

Rozwój metod deep learningu jako narzędzia wsparcia analizy mikroskopowych obrazów patomorfologicznych

Jedną z najpopularniejszych obecnie metod uczenia maszynowego są metody deep learningu (DL). Podstawą działania tych metod jest detekcja cech obiektów w oparciu o wysoki poziom abstrakcji. Biologiczną inspiracją dla tego rozwiązania stanowi sposób działania mózgu. Architektura sieci DL jest niezwykle złożona, w ich skład wchodzi wiele różnych typów warstw posiadających liczne parametry. Przykładem tego jest sieć Alex Net posiadająca 60 milionów parametrów oraz 500 tysięcy neuronów.

Metody deep learningu są stosowane przez wiele firm o zasięgu międzynarodowym, takich jak Google oraz Facebook. Przykładem praktycznego zastosowania DL są systemy automatycznego rozpoznawania mowy, systemy rozpoznawania scen, predykcja ontologii genów, predykcja wpływu chemikaliów na środowisko, systemy określające wiek i płeć. Ponadto rozwiązanie, to stosowane jest w wielu technicznych zastosowaniach oraz projektach badawczych. Główną zaletą zastosowania metod DL jest szybka klasyfikacja oraz możliwość zastosowania wielu kategorii. Jednakże etapy trenowania i opracowywania architektury tego typu sieci stanowią złożone zagadnienie. Możemy wyróżnić dwie metody uczenia sieci DL: pełne uczenie oraz uczenie transferowe. Proces uczenia transferowego wykorzystuje pre-trenowane modele sieci, będące sieciami trenowanymi na dużych zbiorach danych (np. 1.3 miliona danych lub więcej). Metoda dostrajania (fine-tuning, FT), polegająca na modyfikacji parametrów sieci pre-trenowanej podczas ponownego procesu uczenia. Kluczowym zagadnieniem procesu uczenia jest ilość danych. W przypadku pełnego uczenia niezbędne są setki tysięcy obrazów dla każdej z klas. W przypadku wykrywania twarzy, detekcji obiektów, rozpoznawania zwierząt lub płci pozyskanie dużej liczby danych nie jest problematyczne. Jednakże w przypadku danych medycznych pozyskanie zbiorów danych o takich liczebności może być skomplikowane lub niemożliwe. Ilość danych medycznych jest znacząco ograniczona, ponadto poszczególne klasy mogą być gorzej reprezentowane niż inne.

W naszych badaniach planujemy ocenić przydatność różnych metod trenowania sieci DL w celu uzyskania prawidłowej klasyfikacji danych medycznych (patomorfologicznych) oraz rozwinąć metody uczenia sieci DL w przypadku ograniczonej liczby danych. Jest to istotne zagadnienie ze względu na ograniczenie liczebności zbiorów danych medycznych. Prowadzi to do pytania: „jak liczny zbiór danych jest niezbędny do prawidłowego uczenia sieci DL?”. Planujemy rozwijać metody dostrajania sieci (FT) do analizy obrazów patomorfologicznych. Uzyskane wyniki zostaną porównane z innymi metodami uczenia. W celu rozwiązania problemu liczby danych planujemy opracowanie metod sztucznego zwiększania liczby danych patomorfologicznych. Szczegółowa analiza preparatów patomorfologicznych pozwoli na modyfikację obrazów w celu zwiększenia ich liczby. Metody sztucznego zwiększenia liczby danych patomorfologicznych mogą być użytecznym narzędziem w przetwarzaniu obrazów oraz trenowaniu sieci DL. Badania w tym obszarze są innowacyjne

Wyniki badań będą miały bezpośredni wpływ na dziedzinę badań, ekonomię oraz społeczeństwo. Uzyskane wyniki pozwolą na wzrost poziomu wiedzy społeczeństwa oraz opracowanie nowych rozwiązań w analizie obrazów medycznych. Wykazanie, że metody DL mogą być wydajnym narzędziem w przypadku ograniczonej liczby danych pozwoli to na opracowanie nowych systemów wspierających patomorfologię cyfrową.