścia Szczecina oraz pogląd miasta z badany obszarem tle województwa


Kolejny etap stanowiła implementacja wektorowych danych, takich jak budynki, drogi oraz miejsca parkingowe ze strony

geofabrik (link do danych). W trakcie pracy okazało się, że import stref przedstawiających parkingi jest nieaktualny i wymagał uzupełnienia manualnego bazy danych, czyli własnoręcznego zwektoryzowania obiektów na podstawie rastra. Gdy badany fragment miasta został zaktualizowany, całość została poddana narzędziu „Wykrywaj obiekty metodą Deep Learning” wykorzystując przy tym gotowy model Car Detection – USA. Dzięki ekstrakcji cech następuje warstwowe przetwarzanie obrazu. Pierwsze warstwy wykrywają proste cechy (linie, krawędzie, kolory), kolejne warstwy rozpoznają bardziej zaawansowane szczegóły samochodu np. maskę, a ostateczne całe pojazdy. Obraz dzielony jest na siatkę i każda kratka analizowana jest pod kątem obecności obiektu. Jeśli obiekt został wykryty, oznaczany jest kwadratem, który określa jego pozycję i rozmiar. Taki proces spowodował, że na mapie pojawiła się warstwa z zaznaczonymi pojazdami czterokołowymi co zaprezentowano na rys.3. Następnie w programie wyselekcjonowano tylko te samochody, które w trakcie wykonywania fotografii lotniczej były w trakcie postoju, włączono zaś wszystkie te, które poruszały się po jezdni.



Rysunek 3 Pogląd działania detekcji narzędzia Deep Learning
Wykonane czynności złożyły się na finalny efekt badania, którego celem było przyjrzenie się wszystkim samochodom w


trakcie postępu obecnym na fotografii lotniczej, obejmującej konkretny fragment Szczecina – Śródmieście. Na rys. 4 przedstawiono fragment końcowego etapu realizacji badań.



Rysunek 4 Fragment końcowego etapu realizacji badania

Wyniki i obserwacje

Ostatnim elementem badania była analiza otrzymanych wyników. Wykryto łącznie 5453 elementy.auta w przestrzeni miejskiej stanowiły liczbę 2506 wykrytych obiektów, z czego samochodów zaparkowanych na miejscach parkingowych było 2402, natomiast 104 pojazdy stały w obszarach utrudniających ruch miejski. Pozostałe 2947 zidentyfikowanych egzemplarzy, to pojazdy stojące na prywatnych posesjach, wjazdach oraz ulicach i zostały wykluczone z badania. Porównanie położenia aut w przestrzeni miejskiej przedstawiono na rys. 5.



Rysunek 5 Porównanie położenia aut w przestrzeni miejskiej

Analiza przestrzenna rastra z zaznaczonymi obiektami wykazała, że zdecydowana większość samochodów była zaparkowana poprawnie. Zbiór aut zaparkowanych w nieodpowiednich strefach odnosi się m.in. do:

- Parkowania na chodnikach – w kilku lokalizacjach pojazdy były zaparkowane częściowo lub całościowo na chodnikach, co stanowi znaczne utrudnienie ruchu pieszych oraz narusza przepisy drogowe.




 Prawidłowo
zaparkowane pojazdy

 Niepoprawnie
zaparkowane pojazdy


Rysunek 6 Przykład błędnie zaparkowanego pojazdu

- Zajmowania miejsc niedozwolonych – znaleziono auta zaparkowane w lokalizacjach takich, jak strefy wyłączone z ruchu czy miejsca przeznaczone dla służb ratunkowych, co może prowadzić do powstawania sytuacji niebezpiecznych.



Rysunek 7 Przykład błędnie zaparkowanego pojazdu

- Nieprzestrzeganie oznakowania poziomego – część pojazdów była zaparkowana poza wyznaczonymi liniami parkingowymi, co może przyczyniać się do zmniejszenia efektywności wykorzystania przestrzeni parkingowej oraz utrudniania parkowania innym pojazdom.



Rysunek 8 Przykład błędnie zaparkowanego pojazdu

Wykrywalność pojazdów na ortofotomapach poprzez użycie detekcji obiektów za pomocą Deep Learning'u jest efektywnym i praktycznym rozwiązaniem. Wykorzystana metoda pozwala na zaznaczenie 90% widocznych samochodów, co dowodzi wysokiej skuteczności podejścia.

W kontekście analizy przestrzeni miejskiej, wykryte pojazdy można kolejno przyporządkować do kategorii- zaparkowane na parkingach, poruszające się po ulicach lub poza zidentyfikowanymi obszarami. Takie grupowanie wspiera analizę natężenia ruchu i identyfikację tzw. „dzikiego parkowania”.

AI a przyszłość parkowania w miastach

Na podstawie przeprowadzonego badania można rozważyć wiele potencjalnych zastosowań dla udziału Sztucznej Inteligencji w rozplanowywaniu bezpiecznego parkowania przez kierowców, a także tworzeniu lepszych, większych i bardziej przestrzennych parkingów w celu wyeliminowania parkowania w miejscach, które nie są do tego przeznaczone.

AI umożliwia wykrywanie samochodów na ortofotomapach, umożliwiając tworzenie bieżących map zapełniania miejsc postojowych. Pozwala na urbanistyczną i planistyczną analizę ruchu drogowego, co może ułatwić identyfikację najczęściej zapełnionych ulic, a także może np. poprzez aplikację monitorować, czy w danym czasie na danym parkingu występują wolne miejsca postojowe.

Jak widać, Sztuczna Inteligencja w miarę postępu technologii może znaleźć ogrom zastosowań w usprawnianiu parkowania w dużych, zatłoczonych miastach. Detekcja AI daje szeroki pogląd sytuacji przestrzennej i pozwala na precyzyjne sterowanie i zarządzanie zasobami parkingowymi. W przyszłości może być narzędziem przydatnym nie tylko dla planistów miejskich czy operatorów parkingów, ale dzięki inteligentnym

systemom miejskim może przysłużyć się przede wszystkim kierowcom, którzy z powodu braku miejsc nie będą zmuszeni do tzw. „dzikiego parkowania”.

ArcGIS Living of the World

Zainteresował Cię artykuł i chciałbyś skorzystać z gotowych modeli Deep Learning?

Najpopularniejsze z nich to m.in.:

- **wykrywanie budynków** na zobrazowaniach,
- **klasyfikacja pokrycia terenu** na zdjęciach satelitarnych,
- **wykrywanie dróg** oraz klasyfikacja innych danych niż rastrowe, np. **chmur punktów**.

Wejdź na stronę: livingatlas.arcgis.com w zakładce „Browse” wpisz „deep learning” i odkryj ponad **100 gotowych modeli**.

