Streszczenie

Niniejsza rozprawa doktorska bada metody projektowania systemów sztucznej inteligencji do analizy obrazów medycznych i biologicznych, które zachowują wysoką dokładność, efektywność danych, wykonalność obliczeniową oraz niezawodność w warunkach niejednoznaczności adnotacji. Praca została sformułowana jako kumulatywny program badawczy obejmujący dedykowane architektury neuronowe do klasyfikacji, segmentacji semantycznej, generowania danych syntetycznych oraz modelowania niepewności rozmytej. Badania te wieńczy opracowanie półnadzorowanego szkieletu opartego na Transformerach do segmentacji hematologicznej, który integruje w jednym procesie uczącym przetwarzanie wstępne uwzględniające specyfikę barwienia, globalną atencję z pulowaną pamięcią, kompresję spektralną, maskowany nadzór oraz regularyzację opartą na odpornych algorytmach rozmytych C-średnich w przestrzeni RGB. Wyniki przedstawione w rozprawie dowodzą, że architektury adaptowane domenowo oraz pryncypialne strategie efektywności danych przewyższają ogólne modele bazowe w naukowych zastosowaniach niskodanych, podczas gdy modelowanie rozmyte poprawia działanie systemu na niejednoznacznych krawędziach i obszarach słabo adnotowanych. Finalny system hematologiczny osiąga dokładność walidacyjną na poziomie 99,73%, wskaźnik micro-Dice równy 99,73% oraz micro-IoU wynoszący 99,46% w reżimie niskiego zapotrzebowania na etykiety, co potwierdza tezę, że efektywne modelowanie kontekstu dalekiego zasięgu oraz uwzględniający niepewność półnadzór mogą zostać zintegrowane w praktyczne narzędzie do mikroskopii wymazów krwi.

Słowa kluczowe: analiza obrazow medycznych, segmentacja semantyczna, transformatory, uczenie polnadzorowane, logika rozmyta, mikroskopia hematologiczna