



Wrocław, 07.10.2024

mgr inż. Patryk Wielopolski

Dyscyplina naukowa: Informatyka Techniczna i Telekomunikacja

Numer albumu: 10522

Streszczenie rozprawy doktorskiej
pt. "Normalizing flow models for modeling uncertainty in machine learning tasks"

W ostatnich latach modele uczenia maszynowego osiągnęły niezwykle wyniki w szerokim zakresie zadań, w tym klasyfikacji, regresji i generowania danych, obejmujących różne modalności, takie jak dane tabelaryczne, tekst, obrazy i chmury punktów. Jednak wiele z tych zastosowań skupiało się głównie na przewidywaniach deterministycznych, często pomijając znaczenie modelowania niepewności w tych przewidywaniach. Niniejsza rozprawa ma na celu rozwiązanie tego ograniczenia poprzez wykorzystanie modeli normalizacji przepływu do efektywnego modelowania niepewności w szerokim spektrum zadań uczenia maszynowego.

Ta rozprawa składa się z siedmiu artykułów i jest podzielona na trzy części. Pierwsza część, omówiona w publikacjach [I-III], koncentruje się na stosowaniu modeli normalizacji przepływu do zadań dyskryminacyjnych. Publikacja [I] wprowadza TreeFlow, nowatorskie podejście, które wzmacnia parametryczne modele oparte na drzewach o bardziej ekspresyjne rozkłady prawdopodobieństwa dla zadań regresji. Publikacja [II] przedstawia NodeFlow, kompleksowe podejście do regresji probabilistycznej dla danych tabelarycznych, które ulepsza dwuetapowy proces trenowania TreeFlow. Publikacja [III] demonstruje wszechstronność tych metod poprzez dostosowanie ich do spersonalizowanego przetwarzania języka naturalnego, co daje znaczące usprawnienia w rozpoznawaniu emocji i wykrywaniu mowy nienawiści.

Druga część pracy, obejmująca Publikacje [IV-VI], bada zastosowanie normalizacji przepływów do zadań generatywnych. Publikacja [IV] wprowadza Flow Plugin Network (FPN), innowacyjną architekturę, która integruje modele normalizacji przepływu z wstępnie wyszkolonymi modelami generatywnymi. Publikacje [V, VI] przedstawiają PluGeN, wyrafinowane podejście do wieloetykietowej generacji warunkowej, które wykorzystuje wstępnie wyszkolone modele, demonstrując jego potencjał w generowaniu obrazów i chmur punktów 3D z kombinacjami atrybutów niewidocznymi podczas treningu.

Trzecia część, omówiona w Publikacji [VII], bada przecięcie się zadań dyskryminacyjnych i generatywnych w domenie Explainable AI (XAI). Wprowadza nową metodę generowania prawdopodobnych, kontrfaktycznych wyjaśnień przy użyciu normalizacji przepływów (PPCEF), zwiększając wiarygodność i interpretowalność wyjaśnień AI.

Wszystkie wspomniane publikacje zostały zaprezentowane na prestiżowych konferencjach lub ukazały się w renomowanych czasopismach naukowych. Badania te pokazują, jak



wszechstronne zastosowanie mają modele normalizacji przepływu w różnych dziedzinach uczenia maszynowego. Przyczyniają się one do tworzenia systemów sztucznej inteligencji, które są nie tylko dokładniejsze, ale także bardziej kontrolowane i łatwiejsze do zrozumienia. Ta praca otwiera wiele obiecujących kierunków dla przyszłych badań. Wśród nich można wymienić zastosowanie tych metod do większych zbiorów danych, połączenie ich z nowymi koncepcjami w dziedzinie AI, a także rozszerzenie ich wykorzystania na nowe obszary.