APLIKACE JAZYKOVÝCH MODELŮ V KLINICKÉ PRAXI

D.Novák[1], J.Prokop[1], Ch. Kang[1]

[1]katedra kybernetiky, FEL, ČVUT v Praze

ABSTRAKT

Tento článek si klade za cíl popsat možný přístup k vývoji moderního a interaktivního automatizovaného poradenského systému, který je přizpůsobený potřebám pacientů. Tento systém využívá nedávné pokroky v oblasti zpracování přirozeného jazyka což umožňuje snazší komunikaci s pacienty pomocí chatování a zároveň shromažďuje data pro vývoj samostatného terapeutického modelu založeného na NLP.

KLÍČOVÁ SLOVA

Jazykové modely, chatovací systém

ÚVOD

Použití zpracování přirozeného jazyka (NLP) bylo úspěšně aplikováno na mnoho zdravotních problémů. NLP se zabývá stále se zvyšujícím počtem různých úkolů. Značná část předešlých úspěšných aplikací se zaměřila na zpracování nestrukturovaného lékařského textu (např. anamnézy nebo závěrečných zpráv). Výhoda těchto aplikací vyplývá především z následujících skutečností. Za prvé, běžný lékařský záznam je příliš rozsáhlý, aby ho člověk mohl v omezeném čase plně pochopit. Za druhé, existuje mnoho úkolů a výzkumných otázek v lékařském oboru, jejichž řešení vyžaduje cenné informace obsažené v lékařských záznamech ve specifické formě. Za třetí, až 70 % běžného lékařského záznamu tvoří nestrukturovaný text [1]. Dva význačné příklady jsou extrakce informací a shrnutí textu. Komplexní přehled aplikací extrakce klinických informací je poskytnut ve studii [2]. Dalšími příklady jsou predikce, například predikce závažnosti příznaků z neuropsychiatrických záznamů [3] nebo problémy s užíváním léků na předpis [4], klasifikace, například klasifikace stádia rakoviny z histologických zpráv [5], analýza sociálních médií, prevalence a podobných témat v souvislosti s lékařskými otázkami [6] a zejména anonymizace. S výjimkou anonymizace spadají všechny tyto úkoly do podoblasti porozumění přirozenému jazyku (NLU). Komplexní shrnutí takových aplikací NLP v klinickém oboru poskytuje studie [7] . Mnohé z těchto aplikací jsou již dobře zavedené a existuje několik hotových softwarových platforem, například SemEHR [8] nebo cTAKES [9].

MATERIÁLY A METODY

Zpracování přirozeného jazyka je interdisciplinární obor mezi lingvistikou a informatikou, který se zaměřuje na interakci mezi počítačem a člověkem prostřednictvím přirozeného jazyka. Umělé neuronové sítě (Artificial Neural Networks - ANNs) získaly v posledních letech na popularitě díky mnoha samostatným vylepšením, která se spojila a umožnila vytvoření dobře fungujících modelů. Konkrétně uvedení transformeru [10] vedl k zlepšením v úlohách text-to-text, jako je odpovídání na otázky nebo dokonce vedení konverzace. Architektura transformeru je uvedena na obrázku 1.

DOI: 10.13164/trendybmi.2023.207

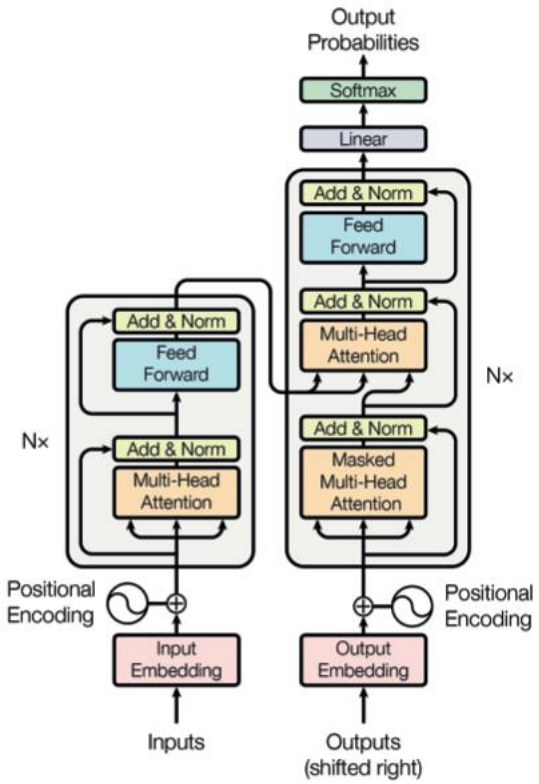

Obr. 1 Architektura transformeru, převzata z [10].

Samotná aplikace sofistikovaných modelů, jako jsou transformery, na konkrétní reálné problémy často narazí na zásadní překážku - tyto modely vyžadují významné množství dat, zatímco pro daný problém může být dostupných jen velmi málo dat. V oblasti zpracování přirozeného jazyka (NLP) lze tuto situaci částečně zmírnit pomocí přenosu znalostí (transfer learning). Hlavní myšlenkou je předtrénovat model na úlohách souvisejících s cílovou úlohou, která je obvykle označována jako úloha následného zpracování (downstream task) v této oblasti, pro kterou je dostupné mnoho trénovacích dat. Toto je zvláště užitečné v NLP díky obrovskému množství textových dat dostupných na World Wide Webu. Nedávný rozsáhlý průzkum [11] založený na modelech založených na transformerech, schopných řešit různé úlohy text-to-text, spolu s uvolněním kódu, dobře fungujících předtrénovaných modelů a velkého připraveného k použití "Colossal Clean Crawled Corpus," otevírá nové možnosti pro aplikaci NLP na nové úlohy jako je např. psychologická podpora či konzultace lékařských nálezů.

S výše uvedenými důvody pro digitální behaviorální terapii, omezeními současného "hard-coded" návrhu a nedávnými relevantními pokroky v NLP, se nabízí příležitost vytvořit konverzačního agenta založeného na transformerech. Vzhledem k tomu, že neexistují snadno dostupná data pro doladění agenta v oblasti psychologické podpory, navrhované řešení se skládá z dvou hlavních kroků. V prvním kroku model pouze navrhne odpovědi odborníkům v lidské konverzaci založené na chatu. Předběžně jsme navrhli webový systém pro sběr informací v oblasti odvykání kouření, na obrázku 2 je prezentováno grafické rozhraní. Postupně bude tuto úlohu zjednodušovat pro profesionály tím, že ušetří potřebu psaní. To umožní systému učit se na odpovědích, nebo spíše na celých konverzacích obsahujících schválené odpovědi od vyškolených odborníků. Jakmile je model dostatečně trénovaný, otestovaný a schválený, může úplně převzít úlohu a začít pomáhat ve větším měřítku.

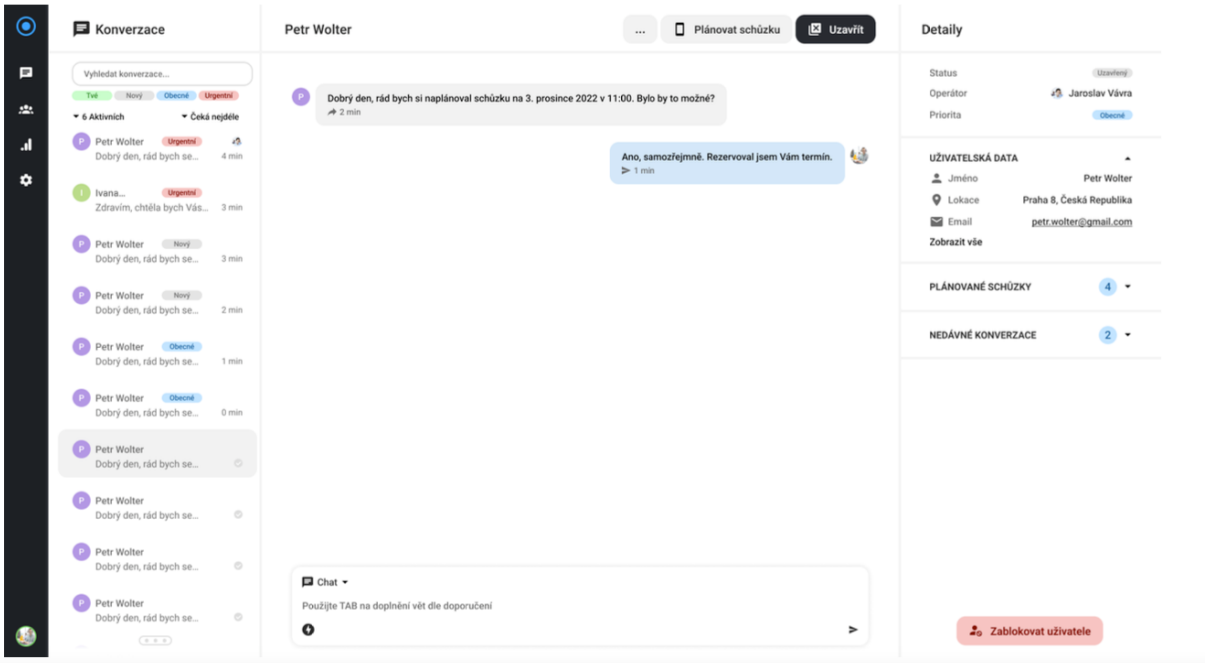

Obr 2. Návrh uživatelského rozhraní konzultací s klienty

Jediný dříve navrhovaný chatbot pro podporu kuřáků je popsaný v práci [12]. Tato studie ukázala vysokou účinnost; 28,9 % účastníků nekouřilo tři měsíce po odvykání. Přístup navržený v tomto článku se liší dvěma způsoby. Za prvé, samotný model chatbota je zásadně odlišný; chatbot použitý v [12] je stavový automat, v principu blízký přístupu stromu rozhodnutí a je tedy nutně poněkud omezený v interakcích ve srovnání s dobře fungujícím agentem založeným na umělých neuronových sítích. Druhým rozdílem je terapeutická základna. Zatímco oba programy se skládají z před-odvykací a po-odvykací fáze, první aktivně připravuje kuřáka na odvykání prostřednictvím kognitivně-behaviorálních metod terapie, zatímco druhý pouze shromažďuje data, jako je počet cigaret denně nebo návyky uživatele kouření, a používá je v po-odvykací fázi a stručně je představuje uživateli, aby zvýšil jejich motivaci. Agent založený na ANN by měl být schopen naučit se napodobit vyškoleného odborníka na závislosti a poskytnout komplexní kognitivně-behaviorální terapii pro odvykání kouření.

DISKUZE A ZÁVĚR

Navrhovaný přístup není bez problémů. Za prvé, i přes nedávné slibné výsledky v jazykových modelech by vytvoření agenta dostatečné kvality, jak je popsáno, mohlo představovat aktuálně úlohu nad rámec současných technických možností. Dosáhnutí požadované úrovně výkonu, která umožní modelu efektivně napodobit vyškoleného odborníka, by mohlo být náročný úkol. Za druhé, sběr citlivých dat nezbytných pro trénování systému není jednoduchý proces. Je nezbytné přijmout opatření, aby se zajistilo, že žádná osobní data nezůstanou uložena ani v uložených příkladech, ani v samotném umělém neuronovém modelu (ANN). Nalezení správné rovnováhy mezi anonymizací dat a schopností modelu se učit je zásadní. Etická zvažování sehrávají klíčovou roli při stanovení dostatečnosti těchto opatření a musí splňovat etické standardy, které se nyní definují na úrovni vládních a odborných institucí.

Popsali jsme návrh chatbota pro odvykání kouření založeného na umělé neuronové síti typu transformer. Jakmile by takový systém fungoval, bylo by jeho provozní náklady relativně nízké a byl by dostupný kdykoli. Kvůli nedostatku dat pro učení takových modelů je navržen dvoufázový přístup. První fáze zahrnuje odborníky na závislost, kteří poskytují lidskou konzultaci prostřednictvím chatovacího rozhraní, čímž usnadňují sběr dat. Zároveň by mohli kontrolovat, jak se systém zlepšuje na základě předchozích konverzací s každou navrhovanou odpovědí systému. To by mělo nakonec umožnit druhou fázi, ve které bude vytvořen zcela autonomní chatbot pro behaviorální terapii odvykání kouření. Na základě důkazů z předchozích výsledků z RCT [13], studie přijetí uživatelů [14] a dalších výsledků se zdá, že mít takový systém by bylo velmi žádoucí. Nové techniky zpracování přirozeného jazyka spolu s dostupností relevantního kódu, modelů a dat [11], umožňují, aby toto úsilí bylo proveditelné v technickém smyslu. Možnou nevýhodou použití plně naučeného jazykového modelu je absence schopnosti vysvětlit jeho chování. Existuje riziko, že model nebude jednat podle očekávání a nebudou jasná řešení pro odstranění problémů. Systém popsaný zde je v současné době ve stádiu vývoje.

LITERATURA

[1] Roberts, A. (2017). Language, structure, and reuse in the electronic health record. *AMA Journal of Ethics, 19* (3), 281–288. www.amajournalofethics.org

[2] Wang, Y., Wang, L., Rastegar-Mojarad, M., Moon, S., Shen, F., Afzal, N., Liu, S., Zeng, Y., Mehrabi, S., Sohn, S., & Liu, H. (2018). Clinical information extraction applications: A literature review. *Journal of Biomedical Informatics, 77,* 34–49. https://doi.org/10.1016/j.jbi.2017.11.011

[3] Filannino, M., Stubbs, A., & Uzuner, Ö. (2017). Symptom severity prediction from neuropsychiatric clinical records: Overview of 2016 CEGS N-GRID shared tasks Track 2. *Journal of Biomedical Informatics, 75,* S62–S70. https://doi.org/10.1016/j.jbi.2017.04.017

[4] Carrell, D. S., Cronkite, D., Palmer, R. E., Saunders, K., Gross, D. E., Masters, E. T., Hylan, T. R., & Von Korff, M. (2015). Using natural language processing to identify problem usage of prescription opioids. *International Journal of Medical Informatics, 84* (12), 1057–1064. https://doi.org/10.1016/j.ijmedinf.2015.09.002

[5] McCowan, I., Moore, D., & Fry, M. J. (2006). Classification of cancer stage from free-text histology reports. *Annual International Conference of the IEEE Engineering in Medicine and Biology – Proceedings,* 5153–5156. https://doi.org/10.1109/IEMBS.2006.259563

[6] Conway, M., Hu, M., & Chapman, W. W. (2019). Recent advances in using natural language processing to address public health research questions using social media and consumer-generated data. *Yearbook of Medical Informatics, 28* (1), 208–217. https://doi.org/10.1055/s-0039-1677918

[7] Velupillai, S., Suominen, H., Liakata, M., Roberts, A., Shah, A. D., Morley, K., Osborn, D., Hayes, J., Stewart, R., Downs, J., Chapman, W., & Dutta, R. (2018). Using clinical Natural Language Processing for health outcomes research: Overview and actionable suggestions for future advances. *Journal of Biomedical Informatics, 88,* 11–19. https://doi.org/10.1016/j.jbi.2018.10.005

[8] Wu, C. S., Madotto, A., Hosseini-Asl, E., Xiong, C., Socher, R., & Fung, P. (2020). Transferable multi-domain state generator for task-oriented dialogue systems. *ACL 2019 - 57th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference,* 808–819.

[9] Savova, G. K., Masanz, J. J., Ogren, P. V., Zheng, J., Sohn, S., Kipper-Schuler, K. C., & Chute, C. G. (2010). Mayo clinical Text Analysis and Knowledge Extraction System (cTAKES): Architecture, component evaluation and applications. *Journal of the American Medical Informatics Association, 17* (5), 507–513. https://doi.org/10.1136/jamia.2009.001560

[10] Vaswani, A., Brain, G., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems, Nips,* 5998–6008. http://papers.nips.cc/paper/7181-attention-is-all-you-need.pdf

[11] Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Peter, W. L., & Liu, J. (2020). Exploring the limits of transfer learning with a unified text-to-text transformer. *Journal of Machine Learning Research, 21* (140), 1–67.

[12] Calvaresi, D., Calbimonte, J. P., Dubosson, F., Najjar, A., & Schumacher, M. (2019). Social network chatbots for smoking cessation: Agent and multi-agent frameworks. *Proceedings – 2019 IEEE/WIC/ACM International Conference on Web Intelligence, WI 2019,* 286–292. https://doi.org/10.1145/3350546.3352532

[13] Kulhánek, A., Gabrhelík, R., Novák, D., Burda, V., & Brendryen, H. (2018). eHealth intervention for smoking cessation for Czech tobacco smokers: Pilot study of user acceptance. *Adiktologie, 18* (2), 81–85.

[14] Kulhánek, A., Lukavská, K., Gabrhelík, R., Prokop, J., Burda, V., Novák, D., Holter, M. T. S., & Brendryen, H. (2021). *eHealth smoking cessation intervention in less adherent smokers: A randomized controlled trial comparing text messages and e-mail reminders.* JMIR Health, 2022