

Streszczenie

Metody uczenia maszynowego dla systemów rekomendacyjnych rozwijają się obecnie niezwykle szybko. Rozwój metod naukowych podsycany jest przez rosnącą praktyczną potrzebę wykorzystywania systemów rekomendacyjnych w biznesie. Postęp w dziedzinie mierzony przez dynamicznie rozwijane benchmarki, często tworzone w ramach konkursów na prestiżowych międzynarodowych konferencjach, takich jak na przykład konkurs KDD Cup na konferencji SIGKDD Conference on Knowledge Discovery and Data Mining, RecSys Challenge organizowany przez ACM Conference Series on Recommender Systems (RecSys), czy OGB Large-Scale Challenge uniwersytetu Stanford. Badania nad systemami rekomendacyjnymi wiążą się ściśle z dziedzinami takimi przetwarzanie dużych danych (*big data*), skalowalne uczenie maszynowe, przetwarzanie danych grafowych, wyszukiwanie informacji (*information retrieval*), oraz przetwarzanie danych multimedialnych. Zastosowanie systemów rekomendacji w praktycznych scenariuszach biznesowych powoduje, że ważnym wyzwaniem jest tu również interpretowalność modeli oraz badanie ich stabilności wobec przykładów wrogich (*adversarial examples*).

Celem niniejszej pracy doktorskiej jest zbadanie zdolności i ograniczeń istniejących systemów rekomendacji, oraz stworzenie nowych metod rekomendacyjnych. Zaproponowane rozwiązania powinny poprawić jakość znanych metod, co może przyczynić się do rozwoju tej dziedziny naukowej.

Wszystkie postawione cele pracy zostały zrealizowane, czego efektem końcowym było stworzenie multimedialnego i odpornego systemu rekomendacyjnego, który osiąga sumarycznie lepsze wyniki na wielu benchmarkach. Badania opisane w pracy zostały wdrożone w ramach dwóch platform komercyjnych, które są obecnie dostępne na rynku i osiągają sukces biznesowy.

Abstract

The area of machine learning for recommender systems has faced unprecedented growth in recent years. Research is fuelled by practical business demand for these models. The pace of progress is measured by dynamically growing benchmarking effort, often in terms of competitions held at esteemed scientific conferences, such as the annual KDD Cup at SIGKDD Conference on Knowledge Discovery and Data Mining, RecSys Challenge held at ACM Conference Series on Recommender Systems (RecSys), or Stanford's OGB Large-Scale Challenge. Recommender systems research relies heavily on topics such as big data processing, scalable machine learning, large graph processing, information retrieval, and multimodal aspects of data. The practical application of recommender systems in production also calls for development of interpretability and robustness algorithms.

The purpose of this PhD thesis is to research the abilities and limitations of current recommender algorithms, and introduce new methods in the broad area of recommenders. These new methods should improve upon the performance results achieved by previous research and contribute to the growth of this science branch.

The thesis introduces a number of research objectives, which have all been achieved. The final result is a full recommender system, which reaches new state-of-the-art results on multiple datasets and performance metrics. The recommender system is applied in a business setting in two commercial platforms, which are currently available on the market and have reached a business success.