

MLAdapt - Self-Adapting Machine Learning

W niedalekiej przyszłości ludzkość wysła zaawansowanego robota-odkrywcę, pieszczośliwie nazywanego "Łazikiem", na przełomową misję mającą na celu odkrycie tajemnic Marsa. Wyposażony w najnowocześniejsze systemy wizualne, Łazik wyrusza w podróż, mając za zadanie zebrać kluczowe dane na temat marsjańskiej geologii, klimatu i potencjału przeszłego lub obecnego życia. Jednak gdy Łazik napotyka trudne i nieprzewidywalne warunki marsjańskiego krajobrazu, pojawiają się nieoczekiwane wyzwania, które powodują niepowodzenie misji. Burze piaskowe, ekstremalne wahania temperatury i skaliste tereny odbijają się na systemach wizualnych Łazika, utrudniając mu nawigację i realizację celów misji. To niepowodzenie rodzi pytania dotyczące zdolności adaptacji naszej technologii do nieprzewidywalnej natury eksploracji pozaziemskiej.

W odpowiedzi na to wyzwanie, naukowcy i inżynierowie na Ziemi postanawiają wyposażyć Łazika w przełomową aktualizację - samoadaptujące się algorytmy uczenia maszynowego. Algorytmy te, zaprojektowane do ciągłego uczenia się i ewolucji, są zintegrowane z systemami wizualnymi Łazika. Robot staje się dynamicznym uczniem, analizując i dostosowując się do stale zmieniających się warunków marsjańskich. Podczas przemierzania marsjańskiego terenu, samodostosowujące się algorytmy pozwalają Łazikowi szybko reagować na nieoczekiwane wyzwania. Łazik uczy się rozpoznawać i omijać przeszkody, dostosowywać parametry wizualne do zmiennych warunków oświetleniowych, a nawet przewidywać potencjalne problemy na podstawie wcześniejszych doświadczeń.

Chociaż historia ta przedstawia odległą przyszłość, pokazuje potencjał transformacji samoadaptujących się modeli uczenia maszynowego. Jest to przeciwieństwo obecnych algorytmów charakteryzujących się stałymi zestawami danych i cyklicznym powtórny trenowaniem modelu. Pozwalając modelowi na dostosowanie się po pierwotnym uczeniu, może on wykorzystać informacje dostępne podczas jego użytkowania w celu poprawy swoich możliwości, podobnie jak ma to miejsce w przypadku uczenia się ludzi. Taka technologia może być wykorzystywana w wielu dziedzinach, takich jak asystenci głosowi, systemy medyczne itp.

Znaczenie projektu. Obecne podejścia do głębokiego uczenia zakładają podobieństwo danych treningowych do danych, które model przetwarza po wdrożeniu. Jednak wydajność znacznie spada w obliczu odmiennych rozkładów danych lub domen, co ogranicza możliwości zastosowań w praktyce.

Przygotowanie modeli dla scenariusza aplikacji w otwartym świecie jest prawie niemożliwe ze względu na różnorodność i niekontrolowane środowiska. Wymagałoby to ogromnych lub nieskończonych, zróżnicowanych zbiorów danych do uczenia, co prowadzi do wysokich kosztów etykietowania danych i wymaganych zasobów obliczeniowych. Dodatkowo, wykorzystanie nowo pozyskanych danych często wymaga całkowitego powtórnego uczenia modelu, co zwiększa koszty i potrzeby obliczeniowe, podkreślając lukę między sztuczną a ludzką inteligencją.

Cel projektu. Celem projektu jest rozwiązanie powyższych problemów w trybie online po pierwotnym uczeniu i wdrożeniu sieci neuronowej. To podejście zminimalizuje niedogodności związane z początkowym uczeniem, a jednocześnie zwiększy poziom inteligencji sieci, zmniejszając przepaść między ludzką a sztuczną inteligencją. Wykorzystując nieograniczone, nieoznakowane strumienie danych, aby nie tylko generować prognozy, dążymy do adaptacji i ciągłego zdobywania wiedzy, dzięki czemu sieć będzie dokładniejsza. Użyjemy ten konwencjonalnie niewykorzystywany potencjał danych testowych, stosując i) samonadzorowane (ang. self-supervised) cele uczenia, ii) modułowe architektury modeli sieci neuronowych oraz iii) dostosowywanie hiperparametrów online.

Naszym celem jest udoskonalenie tradycyjnych metod uczenia głębokiego, umożliwiając im ciągłe uczenie się na podstawie nieoznakowanych danych, dostosowanie się do wyzwań związanych z wdrażaniem w świecie rzeczywistym, a co najważniejsze, umożliwienie ukończenia misji powierzonej naszemu modelowi.

Oczekiwane wyniki. Rezultatem badań będą wysoce elastyczne i dynamiczne sieci neuronowe, które nie tylko wykorzystują wiedzę zdobytą podczas początkowego uczenia, ale także stale ewoluują w oparciu o nieograniczoną ilość danych wykorzystywanych do wnioskowania. Umożliwi to metodom głębokiego uczenia pozostanie odpornymi na trudne do przewidzenia wyzwania w niekontrolowanych środowiskach, skutecznie radząc sobie z nieoczekiwanymi sytuacjami.

Oczekujemy, że opracowane podejścia znajdą zastosowanie w wielu rzeczywistych aplikacjach, od przetwarzania obrazów medycznych po przemysł motoryzacyjny i robotykę. Skoncentrujemy się na zadaniach związanych z wizją komputerową, ponieważ jest to idealne pole testowe, biorąc pod uwagę różnorodność możliwych domen wizualnych oraz wymóg, aby modele dokładnie rozumiały i interpretowały bogate informacje wizualne. Koncentrując się na wyzwaniach związanych z wizją komputerową, chcemy stworzyć solidne podstawy do powszechnego wdrażania tych technik w rzeczywistych warunkach, przyczyniając się do postępu w wielu krytycznych branżach.