

# GeoAI a tvorba kognitivní mapy

Petr Rapant<sup>1</sup>, Marek Menšík<sup>2</sup>, Adam Albert<sup>2</sup>

1 Katedra geoinformatiky, Hornicko-geologická fakulta, Vysoká škola báňská – Technická univerzita Ostrava

2 Katedra informatiky, Fakulta elektrotechniky a informatiky, Vysoká škola báňská – Technická univerzita Ostrava

[petr.rapant@vsb.cz](mailto:petr.rapant@vsb.cz), [marek.mensik@vsb.cz](mailto:marek.mensik@vsb.cz), [adam.albert@vsb.cz](mailto:adam.albert@vsb.cz)

## Abstrakt

GeoAI, neboli prostorová umělá inteligence, je nově vznikající obor, který kombinuje geovědy a metody umělé inteligence za účelem získávání poznatků, vytváření předpovědí a podporu rozhodování o prostoru. GeoAI se standardně zaměřuje na zpracování obrazových dat, jako jsou družicové a letecké snímky a data ze senzorů, např. LIDAR nebo GNSS. Zpracování nestrukturovaných textů obsahujících i prostorová data je zatím méně běžné. Cílem našeho výzkumu je naučit GeoAI vytvářet v počítači zpracováním nestrukturovaných textů obdobu kognitivní mapy, známé ze studia reprezentace prostoru v mozku člověka. Kognitivní mapa je vnitřní (mentální) reprezentací vnější reality v mozku člověka především z hlediska prostorových vztahů mezi objekty.

## 1 Kognitivní mapy a kognitivní grafy

Abychom se mohli efektivně pohybovat z místa na místo, musíme si ve své paměti vytvořit kognitivní reprezentaci prostoru kolem nás (Peer a kol., 2021), (Wang a Worboys, 2017). Této vnitřní reprezentaci našeho okolí se říká kognitivní mapa, protože hraje roli, která je podobná klasické fyzické mapě. S konceptem kognitivní mapy přišel jako první Tolman (1948). K formulování této myšlenky došel na základě studia pohybu krysy v bludišti. U kognitivní mapy se předpokládalo, že je zasezena do euklidovského prostoru, a tedy že reprezentuje kvantitativně vzdálenosti a směry zasazené do globálního referenčního rámce.

Pozdější výzkum přivedl vědce na myšlenku reprezentace prostoru prostřednictvím kognitivního grafu, protože se ukázalo, že si agenti snáze jako první osvojují právě topologické vztahy mezi prostorovými entitami. Kognitivní graf Peer a kol. (2021) definoval jako reprezentaci prostoru prostřednictvím uzlů (zastupujících místa v prostoru) a je spojujících hran (zastupujících segmenty komunikací mezi nimi). Kognitivní graf může být topologický (reprezentující pouze to, zda jsou místa vzájemně propojena či nikoli), nebo označený (reprezentující místní metrické informace, jako jsou vzdálenosti míst, směry každého

segmentu komunikace nebo úhly, které svírají komunikace incidentní s daným místem).

Abychom porozuměli vzájemnému vztahu mezi kognitivním grafem a kognitivní mapou, je důležité zvážit pořadí jejich vytváření. Existují dvě možnosti: buďto si člověk jako první vytváří kognitivní graf, nebo naopak kognitivní mapu (Peer a kol., 2021).

Z pohledu geoinformatiky se jako pravděpodobnější jeví první scénář: prostředí je zpočátku reprezentováno prostřednictvím míst a je spojujících tras a zachycuje především topologii míst situovaných v prostředí – vzniká topologický kognitivní graf. S rostoucím penzmem znalostí o prostředí, s rostoucí empirickou zkušeností získanou pohybem v něm nebo sdílením znalostí s jinými agenty je možné tuto reprezentaci dále obohacovat o informace o vzdálenostech mezi místy podél hran a o směrech mezi hranami – vznikne označený kognitivní graf. S dalším poznáváním prostředí může celkový nárůst informací o prostředí umožnit konstrukci reprezentace s globálním referenčním rámcem v podobě kognitivní mapy (Peer a kol., 2021), (Ericson a Warren, 2020).

Topologický kognitivní graf (někdy označovaný jednoduše jako graf míst (Vasardani a kol., 2013), (Chen a kol., 2018)) zachycuje síť cest spojujících místa v prostředí. Skládá se z uzlů reprezentujících místa a hran reprezentujících prostorové vztahy mezi dvojicemi míst. Topologický kognitivní graf je možné použít jak k vizualizaci, tak i k prostorovému usuzování.

Graf míst zachovává konektivitu mezi místy a jejich ordinální vztahy, ale neobsahuje žádné informace o vzdálenostech a úhlech. Jednou z výhod topologického grafu je, že je robustnější a odolnější vůči šumu a chybám než euklidovská mapa, protože topologie prostředí je zachována, i když metrické vlastnosti nejsou známy dostatečně přesně (Ericson a Warren, 2020).

Označený kognitivní graf rozšiřuje čistě topologický graf o hrubé (zpravidla kvalitativní) místní informace o vzdálenostech a úhlech (Warren a kol., 2019). To, co odlišuje označený kognitivní graf od kognitivní mapy, je to, že tyto místní informace nejsou vloženy do geometricky konzistentního globálního referenčního rámce. Zachycené prostorové znalosti tak mohou být geometricky nekonzistentní a mohou porušovat

euklidovské postuláty (Ericson a Warren, 2020), (Warren a kol., 2019).

Ať už v reálném nebo virtuálním prostoru, mít označený kognitivní graf je zásadní pro to, abychom mohli rychle a efektivně určit, kde se něco nachází a jak se tam člověk dostane (Jaeger a kol., 2023). K vytvoření označeného kognitivního grafu se velice dobře hodí verbální nebo textové popisy tras nebo prostředí (Warren a kol., 2019), (Jaeger a kol., 2023).

## 2 Texty v přirozeném jazyce jako zdroj prostorových dat pro kognitivní graf

Jednou ze základních funkcí přirozeného jazyka je sdělovat informace o prostorových vztazích mezi prostorovými entitami a o jejich relativním, případně i absolutním umístění v prostoru (Kordjamshidi a kol., 2011), (Chen a kol., 2018), (Chen a kol., 2018a). Pro vyjádření prostorových vztahů se používají různá slova nebo fráze, popisující mimo jiné konektivitu a orientaci prostorových entit. Ačkoliv tato vyjádření poskytují informace zpravidla jen o relativním umístění a relativních směrech mezi prostorovými entitami, poskytují i tak dostatek informací pro rekonstrukci prostorového kontextu a mohou tak být využita v mnoha aplikacích (Chu a kol., 2022), (Rapant a kol., 2024). To z textů v přirozeném jazyce činí zajímavý zdroj prostorových dat a informací, která mohou významně obohatit existující prostorové databáze (geoenrichment) (Yang a kol., 2022). V současné době dokonce mnohá vysoce aktuální prostorová data existují pouze ve formě nestrukturovaného textu v přirozeném jazyce, například ve formě zpravodajských článků, webových stránek, příspěvků na sociálních sítích, e-mailů, blogů, zpráv, výzkumných prací a fór Q&A, travel guides a travel logs, archivů naskenovaných historických dokumentů (Janowicz a kol., 2020), (Rawsthorne a kol., 2023), (Strötgen a Gertz, 2012) apod. Člověk čtoucí tyto texty si vytváří svoji vnitřní reprezentaci popisované lokality. Nejprve si vytváří topologický kognitivní graf, později označený kognitivní graf a v případě dostatku relevantních prostorových dat ve finále i kognitivní mapu.

Naším cílem je naučit GeoAI zpracovávat texty v přirozeném jazyce tak, aby bylo možné z extrahovaných prostorových dat vytvořit reprezentaci podobnou vnitřní reprezentaci člověka, která umožní se v reprezentovaném prostoru orientovat. Přitom předpokládáme, že vývoj této reprezentace projde obdobnou genezí, jako interní reprezentace člověka.

Jako vhodnou primární reprezentaci prostorových dat extrahovaných z textů jsme zvolili znalostní graf, který je hojně používán i v oblasti práce s prostorovými daty (Hogan, 2020), (Hogan, 2012), (Mai a kol., 2022), (Ge a kol., 2016), (Mai a Cai, 2020), (Zhang a kol., 2021), (Shbita a kol., 2023), (Ma, 2022), (Ji a kol., 2022), (Kertkeidkachorn a Ichise, 2018) a který je vhodný pro

reprezentaci topologického kognitivního grafu v počítači.

## 3 Znalostní graf

Znalostní grafy se ukázaly jako účinný způsob, jak zaznamenávat informace o reálném světě a jak integrovat informace extrahované z více zdrojů dat. Znalostní grafy také začaly hrát ústřední roli ve strojovém učení jako metoda vhodná jak pro zadávání vstupních znalostí pro potřeby učení, tak i jako cílová reprezentace extrahovaných znalostí (Chudri, 2021).

Znalostní graf je v principu orientovaný označený graf, ve kterém mají štítky přesně definovaný význam. Orientovaný označený graf se skládá z uzlů, hran a štítků. Uzly mohou reprezentovat například místa, hrany spojují dvojice uzlů a zachycují existenci vztahu mezi nimi. Ten je blíže specifikován pomocí štítku připojeného k hraně. Může to být i vztah prostorový, například vztah sousedství mezi dvěma místy apod.

Pro reprezentaci znalostních grafů v počítači se používají dva populární grafové datové modely: Resource Description Framework (RDF) a property graph (PG) (Chudri, 2021).

RDF je datový model, který byl vyvinut pro reprezentaci informací na webu. Základní jednotkou reprezentace v tomto modelu je trojice, která se skládá ze subjektu, predikátu a objektu. Množina takových trojic se nazývá graf RDF. Trojici RDF můžeme reprezentovat jako digraf uzlu-hrana-uzel.

Z jednotlivých trojic je pak možné automatizovaně zkonstruovat znalostní graf pro určitou doménu (a to i prostorovou) tak, že se ztotožní stejně označené uzly.

Datový model property graph se skládá z uzlů, vztahů a vlastností. Každý uzel má označení a sadu vlastností ve formě libovolných párů klíč-hodnota. Klíče jsou řetězce a hodnoty jsou libovolné datové typy. Vztah je orientovaná hrana mezi dvěma uzly, má popisek a může mít také přiřazenu sadu vlastností (Chudri, 2021). Oba grafové datové modely jsou použitelné i pro záznam prostorových vztahů, avšak jen těch, které jsou binární. Nás nicméně zajímají směrové prostorové vztahy, které nejsou zasazeny do společného referenčního rámce – zajímají nás kvalitativně vyjádřené relativní směry. Relativní směr je obvykle definován různými osmi sektory, ke kterým je přiřazen symbol reprezentující jeden z kvalitativních směrů (Rapant a kol., 2024). Relativní směry jsou také známy jako egocentrické.

Pro určení relativního směru používáme lokální referenční rámec [(Cohn a Renz, 2008)], který umožňuje definovat vztah mezi trojicí míst: výchozím, průchozím a cílovým. Výchozí a průchozí místo tvoří přichodzí hranu, reprezentující lokální směrový referenční rámec – definuje směr F, průchozí a cílové místo tvoří odchodzí hranu. Při určování relativního směru odchodzí hrany se postupuje tak, že se rozeta relativních směrů umístí do průchozího místa tak, aby

směr F byl shodný s aktuálním směrem příchozí hrany. Relativní směr pohybu podél odchozí hrany se pak odečte z růžice (Rapant a kol., 2024). Relativní směr odchozí hrany je tedy vyjádřen v místním referenčním rámci platném pouze pro danou trojici míst, jsou-li procházena v daném pořadí. Z toho je patrné, že relativní směr je ternární relací mezi třemi místy a je tedy datovými strukturami znalostního grafu neuchopitelný. Pro její zachycení je proto potřebná jiná datová struktura.

#### 4 Reprezentace grafu relativních směrů mezi prostorovými entitami – kvadruplet

Pro zachycení ternárního vztahu potřebujeme znát čtyři údaje: výchozí, průchozí a cílové místo, definující příchozí hranu do a odchozí hranu z průchozího místa a relativní směr odchozí hrany vzhledem k hraně příchozí. Pro její záznam jsme navrhli jednoduchou datovou strukturu – kvadruplet:

{výchozí\_místo, průchozí\_místo, cílové\_místo, relativní\_směr}

Tuto strukturu můžeme zaznamenat i graficky – viz Obr. 1:. Směr Forward je pro všechny kvadruplety stejný, proto ho explicitně neuvádíme.



**Obr. 1:** Grafická reprezentace kvadrupletu.

Odvozování kvadrupletů z nestrukturovaných textů není triviální, obecně je možné ho provádět jen na speciálním druhu textů – na tzv. narativech, systematickém popisu pohybu agenta v prostoru. Významnou vlastností narativů je jejich prostorová koherence (Menšík a kol., 2023), díky které je možné z textu extrahovat posloupnosti navštívených míst a změn směrů při cestě z místa na místo.

Pokud se nám ze zpracovaných narativů podaří sestavit kompletní sadu kvadrupletů pokrývajících určitou oblast, můžeme ji vložit do globálního směrového referenčního rámce a nakonec odvodit absolutní směry jednotlivých hran v tomto rámci. Tím můžeme naši datovou strukturu opět překlomit do podoby kognitivního grafu, v tomto případě označeného kognitivního grafu, reprezentovaného opět klasickým znalostním grafem. Kognitivní graf můžeme použít pro vizualizaci v podobě nártu popisované lokality (Rapant a kol., 2024). Ten můžeme považovat za externalizaci kognitivní mapy (Wang a Worboys, 2017).

## 5 Závěr

Z poznání kognitivních vědců vyplývá, že člověk je schopen si vytvořit vnitřní reprezentaci prostředí, ve kterém se pohybuje, nebo o kterém je informován prostřednictvím nestrukturovaných textů, ideálně narativů. Nejprve si vytváří jen reprezentaci topologie tohoto prostoru, reprezentované topologickým kognitivním grafem. Jakmile je schopen tuto úvodní reprezentaci obohatit i o prostorové vztahy mezi navštívenými místy, především o relativní směry mezi nimi, vytváří si označený kognitivní graf, který už zahrnuje prostorové vztahy mezi místy a je schopen podporovat navigaci reprezentovaným prostředím. Při obohacení této reprezentace tak, aby bylo možné relativní směry transformovat to společného směrového referenčního rámce, se označený kognitivní graf postupně přetrasformuje až do podoby kognitivní mapy.

Obdobný proces realizujeme v našem výzkumu při zpracování narativů zaznamenaných v podobě nestrukturovaných textů v přirozeném jazyku nástroji zpracování přirozeného jazyka a umělé inteligence. Nejprve vytváříme znalostní graf, který je obdobou topologického kognitivního grafu. Nad ním vytváříme pomocnou datovou strukturu, tvořeno kvadruplety, které nám umožní převést relativní směry na absolutní směry zasazené do společného směrového referenčního rámce. Díky tomu můžeme vytvořit nový znalostní graf, který je obdobou označeného kognitivního grafu, podporujícího navigaci popisovaným prostředím. V případě, že bude možné z narativů získat i data o vzdálenostech míst, bude možné označený kognitivní graf převést na obdobu kognitivní mapy – mapu zasazenou do metrického prostoru.

## Reference

- Cohn, A. G., & Renz, J. (2008). Chapter 13 Qualitative Spatial Representation and Reasoning. In *Handbook of Knowledge Representation* (pp. 551-596). Elsevier. [https://doi.org/10.1016/S1574-6526\(07\)03013-1](https://doi.org/10.1016/S1574-6526(07)03013-1)
- Ericson, J. D., & Warren, W. H. (2020). Probing the invariant structure of spatial knowledge: Support for the cognitive graph hypothesis. *Cognition*, 200. <https://doi.org/10.1016/j.cognition.2020.104276>
- Ge, T. a kol.: Visualizing and Curating Knowledge Graphs over Time and Space. 2016. <https://aclanthology.org/P16-4005/>
- Janowicz, K., Gao, S., McKenzie, G., Hu, Y., & Bhaduri, B. (2020). GeoAI: spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. *International Journal of Geographical Information Science*, 34(4),

625-636.

<https://doi.org/10.1080/13658816.2019.1684500>

Mai, G., Huang, W., Cai, L., Zhu, R., & Lao, N. (2022). Narrative Cartography with Knowledge Graphs. *Journal of Geovisualization and Spatial Analysis*, 6(1). <https://doi.org/10.1007/s41651-021-00097-4>

Hogan, A. (2020). Knowledge Graphs: Research Directions. In M. Manna & A. Pieris (Eds.), *Reasoning Web. Declarative Artificial Intelligence* (pp. 223-253). Springer International Publishing. [https://doi.org/10.1007/978-3-030-60067-9\\_8](https://doi.org/10.1007/978-3-030-60067-9_8)

Hogan, A. (2012). Knowledge Graphs: A Guided Tour <https://aidanhogan.com/docs/kg-tour.pdf>

Chaudhri, V.: Knowledge Graphs. Stanford 2021. 73 str. [https://web.stanford.edu/~vinayc/kg/notes/Table\\_Of\\_Contents.html](https://web.stanford.edu/~vinayc/kg/notes/Table_Of_Contents.html)

Chen, H., Vasardani, M., Winter, S., & Tomko, M. (2018). A Graph Database Model for Knowledge Extracted from Place Descriptions. *ISPRS International Journal of Geo-Information*, 7(6). <https://doi.org/10.3390/ijgi7060221>

Chen, H., Winter, S., & Vasardani, M. (2018a). Georeferencing places from collective human descriptions using place graphs. *Journal of Spatial Information Science*, (17), 31-62. <https://doi.org/10.5311/JOSIS.2018.17.417>

Chu, D., Wan, B., Li, H., Dong, S., Fu, J., Liu, Y., Huang, K., & Liu, H. (2022). A machine learning approach to extracting spatial information from geological texts in Chinese. *International Journal of Geographical Information Science*, 36(11), 2169-2193. <https://doi.org/10.1080/13658816.2022.2087224>

Jaeger, A. J., Weisberg, S. M., Nazareth, A., & Newcombe, N. S. (2023). Using a picture (or a thousand words) for supporting spatial knowledge of a complex virtual environment. *Cognitive Research: Principles and Implications*, 8(1). <https://doi.org/10.1186/s41235-023-00503-z>

Kertkeidkachorn, N., & Ichise, R. (2018). An Automatic Knowledge Graph Creation Framework from Natural Language Text. *IEICE Transactions on Information and Systems*, E101.D(1), 90-98. <https://doi.org/10.1587/transinf.2017SWP0006>

Shbita, B., Knoblock, C. A., Duan, W., Chiang, Y. -Y., Uhl, J. H., Leyk, S., Kirrane, S., Ngonga Ngomo, A. -C., Kirrane, S., & Ngonga Ngomo, A. -C. (2023). Building spatio-temporal knowledge graphs from

vectorized topographic historical maps. *Semantic Web*, 14(3), 527-549. <https://doi.org/10.3233/SW-222918>

Kordjamshidi, P., Van Otterlo, M., and Moens, M.F. (2011). Spatial role labeling: Towards extraction of spatial relations from natural language. *ACM Trans. Speech Lang. Process.* 8, 3, Article 4 (December 2011), 36 pages. <https://doi.org/10.1145/2050104.2050105> <https://dl.acm.org/doi/10.1145/2050104.2050105>

Ma, X. (2022). Knowledge graph construction and application in geosciences: A review. *Computers & Geosciences*, 161. <https://doi.org/10.1016/j.cageo.2022.105082>

Mai, G., Cai, L.: Knowledge Graphs and Spatiotemporal Data. STKO Lab, OKN Vocamp, Jan. 2020, University of California Santa Barbara <https://gengchenmai.github.io/presentations/2020-NSF-OKN-VoCamp.pdf>

Menšík, M., Rapant, P., and Albert, A., 2023a. Algorithm outline for sketch map drawing from spatial data distilled from natural language descriptions. In: *Proceedings of the 33rd International Conference on Information Modelling and Knowledge Bases, EJC 2023*, Maribor. University of Maribor Press, 317–331. Available from: <https://books.google.cz/books?id=wWwr0AEACAAJ>

Peer, M., Brunec, I. K., Newcombe, N. S., & Epstein, R. A. (2021). Structuring Knowledge with Cognitive Maps and Cognitive Graphs. *Trends in Cognitive Sciences*, 25(1), 37-54. <https://doi.org/10.1016/j.tics.2020.10.004>

Rapant, P., Menšík, M., & Albert, A. Automatic sketch map creation from labeled planar graph. *International Journal of Geographical Information Science*, 1-26. <https://doi.org/10.1080/13658816.2024.2330064>

Rawsthorne, H. M., Abadie, N., Kergosien, E., Duchêne, C., & Saux, É. (2023). Automatic Nested Spatial Entity and Spatial Relation Extraction From Text for Knowledge Graph Creation. In *Proceedings of the 7th ACM SIGSPATIAL International Workshop on Geospatial Humanities* (pp. 21-30). ACM. <https://doi.org/10.1145/3615887.3627754>

Ji, S., Pan, S., Cambria, E., Marttinen, P., & Yu, P. S. (2022). A Survey on Knowledge Graphs: Representation, Acquisition, and Applications. *IEEE Transactions on Neural Networks and Learning Systems*, 33(2), 494-514. <https://doi.org/10.1109/TNNLS.2021.3070843>

- Strötgen, J., & Gertz, M. (2012). Event-centric search and exploration in document collections. In *Proceedings of the 12th ACM/IEEE-CS joint conference on Digital Libraries* (pp. 223-232). ACM. <https://doi.org/10.1145/2232817.2232859>
- Tolman, E. C. (1948). Cognitive maps in rats and men. *Psychological Review*, 55(4), 189-208. <https://doi.org/10.1037/h0061626>
- Vasardani, M., Timpf, S., Winter, S., Tomko, M. (2013). From Descriptions to Depictions: A Conceptual Framework. In: Tenbrink, T., Stell, J., Galton, A., Wood, Z. (eds) *Spatial Information Theory. COSIT 2013. Lecture Notes in Computer Science*, vol 8116. Springer, Cham. [https://doi.org/10.1007/978-3-319-01790-7\\_17](https://doi.org/10.1007/978-3-319-01790-7_17)
- Wang, J., & Worboys, M. (2017). Ontologies and representation spaces for sketch map interpretation. *International Journal of Geographical Information Science*, 31(9), 1697-1721. <https://doi.org/10.1080/13658816.2017.1309043>
- Warren, W. H., el Jundi, B., Kelber, A., & Webb, B. (2019). Non-Euclidean navigation. *Journal of Experimental Biology*, 222(Suppl\_1). <https://doi.org/10.1242/jeb.187971>
- Yang, J., Jia, H., & Liu, H. (2022). Spatial Relationship Extraction of Geographic Entities Based on BERT Model. *Journal of Physics: Conference Series*, 2363(1). <https://doi.org/10.1088/1742-6596/2363/1/012031>
- Zhang, Z., Wang, Z., Li, A., Ye, X., Usery, E. L., & Li, D. (2021). An AI-based Spatial Knowledge Graph for Enhancing Spatial Data and Knowledge Search and Discovery. In *Proceedings of the 1st ACM SIGSPATIAL International Workshop on Searching and Mining Large Collections of Geospatial Data* (pp. 13-17). ACM. <https://doi.org/10.1145/3486640.3491393>