

Generatywne modele przepływowe w zastosowaniu do modelowania niepewności w zadaniach uczenia maszynowego

Nowoczesne modele uczenia maszynowego osiągają niesamowite wyniki w różnych zadaniach, w tym klasyfikacji, regresji, wykrywania obiektów, segmentacji semantycznej, grupowania, uczenia reprezentacji, generowania różnorodnych typów danych i wielu innych. Dla większości z wymienionych zastosowań celem jest raczej dostarczenie deterministycznej predykcji, nie skupiając się zbytnio na modelowaniu niepewności predykcji.

Jednym z najczęstszych zastosowań modelowania niepewności są obszary wysokiego ryzyka, w których wymagana jest pełna informacja o rozkładzie predycyjnym, np. wolelibyśmy wiedzieć, że pacjent ma 50% szans na przeżycie kolejnych 12 miesięcy i 20% szans na przeżycie następnych 24 miesięcy itd., zamiast wiedzieć tylko tyle, że średni czas przeżycia dla tego pacjenta wynosi 13 miesięcy. Kolejnym obszarem zastosowania jest predykcja przyszłego stanu obiektu, którą przedstawia Rysunek 1. Jak widać na przedstawionym obrazie, taki problem wymaga elastycznego podejścia, umożliwiającego modelowanie wielomodalnych rozkładów prawdopodobieństwa.



Figure 1: Zastosowanie jednego z głębokich probabilistycznych modeli regresji - RegFlow wykorzystującego modele przepływowe. Biorąc pod uwagę przeszłą pozycję obiektu na obrazie (na czerwono) i dane treningowe, celem predykcji było modelowanie rozkładu prawdopodobieństwa przyszłych stanów obiektu (przedstawionych za pomocą mapy ciepła) i najbardziej prawdopodobnych kierunków (przedstawionych strzałkami). Prawdziwe przyszłe stany mają kolor fioletowy.¹

Jednym z głównych problemów dostępnych probabilistycznych modeli regresji jest założenie dotyczące przewidywanego rozkładu prawdopodobieństwa, którym zwykle jest rozkład Gaussa, z uwagi na fakt, że nie może on w elastyczny sposób modelować rozkładów wielomodalnych. To ograniczenie można przewyciężyć dzięki modelom przepływowym, które są w stanie modelować dowolny rozkład prawdopodobieństwa. Dzięki takiej elastyczności modele te mogą być wykorzystywane nie tylko w standardowych problemach regresji, ale także w trudniejszych konfiguracjach.

Celem tego projektu jest budowa modeli opartych na przepływowych modelach uczenia głębokiego dla jednowymiarowej i wielowymiarowej regresji probabilistycznej. Ponadto modele przepływowe zostaną połączone z modelami opartymi na drzewach oraz rozszerzone na inne zadania uczenia maszynowego, takie jak grupowanie lub wykrywanie wartości odstających, inne rodzaje danych, takie jak dane sekwencyjne, oraz inne obszary zastosowań. Ponadto opracowany zostanie zestaw zaleceń dotyczących wcześniejszego wyboru rozkładu bazowego modelu przepływowego, a na koniec opracowane zostaną nowe narzędzia do analizy niepewności opartej na tych modelach. Skonstruowane metody zostaną przeanalizowane jakościowo i ilościowo z wykorzystaniem zestawów danych porównawczych dostępnych publicznie w Internecie.

¹Source: Maciej Zioba et al. *RegFlow: Probabilistic Flow-based Regression for Future Prediction*. (2020).