

Hypernetworks methods in Meta-Learning

W ostatnich latach modele uczenia maszynowego w wielu zadaniach otrzymują lepszą skuteczność niż człowieka. Na przykład w grach Atari, czy rozpoznawaniu obiektów na zdjęciach. Mimo to nasze modele sztucznej inteligencji nie dorównują ludzkiej możliwości uczenia się.

Obecne techniki sztucznej inteligencji nie potrafią szybko adaptować się do nowych zadań na podstawie kilku przykładów uczących. Większość architektur głębokich sieci neuronowych musi być uczona na ogromnych zbiorach danych. W przeciwieństwie do tego, ludzie są w stanie szybko uczyć się nowych zadań, wykorzystując to, czego nauczyli się w przeszłości. Na przykład dziecko, które nauczyło się dodawać, może szybko uogólnić swoją wiedzę, aby nauczyć się mnożenia wykorzystując tylko kilka przykładów (np. $2 * 3 = 2 + 2 + 2$ i $3 * 1 = 1 + 1 + 1$). Ponadto dzieci mają zdolność zapamiętywania ludzi tylko po kilku zdjęciach. Mając kilka zdjęć nieznanego, dziecko może łatwo zidentyfikować tę samą osobę na dużej liczbie obrazów. **Few-shot learning** próbuje wypełnić tę lukę, aby uczyć modele sztucznej inteligencji z ograniczonej liczby przykładów, patrz Rys. 1.


Z drugiej strony, dla ludzi uczenie się na ciągłym strumieniu danych jest całkiem normalne, ponieważ dane w świecie rzeczywistym przychodzą sekwencyjnie. Uczenie się nowych zadań przy jednoczesnym zachowaniu i wykorzystaniu wiedzy z poprzednich jest kluczowe w codziennym życiu. Chociaż modele uczenia głębokiego osiągnęły wielki sukces w różnych zadaniach, nadal zawodzą w tym zasadniczym momencie, wykazując słabą wydajność na wcześniej nauczonych zadaniach. Zjawisko to nazwane zostało katastroficznym zapominaniem. **Continual learning** zajmuje się uczeniem modeli na podstawie strumienia danych, patrz Rys. 2.

W większości istniejących systemów sztucznej inteligencji, obrazy, dźwięki, obiekty 3D mają dyskretną reprezentację. Na przykład obrazy są zwykle reprezentowane jako tablice pikseli 2D, dźwięki jako szeregi czasowe, a obiekty 3D jako chmury punktów 3D (lub siatki 3D). Z drugiej strony ludzie postrzegają obiekty w reprezentacji ciągłej. W praktyce, kiedy patrzymy na obraz, ekstrapolujemy/halucynujemy niewidoczną część. W związku z tym możemy rozpoznać niektóre obiekty, gdy w przyszłości zobaczymy z różnych pozycji i w różnych rozdzielczościach. W uczeniu maszynowym możemy reprezentować obiekty jako ciągły model reprezentowane przez sieci neuronowe – **ciągłe reprezentowanie obiektów**.

W naszym projekcie mamy zamiar zredukować różnice w procesie uczenia między ludźmi a modelami sztucznej inteligencji. Nasza główna idea polega na kontrolowaniu struktury wag w głębokich sieciach neuronowych w celu rozwiązania powyższych problemów. Przede wszystkim planujemy wykorzystać architekturę Hiper sieci. Hiper sieci definiuje się jako modele, które generują wagi dla docelowej architektury, która rozwiązuje nasze zadanie. Taką architekturę może warunkować wagi informacjami z poprzednich zadań. W naszym grancie pojęcie **Hipersieć** będziemy rozumieć szerzej, jako mechanizm, który może kontrolować strukturę wag sieci neuronowych.



Rysunek 1: Na powyższym obrazku przedstawiamy problem few-shot learningu. W trakcie uczenia aktualizujemy parametry modelu na podstawie kolejnych tasków treningowych. Po nauczaniu nasz model musi poprawnie zaklasyfikować elementy ze zbioru query na podstawie elementu ze zbioru support.



Rysunek 2: Ogólnie rzecz biorąc, ciągłe uczenie się oznacza zdolność sieci neuronowej do efektywnego uczenia się nowych zadań, jednocześnie starając się nie zapominać już poznanych informacji.