

Algorytmy autonomicznego zarządzanie asortymentem i rekomendacji dla celów handlu detalicznego na dużą skalę z wykorzystaniem zaawansowanych technik przetwarzania języka naturalnego i modeli transferowalnego popytu

PROMOTOR:

Dr hab. inż. Szymon Łukasik (slukasik@ibspan.waw.pl)

PROMOTOR POMOCNICZY:

Dr inż. Anna Wróblewska (anna.wroblewska@mini.pw.edu.pl)

INSTYTUT:

Systems Research Institute Polish Academy of Sciences, Newelska 6, Warszawa

DYSCYPLINA:

Informatyka techniczna i telekomunikacja

REKRUTACJA:

Rozmowa rekrutacyjna

ILOŚĆ MIEJSC:

1

OPIS PROJEKTU

Obecnie systemy rekomendacyjne osiągają znakomite wyniki i zyskują popularność, zwłaszcza w sektorze handlu detalicznego. Jednak znalezienie i wyjaśnienie relacji między produktami wymaga dużej ilości badań i ciągłego rozwoju. W tym kontekście kluczowe jest zidentyfikowanie i wykazanie, czy dwa produkty są substytutami, czy są w stosunku do siebie produktami komplementarnymi [[McAlister, Lattin, 1983](#)]. Zastosowania biznesowe ulepszonych mechanizmów rekomendacji muszą być uzasadnione i określone ilościowo poprzez wprowadzenie odpowiednich wskaźników wydajności. Dlatego rekomendacja powinna nie tylko wspierać wybory konsumentów, ale także pomagać w podejmowaniu decyzji biznesowych.

Popyt transferowalny (*ang. transferable demand*) również ma na celu modelowanie substytucji produktów z perspektywy sprzedawcy. Jeśli konsument pominie produkt z określonej puli popytu, lub może nawet wyeliminuje w swych decyzjach wszystkie produkty z określonej puli popytu (np. wszystkie małe opakowania lub wszystkie artykuły o smaku kurczaka), czy może on przenieść popyt z pominiętego produktu na pozostałe produkty w asortymencie? A może okaże się tak lojalny wobec tego konkretnego zestawu potrzeb (pominiętego produktu), że wyjdzie ze sklepu bez dokonania zakupów? Dlatego jedną z kluczowych decyzji, jaką powinien podjąć specjalista ds. asortymentu, jest dobór takiego asortymentu, aby klienci mieli do wyboru różne alternatywne produkty. Wybór asortymentu jest z natury pytaniem typu „Co by było, gdyby?”. Co się stanie, jeśli produkt A będzie na półce zamiast produktu B? Jak popyt zostałby rozłożony na inne produkty w kategorii produktów i poza nią? Wcześniejsze oszacowanie popytu i prace związane z optymalizacją asortymentu [[Kök, Fisher, 2007](#)]

próbują podjąć ten temat, ponieważ oszacowanie prawdopodobieństwa zastąpienia jest szczególnie przydatne w biznesie związanym ze sprzedażą. Jednak powyższe prace nie biorą pod uwagę decyzji dotyczących zapasów, co może nie być dobrym rozwiązaniem dla szybko rozwijających się dużych firm detalicznych, w których niezmiernie ważne są koszty związane z zapasami.

Niektórzy badacze intensywnie wykorzystują korpusy tekstu zawierające recenzje i opisy produktów, aby udoskonalić wyszukiwanie powiązań pomiędzy produktami [McAuley et al., 2015]. Istnieje przy tym duży potencjał w wykorzystaniu bardziej rozbudowanych recenzji produktów, np. ustrukturyzowanych atrybutów produktu oraz ich zalet i wad w zwiększaniu popytu i prognozowaniu zastępowalności. Dlatego uważa się, że wykorzystanie technik eksploracji tekstu i przetwarzania języka naturalnego (*ang. natural language processing - NLP*) ma fundamentalne znaczenie dla dalszego rozwoju identyfikacji konwencjonalnych i nietypowych produktów, które można zastąpić lub uzupełnić. Podsumowanie tekstu (*ang. text summarization*) jest częścią dziedziny NLP, która jest szczególnie interesującą, ponieważ ma duży potencjalny wpływ na personalizację zaleceń.

Podsumowanie tekstu, a dokładniej podsumowanie automatyczne [Jones, Karen, 2007] to złożony temat, jeśli chodzi o podejście techniczne i wdrażanie biznesowe. Wytłumaczalne systemy sztucznej inteligencji (XAI) [Biran and Cotton, 2017] pomagają radzić sobie ze zmianami i zapewniają narzędzia do opracowywania podejść do konkretnych przypadków użycia. W tym obszarze przeprowadzonych zostało dotąd wiele badań dotyczących wyszukiwania informacji z dokumentacji biomedycznej [Moradi, Ghadiri, 2019] [Reeve et al., 2007]. Niemniej jednak, nie nastąpił przełom w komercyjnym wykorzystaniu tych technik w handlu detalicznym, a zwłaszcza w silnikach rekomendacyjnych. Co ciekawe, użycie elementów tekstowych jest brane pod uwagę podczas budowania różnego rodzaju rekomendacji opartych na treściach tekstowych [Lops et al., 2011], ale zasadniczo nie wykorzystują one technik podsumowań - co mogłoby uczynić uzyskiwane wyniki bardziej spersonalizowanymi i atrakcyjnymi dla klientów.

Propozycja rozprawy doktorskiej ma na celu między innymi wykazanie, że **wyjaśnienia tekstowe i wynikające z nich wskaźniki mogą zwiększyć wydajność rekomendacji**. Oczekuje się, że formalna metodologia rozprawy zostanie zbudowana wokół silnika rekomendacji dopasowanego do potrzeb branży handlu detalicznego. Z jednej strony pozwoli ona użytkownikom zobaczyć **podsumowanie wszystkich komentarzy do danego produktu**, a wybierając fragmenty podsumowania zobaczyć część aktualnych komentarzy/recenzji. Ponadto chcemy zweryfikować możliwość **dos-tosowania narracji** do różnych użytkowników na podstawie wcześniejszej aktywności w sieci i historii zakupów. Z drugiej strony, system powinien również **sugerować asortyment najlepiej dopasowany do uwarunkowań ze strony sprzedawcy**, biorąc pod uwagę istniejące ograniczenia i zastępcze zachowania klientów, ilustrując potencjalny wpływ na uzyskiwane wyniki biznesowe.

Eksperymenty będą prowadzone na rzeczywistych danych transakcyjnych wzbogaconych o aktywność użytkowników i informacje tekstowe, które mają duży potencjał w tej dziedzinie. Chcemy ocenić wydajność modelu za pomocą takich metryk, jak $recall@k$, $precision@k$ i $average\ precision@k$ [Karypis, 2001]. Niemniej jednak celem

jest uczynienie dodatkowego kroku w kierunku wzbogacenia metodologii oceny poprzez wprowadzenie metryk hybrydowych uwzględniających część NLP potencjalnego rozwiązania. Jeśli badania wykażą, że pobieranie tekstu ma znaczący wpływ i będą dowody na istotną poprawę wydajności algorytmu, może zaistnieć potrzeba stworzenia nowej miary, opartej między innymi na technikach ewaluacji BLEU i ROUGE [Nenkova, 2006].

BIBLIOGRAPHY

1. [McAlister, Lattin, 1983] McAlister, L., & Lattin, J. M. (1983). Identifying substitute and complementary relationships revealed by consumer variety seeking behavior.
2. [Kök, Fisher, 2007] Kök, A. G., & Fisher, M. L. (2007). Demand estimation and assortment optimization under substitution: Methodology and application. *Operations Research*, 55(6), 1001-1021.
3. [McAuley et al., 2015] McAuley, J., Pandey, R., & Leskovec, J. (2015, August). Inferring networks of substitutable and complementary products. In *Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 785-794).
4. [Jones, Karen, 2007] Jones, Karen. (2007). Automatic summarising: The state of the art. *Information Processing & Management*. 43. 1449-1481. 10.1016/j.ipm.2007.03.009.
5. [Brian and Cotton, 2017] Biran, O., & Cotton, C. (2017, August). Explanation and justification in machine learning: A survey. In *IJCAI-17 workshop on explainable AI (XAI)* (Vol. 8, No. 1, pp. 8-13).
6. [Moradi, Ghadiri, 2019] Moradi, M., & Ghadiri, N. (2019). Text Summarization in the Biomedical Domain. *arXiv preprint arXiv:1908.02285*.
7. [Reeve et al., 2007] Reeve, L. H., Han, H., & Brooks, A. D. (2007). The use of domain-specific concepts in biomedical text summarization. *Information Processing & Management*, 43(6), 1765-1776.
8. [Lops et al., 2011] Lops, P., De Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In *Recommender systems handbook* (pp. 73-105). Springer, Boston, MA.
9. [Karypis, 2001] Karypis, G. (2001, October). Evaluation of item-based top-n recommendation algorithms. In *Proceedings of the tenth international conference on Information and knowledge management* (pp. 247-254).
10. [Nenkova, 2006] Nenkova, A. (2006). Summarization evaluation for text and speech: issues and approaches. In *Ninth International Conference on Spoken Language Processing*.