

STRESZCZENIE POPULARNONAUKOWE

Celem projektu jest konstrukcja i analiza nowych algorytmów uczących dla złożonych problemów predykcyjnych w ramach *teorii uczenia przyrostowego*. Uczenie przyrostowe dotyczy *sekwencyjnych problemów predykcyjnych*. Rekomendacja filmów w systemach internetowych, predykcja cen akcji, nawigacja i znajdowanie tras w ruchu ulicznym, prognozowanie pogody, strategie w grach, poruszanie się robota w nieznanym środowisku (np. autonomicznego samochodu) czy wybór reklam do pokazania w wyszukiwarce są przykładami takich procesów.

Jako ilustracyjny przykład, rozważmy problem uczenia przyrostowego, w którym każdego dnia algorytm musi przewidzieć czy następnego dnia będzie padał deszcz. Algorytm ma dostęp do kilku ekspertów od prognozy pogody. Każdego dnia, każdy taki ekspert przewiduje czy będzie padać, czy nie, a predykcja algorytmu jest kombinacją predykcji wszystkich ekspertów. Następnego dnia algorytm dowiadyuje się, jaki jest faktyczny stan pogody, i na podstawie tego określa czy jego predykcja była poprawna. W miarę, jak obserwujemy coraz więcej danych, algorytm będzie adaptował swoje decyzje poprzez przydzielanie większej wagi tym ekspertom, którzy często przewidywali poprawnie, i mniejszej wagi ekspertom, którzy często się mylili. Celem algorytmu jest przewidywać z jakością podobną do tej, jaką ma ekspert, który okaże się najlepszy gdy wszystkie dane (stany pogody) zostaną już zaobserwowane; co więcej, chcemy aby to zachodziło niezależnie od tego jakie są predykcje ekspertów i faktyczne stany pogody! Mimo, że cel ten wydaje się trudny do osiągnięcia, istnieją algorytmy, które takie gwarancje posiadają. Cechują się tym, że miarowo koncentrują swoją „ufność” na najlepszym aktualnie ekspercie, równocześnie zabezpieczając się poprzez przydzielanie pewnej niewielkiej wagi pozostałym ekspertom.

O ile problem opisany powyżej może wydawać się odrobinę sztuczny, metody uczenia przyrostowego są obecnie rutynowo używane w uczeniu maszynowym, i zostały z powodzeniem zastosowane w różnorodnych problemach praktycznych. Przykłady zastosowań to: uczenie maszynowe w bardzo dużej skali (miliardy przykładów uczących opisane za pomocą bilionów cech), nowoczesne systemy kompresji danych, systemy rekomendacyjne, pozycjonowanie reklam internetowych, sortowanie wyników zapytań w wyszukiwarkach, gry hazardowe, strategie gry na giełdzie, i wiele innych. Nic więc dziwnego, że metody te obecne są w najbardziej popularnych pakietach oprogramowania do uczenia maszynowego.

Problem uczenia przyrostowego charakteryzują trzy główne elementy: i) Funkcja straty (błędu) zdefiniowana dla możliwych predykcji i wartości przewidywanych. ii) Struktura danych i parametrów algorytmu. iii) Referencyjny zbiór strategii, z którymi algorytm konkuruje. Pierwszy z tych elementów określa zbiór możliwych akcji (predykcji) algorytmu oraz funkcję, która ocenia jakość predykcji, gdy faktyczna wartość przewidywana zostanie już ujawniona. Przykładowo, w problemie prognozowania pogody algorytm przewiduje czy będzie deszcz, a po ujawnieniu prawdziwego stanu pogody karany jest jednostką straty jeśli jego predykcja okazała się niepoprawna, lub nie otrzymuje straty w przeciwnym przypadku. Drugi z elementów określa strukturę danych i odpowiadający jej zbiór parametrów. W naszym przykładzie dane to predykcje poszczególnych ekspertów, a parametr algorytmu to wagi jakie przypisuje on tym predykcjom (formalnie jest to rozkład prawdopodobieństwa). Wreszcie, trzeci element określa klasę strategii predykcyjnych, z którymi jakość działania algorytmu zostanie porównana. W przykładzie prognozowania pogody będzie to po prostu zbiór ekspertów pogodowych, których predykcji algorytm używa.

W tym projekcie zajmiemy się sytuacjami, w których przynajmniej jeden z opisanych elementów składowych – funkcja straty, dane i parametry, lub zbiór strategii – stanowi znaczące wyzwanie badawcze. Rezultaty projektu mają w zamierzeniu zwiększyć efektywność istniejących algorytmów i prowadzić do nowych, oryginalnych metod uczenia przyrostowego dla problemów analizowanych dotychczas w niewielkim stopniu.