

9. Streszczenie

Przedstawiona praca wprowadza kilka nowatorskich metod, które wykorzystują najnowocześniejsze algorytmy uczenia maszynowego do tworzenia systemów rekomendacji. Biorąc pod uwagę subiektywny charakter oceny wydajności systemu, zamiast wyłącznie maksymalizacji miar dokładności, jak opisano w podsekcji 1.2.1, naszym głównym celem było zwiększenie możliwości interpretacji uzyskanych zaleceń. Zaproponowane algorytmy zostały zaprojektowane tak, aby skutecznie obsługiwać różne rodzaje danych powszechnie spotykanych w systemach rekomendacji i wykazały swoją skuteczność.

Po pierwsze przeprowadzono szeroki zakres badań mających na celu opracowanie systemu rekomendacji, który dokładnie odwzorowuje profil użytkownika przy zachowaniu generalizacji wiedzy w ramach sieci neuronowej. Proponowany system rekomendacji jest zbudowany na technikach głębokiego uczenia się i osiąga wysoką wydajność dzięki zastosowaniu struktury hybrydowej, która łączy sieci neuronowe zarówno dla atrybutów nominalnych, jak i nienominalnych. Dodatkowo system ten zawiera moduł zapewniający interpretowalność rekomendowanych obiektów. Oznacza to, że każdej wybranej propozycji na liście rankingowej towarzyszy wyjaśnienie, dlaczego została ona polecona użytkownikowi. Aby zbadać interpretowalność systemu rekomendacji, przeprowadzono symulację przy użyciu zestawu danych MovieLens 20M. W proponowanej metodzie kluczowe znaczenie ma podejście hybrydowe. Wykorzystując model oparty na Collaborative Filtering, rekomendacje mogą być obliczane na poziomie populacji ogólnej, skutecznie łagodząc negatywny wpływ zjawiska zimnego startu, który często dotyka nowo zarejestrowanych użytkowników. Ponadto opracowaliśmy dodatkową strukturę do działania w oparciu o metodologię filtrowania Content-Based. Takie podejście umożliwiło stworzenie indywidualnych modeli dla użytkowników, mających na celu śledzenie relacji między wartościami atrybutów wybranych pozycji a ocenami użytkownika w systemie. Oba moduły rekomendacji zostały zmontowane przy użyciu autorskiego algorytmu, który decyduje o ostatecznym wyniku rekomendacji.

Ponadto zaproponowano wykorzystanie algorytmu t-SNE do celów wizualizacji. Algorytm ten ułatwił redukcję wymiarów, przedstawiając każdy element w przestrzeni trójwymiarowej. W konsekwencji każdemu punktowi w tej przestrzeni 3D odpowiada określony przedmiot, a odległość między dwoma punktami odzwierciedla podobieństwo ich cech. Organizując przestrzeń decyzyjną użytkownika w trzech wymiarach, istnieje możliwość identyfikacji odrębnych grup filmów, które w znacznym stopniu pokrywają się z preferencjami użytkownika. Ta technika wizualizacji stanowi cenne wsparcie dla wyników generowanych przez system rekomendacji. Obliczając wysoką wartość rekomendacji, możemy ocenić prawdopodobieństwo, że dany przedmiot spodoba się gustowi

użytkownika na podstawie jego pozycji w wizualizowanej przestrzeni. Zapewnia to środki do sprawdzania poprawności zaleceń systemu, a ponadto gwarantuje, że zalecane filmy są zgodne z preferencjami użytkownika.

W drugim proponowanym podejściu zaprojektowano system rekomendacji wykorzystujący mechanizmy uwagi Bahdanau, pierwotnie stosowane w przetwarzaniu mowy. W tym systemie zastosowano mechanizm uwagi, aby wyróżnić najbardziej istotne obszary obrazu. System zawiera również możliwość opisywania zdjęć w kategoriach klas, które są wyjściem klasyfikatora podłączonego do sieci CNN. Symulacje przeprowadzono z wykorzystaniem bazy danych Zappos50K. Szeroko pojęte badania nad kluczowymi cechami obrazu zakończyły się opracowaniem modelu AI opartego na uwadze generowanej przez strukturę koder-dekoder dla obrazów. Model ten jest wykorzystywany do klasyfikacji na podstawie uwagi uzyskanej dla obrazów. W rezultacie klasyfikator podkreśla najważniejsze obszary obrazów, umożliwiając podkreślenie charakterystycznych cech każdej klasy.

Ponadto zidentyfikowano ograniczenia metody Occlusion Sensitivity, w szczególności ograniczenie związane z ustaloną wielkością okna. To ograniczenie wpływa nie tylko na szybkość obliczeń, ale także na ogólne wyniki wyświetlane na mapie cieplnej. Aby rozwiązać to ograniczenie, zaproponowano algorytm oparty na rekurencyjnym wyszukiwaniu obrazów, wykorzystujący wyniki uzyskane z funkcji softmax. Algorytm ten umożliwia generowanie obszarów uwagi o różnej wielkości, czego brakuje w oryginalnej metodzie Occlusion Sensitivity. Ponadto algorytm jest zoptymalizowany pod kątem efektywnej wydajności obliczeń równoległych. W celu oceny proponowanej modyfikacji metody Occlusion Sensitivity przeprowadzono symulacje z wykorzystaniem bazy danych MS COCO 2017. Wykorzystano do tego celu model EfficientNetB7, wstępnie wytrenowany na wspomnianej bazie danych. Ze względu na charakter operacji wieloetykietowej sieć generuje rozpoznawanie w postaci wielu klas przypisanych do pojedynczego obiektu. Ta struktura okazuje się bardzo skuteczna, gdy jest stosowana do segmentacji instancji, generując obwiednie dla każdej instancji na obrazie. Dla każdego wykrytego prostokąta zastosowano zaproponowany algorytm. Zawartość w obwiedni została zamaskowana, aby odizolować ją od reszty obrazu. Następnie zastosowano zmodyfikowany rekurencyjny algorytm Occlusion Sensitivity. Ten proces wygenerował zestaw uwag dla każdego obrazu, umożliwiając uchwycenie najbardziej charakterystycznych obszarów w jego obrębie. Proponowana metoda, oferując możliwość generowania uwagi o różnej wielkości, umożliwia dokładniejsze badanie wyjścia sieci, a co za tym idzie, umożliwia dokładniejszy nadzór nad procesem uczenia sieci.

Na koniec omówiono ograniczenia metody GradCAM, w szczególności dotyczące obliczania kierowanego gradientu, który uwzględnia tylko dodatnie gradienty propagowane przez sieć podczas algorytmu wstecznej propagacji błędów. Aby złagodzić to ograniczenie, zaproponowano podejście obejmujące analizę niezerowych gradientów, w tym zarówno wartości dodatnich, jak i ujemnych. Modyfikując w ten sposób algorytm GradCAM, możemy interpretować działanie sieci neuronowej, badając gradienty obliczone z procesu wstecznej propagacji. Wykorzystanie tej zmodyfikowanej metody GradCAM w systemach rekomendacyjnych pozwala na wizualizację działania sieci neuronowej. Ta funkcja wizualizacji zapewnia wsparcie procesów decyzyjnych, szczególnie w dziedzinach takich jak

medycyna. Na przykład proponujemy system klasyfikacji zdjęć rentgenowskich pacjentów na podstawie zaleceń diagnostycznych w kierunku COVID-19. Kluczowe staje się uczenie sieci neuronowej w kolejnych iteracjach, wykorzystując wgląd uzyskany z map cieplnych generowanych przez zmodyfikowany algorytm GradCAM. Ten iteracyjny proces pomaga udoskonalić wydajność sieci i poprawić jej zdolność do dokładnej klasyfikacji promieni rentgenowskich i dostarczania zaleceń diagnostycznych.

Przeprowadzone analizy i zaproponowane metody przedstawione w rozprawie są cennym wkładem we współczesne rozumienie systemów rekomendacji. Należy jednak przyznać, że dynamiczny charakter metod uczenia maszynowego wymaga ciągłej pracy nad ich efektywnym dostosowaniem do realizacji zadań rekomendacyjnych. Konieczne są dalsze wysiłki w celu zwiększenia możliwości interpretacji otrzymanych rekomendacji. Niemniej jednak algorytmy omówione w tej rozprawie zapewniają znaczący postęp i spostrzeżenia w tej dziedzinie, służąc jako solidna podstawa dla przyszłych badań i rozwoju systemów rekomendacji.