

Zastosowanie Sztucznej Inteligencji w optymalizacji procesu leczenia pacjenta

Proces diagnostyki oraz podejmowanego leczenia pacjenta łączy szereg podproblemów. W większości tych problemów możliwe jest nakreślenie optymalnych rozwiązań dzięki wsparciu odpowiednich modeli predykcyjnych, które na podstawie zarejestrowanych danych są w stanie wydobyć wzorce postępowania.

W przypadku prób wyznaczania optymalnej trajektorii leczenia podstawowym pytaniem jakie się nasuwa jest: co to znaczy, że mamy do czynienia z optimum? Jakie są wyznaczniki, które pozwalają w sposób kwantytatywny określić, że dana ścieżka leczenia jest lepsza niż alternatywna. W praktyce zagadnienie to można sprowadzić do szacowania funkcji ryzyka wystąpienia efektów niepożądanych danej metody leczenia. Jednocześnie, należy zauważyć iż poruszamy się w realnych warunkach, w których proces leczenia wiąże się z kosztami danej terapii. Ponieważ funkcja efektu klinicznego leczenia oraz funkcja kosztu terapii są w swojej naturze tzw. funkcjami skonfliktowanymi ze sobą - proces poszukiwania punktu optymalnego to próba uzyskania konsensusu w sensie Pareto, w którym zbiór możliwych rozwiązań tworzy tzw. front Pareta.

W planowanym wystąpieniu zostaną zaprezentowane przykłady realnych rozwiązań opartych na specyficznych mechanizmach Sztucznej Inteligencji, jakie zostały stworzone by zaadresować powyższe zagadnienia. Wśród nich przedstawione zostaną wybrane architektury sztucznych sieci neuronowych, wspierające proces diagnostyki, w szczególności model predykcji kodu DRG (ang. Diagnosis Related Group). W obszarze predykcji optymalnej ścieżki zostaną przedstawione dwa mechanizmy - klasyfikator readmisji oraz śmierci pacjenta oraz predyktor optymalnej ścieżki leczenia w ramach planowania rehabilitacji poszpitalnej (ang. Post Acute Care). Pierwszy z nich zostanie zaprezentowany także w wersji opierającej się na innowacyjnym kodowaniu danych klinicznych, wywodzącym się z idei modelowania pojęć na podstawie ich opisów w języku naturalnym. W tym przypadku modelowanie medycznych terminów jak diagnozy czy procedury medyczne pozwoliło uzyskać postać tzw. wektory osadzonych, które tworzone są głównie w odniesieniu do problemów NLP (ang. Natural Language Processing). Tak wytworzona przestrzeń spełnia własności metryczne co znalazło zastosowanie w semantycznym porównywaniu ze sobą przypadków pacjentów.

Wszystkie wspomniane modele zostały zbudowane na korpusie złożonym z ponad 150 milionów realnych epizodów leczenia pacjentów, pochodzących ze szpitali w USA. Każdy epizod był złożony z informacji o pacjencie, danych klinicznych podanych w międzynarodowym kodowaniu ICD9/ICD10 oraz danych socjo-demograficznych. Modele powyższe wraz z innymi zostały włączone jako silnik predykcyjny, będący podstawą funkcjonowania większego systemu, wdrożonego do dużej sieci szpitali w USA.

Bibliografia

1. Xu Min, Bin Yu & Fei Wang, Predictive modeling of the hospital readmission risk from patients' claims data using machine learning: a case study on COPD, (2019).
2. Łukaszuk, T., Krawczuk J., Ferenc M., Applications of vectorial representation of text medical data, *Information technology in medicine*. (2019).
3. Xiao, C., Ma, T., Dieng, A. B., Blei, D. M. & Wang, F. Readmission prediction via deep contextual embedding of clinical concepts. (2018).
4. Łukaszuk, T. and Ferenc, M., Automatic Generation of Regular Expressions for Extracting Attribute Values of Medical Products. *Studies in Logic, Grammar and Rhetoric*, 56(1), pp.193-204. (2018).
5. Krawczuk, J. and Ferenc, M., Coreference Resolution for Anaphoric Pronouns in Texts on Medical Products. *Studies in Logic, Grammar and Rhetoric*, 56(1), pp.205-216. (2018).
6. Donzé, J., Aujesky, D., Williams, D. & Schnipper, J. L. Potentially avoidable 30-day hospital readmissions in medical patients: derivation and validation of a prediction model. *JAMA internal medicine*, (2013).
7. Elixhauser, A. et al. Readmissions for chronic obstructive pulmonary disease. *Rockville, MD: Agency for Heal. Care Res. Qual.* (2011).