

Prema vlastitom izboru skrećem pozornost čitateljima Geodetskog lista na nekoliko članaka objavljenih od 2010. do danas.

- M. Rajner, T. Liwosz: Studies of crustal deformation due to hydrological loading on GPS height estimates, 2011, No 2.
- M. Ligas, P. Banasik: Conversion between Cartesian and geodetic coordinates on a rotational ellipsoid by solving a system of nonlinear equations, 2011, No 2.
- Ł. Halik: The analysis of visual variables for use in the cartographic design of point symbols for mobile Augmented Reality applications, 2012, No 1.
- B. Medyńska-Gulij, M. Myszczyk: The geovisualisation window of the temporal and spatial variability for Volunteered Geographic Information activities, 2012, No 1.
- K. Marcin: Registration of untypical 3D objects in Polish cadastre – do we need 3D cadastre? 2012, No 2.
- P. Pędzich, M. Kuźma: Application of methods for area calculation of geodesic polygons on Polish administrative units, 2012, No 2.
- L. Pietrzak, A. Hopfer, S. Cegielski: Reforms of a real estate cadastre in Poland, 2012, No 2.
- P. Hanus: Correction of location of boundaries in cadastre modernization process, 2013, No 1.
- A. Trembecka: Analysis of geodetic and legal documentation in the process of expropriation for roads. Krakow case study, 2013, No 1.
- P. Deliś, M. Kędzierski, A. Fryśkowska, M. Wilińska: 3D modeling of architectural objects from video data obtained with the fixed focal length lens geometry, 2013, No 2.
- B. Medyńska-Gulij: Cartographic sign as a core of multimedia map prepared by non-cartographers in free map services, 2014, No 1.
- M. Ligas, M. Kulczycki: Kriging approach for local height transformations, 2014, No 1.
- Z. Parzyński: A new concept for creating the basic map, 2014, No 2.
- P. Wężyk1, M. Szostak, W. Krzaklewski, M. Pająk, M. Pierzchalski, P. Szwed, P. Hawryło, M. Ratajczak: Landscape monitoring of post-industrial areas using LiDAR and GIS technology, 2015, No 1.
- T. Kogut1, J. Niemeyer, A. Bujakiewicz: Neural networks for the generation of sea bed models using airborne lidar bathymetry data, 2016, No 1.
- B. Calka, B. Cahan: Interactive map of refugee movement in Europe, 2016, No 2.
- A. Bolesław Łyszczkiewicz, A. Bernatowicz: Current state of art of satellite altimetry, 2017, No 2.
- M. Poutanen, P. Häkli: Future of National Reference Frames – from static to kinematic? 2018, No 1.
- T. Horbinski, P. Cybulski: Similarities of global web mapping services functionality in the context of responsive web design, 2018, No 2.
- Korisno je znati da pod istim naslovom *Geodesy and Cartography* izlazi i litavski geodetsko-kartografski časopis.

Nedjeljko Frančula

KARTOGRAFIJA I UMJETNA INTELIGENCIJA

Prema Hrvatskoj enciklopediji (2019a) umjetna inteligencija (UI, prema engl. akronimu AI, od *Artificial Intelligence*), dio je računalne znanosti (informatike) koji se bavi razvojem sposobnosti računala da obavljaju zadaće za koje je potreban neki oblik inteligencije, tj. da se mogu snalaziti u novim prilikama, učiti nove koncepte, donositi zaključke, razumjeti prirodni jezik, raspoznavati prizore i dr. Iz Hrvatske enciklopedije preuzeli smo i definicije

ekspertnih sustava i neuronske mreže. Ekspertni sustavi (lat. *expertus*: iskusan, prokušan), računalni su programi iz područja umjetne inteligencije, namijenjeni rješavanju složenih problema uskog područja za koje su specijalizirani (Hrvatska enciklopedija 2019b). Neuronska mreža, u računalstvu i informatici, sustav međusobno povezanih elemenata (nazvanih *umjetni neuroni*) koji služi za raznovrsna izračunavanja, zasnovan na pokušaju oponašanja rada ljudskog mozga (Hrvatska enciklopedija 2019c).

Zanimalo nas je u kojoj se mjeri umjetna inteligencija, ekspertni sustavi i neuronske mreže već primjenjuju u kartografiji. Poslužili smo se *Google Scholarom*, tj. njegovom mogućnošću naprednog pretraživanja. Detaljnije istraživanje napraviti ćemo pretražujući literaturu na engleskom jeziku. Upiše li se u polje *with all* of the words: cartography artificial intelligence dobiva se 40 500 naslova. Da bismo ustanovili u kojim je to područjima kartografije umjetna inteligencija najviše zastupljena, upisat ćemo u polje *with the exact phrase* odgovarajuću kartografsku sintagmu, a u polje *with all* of the words: artificial intelligence. Pretraživanje je obavljeno 13.–21. kolovoza 2019., a rezultati su upisani u tablicu 1. Brojevi u toj tablici približni su brojevi radova u kojima se pojavljuju navedeni termini jer se riječi *artificial* i *intelligence* ne pojavljuju samo u sintagmi *artificial intelligence* već i svaka od njih zasebno u nekom drugom mogućem kontekstu.

Tablica 1. Zastupljenost umjetne inteligencije u kartografiji.

<i>with the exact phrase</i>	<i>with all</i> of the words	Broj radova
automated cartography	artificial intelligence	5830
digital cartography	artificial intelligence	876
computer cartography	artificial intelligence	604
map projection	artificial intelligence	1750
map generalization	artificial intelligence	1240
map generalisation	artificial intelligence	459
cartographic generalization	artificial intelligence	1100
cartographic generalisation	artificial intelligence	280
thematic cartography	artificial intelligence	621
cartographic design	artificial intelligence	609
name placement	artificial intelligence	295
map labeling	artificial intelligence	536
intelligent map	artificial intelligence	198
intelligent mapping	artificial intelligence	310
smart map	artificial intelligence	186
smart mapping	artificial intelligence	73

Budući da je umjetna inteligencija po definiciji dio računalne znanosti, logično je da je najzastupljenija u onima kartografskim tekstovima koji se bave automatizacijom u kartografiji, tj. digitalnom ili kompjutorskom kartografijom – ukupno u 7310 takvih tekstova.

U nastojanju da se izrada karata što više automatizira najveći su problem kartografska generalizacija (Jones i Ware 2005) i smještaj geografskih imena na karti pa i tu umjetna inteligencija omogućuje određena rješenja. Za kartografsku generalizaciju na engleskom jeziku rabe se sintagme: map generalization, map generalisation, cartographic generalization i cartographic generalisation. U tablici 1 zabilježeno je ukupno 3079 naslova. Rješenja za automatizaciju kartografske generalizacije traže se u izradi ekspertnih sustava (Kazemi i dr. 2005). U tu je svrhu potrebno prikupiti znanja kartografskih eksperata i izraditi pravila za

automatsku generalizaciju (Buttenfield i McMaster 1991). U posljednje vrijeme učinjen je znatan napredak prema potpuno automatskoj generalizaciji (Stoter i dr. 2014).

Yoeli (1972) je prvi ukazao na mogućnost automatskog smještaja imena na karti. Jonson i Basoglu (1989) zorno su pokazali kako se ekspertni sustav i neuronska mreža mogu kombinirati u pokušaju automatiziranog smještaja geografskih imena na karti. Kakoulis i Tollis (2018) ističu da smještaj geografskih imena na karti još uvijek nije potpuno automatiziran. Popis literature sadrži 104 naslova. Chirié (2000) izvještava o rezultatima automatskog smještaja imena ulica pomoću programa PANR. Na jednoj karti od 8300 imena program je na kartu smjestio njih 7600 (91,5%) od kojih smještaj 250 (3%) imena nije bio zadovoljavajući, što znači da je 88,5% imena uspješno smješteno.

Umjetna inteligencija ima važnu primjenu i na području kartografskih projekcija. Potvrđuje to i 1750 naslova u tablici 1. Za izradu matematičke osnove neke karte u velikom broju kartografskih projekcija postoje danas gotovi programi pa i slobodno dostupni na internetu. Stoga je najveći problem na tom području izbor najpovoljnije projekcije za kartu određenog područja i određene namjene. U tu je svrhu nedavno objavljena monografija koju su uredili Lapaine i Usery (2017). Korisniku taj zadatak najviše mogu olakšati ekspertni sustavi izrađeni za tu namjenu (Hu i dr. 2007).

Danas, kada karte izrađuju mnogi koji nemaju potrebna kartografska znanja, postoji potreba za ekspertnim sustavima posebno za izradu tematskih karata koji bi i nekartografima omogućili izradu korektnih karata (Brus i dr. 2009).

Forest (1999) ističe da se karte sve češće izrađuju s pomoću gotovih programa za kartografiranje i GIS. Takvim programima služe se i korisnici koji nisu upoznati s načelima kartografskog oblikovanja (*cartographic design*). Da bi se pomoglo u izradi zadovoljavajućih karata, ključno je da se u takve sustave ugradi kartografsko znanje. Stoga autor daje sveobuhvatnu funkcionalnu specifikaciju za ekspertni sustav kartografskog oblikovanja. Specifikacija pokriva širok raspon kartografskih tema i metoda kartografskog prikaza, ali se usredotočuje na karte u rasponu mjerila 1 : 2 000 000 do 1 : 15 000 000.

Nivala i Sarjakoski (2003) navode da korisnici karata na mobilnim uređajima trebaju razne vrste karata u različitim situacijama, tj. pravu vrstu karte odgovarajućeg mjerila sa znakovima prilagođenim upotrebnoj situaciji. Autorice u radu opisuju neke situacije koje mogu poslužiti za izradu budućih inteligentnih (pametnih) karata za mobilne uređaje. Inteligentna karta treba biti u stanju prepoznati kontekst (lokacija, korisnikovi interesi, vrijeme – npr. ljeto ili zima, okoliš) i dati korisniku odgovarajuće informacije u ispravnom formatu.

I u hrvatskom stručnom tisku postoji određeni broj radova posvećenih primjeni umjetne inteligencije u kartografiji. Upiše li se u polje *with all* of the words: kartografija umjetna inteligencija dobiva se 133 naslova. Šapina (2016) izvještava o rezultatima uspješno primijenjene metode umjetnih neuronskih mreža u kartiranju ležišta ugljikovodika. Grgić i Vučetić (2012) pišu o primjeni sustava višestrukih agenata, tj. sustava koji primjenjuju elemente umjetne inteligencije, u kartografskoj generalizaciji. Župan i Frangeš (2012) ukazuju na uobičajene pogreške pri prikazivanju toponima na web-kartama i predlažu moguća rješenja.

Literatura

- Brus, J., Dobešová, Z., Kačok, J. (2009): Utilization of expert systems in thematic cartography, International Conference on Intelligent Networking and Collaborative Systems, Barcelona, 31. 12. 2009, 112–117, doi: 10.1109/INCOS.2009.56, (21. 8. 2019.).
- Buttenfield, B. P., McMaster, R. B. (Eds.) (1991): Map generalization: Making rules for knowledge representation, Longman Group UK, http://portal.survey.ntua.gr/main/courses/geoinfo/admcarto/lecture_notes/cartographic_line/bibliography/buttenfield_1991.pdf, (16. 8. 2019.).

- Chirié, F. (2000): Automated Name Placement with High Cartographic Quality: City Street Maps, *Cartography and Geographic Information Science*, 27, 2, 101–110, <https://doi.org/10.1559/152304000783547902>, (18. 8. 2019.).
- Forest, D. (1999): Developing rules for map design: a functional specification for a cartographic-design expert system, *Cartographica*, 36, 3, (Fall 1999), 31–52, <https://doi.org/10.3138/9505-7822-0066-70W5>, (20. 8. 2019.).
- Grgić, M., Vučetić, N. (2012): Sustavi višestrukih agenata u kartografskoj generalizaciji, *Ekscentar*, br. 15, 100–103, <https://hrcak.srce.hr/81662>, (19. 8. 2019.).
- Hrvatska enciklopedija (2019a): Umjetna inteligencija, <http://www.enciklopedija.hr/natuknica.aspx?ID=63150>, (13. 8. 2019.).
- Hrvatska enciklopedija (2019b): Ekspertni sustavi, <http://www.enciklopedija.hr/natuknica.aspx?id=17426>, (14. 8. 2019.).
- Hrvatska enciklopedija (2019c): Neuronska mreža, <http://www.enciklopedija.hr/natuknica.aspx?ID=43562>, (16. 8. 2019.).
- Hu, Z., Zhu, H., Li, L., Xing, Y. (2007): COM-based expert system for map projection selection, In: 480 Li, M., Wang, J. (eds), *Geoinformatics 2007: cartographic theory and models*, Proceedings of the 481 SPIE, Vol. 6751, doi:10.1117/12.759722, (15. 8. 2019.).
- Jones, C. B., Ware, J. M. (2005): Map generalization in the Web age, *International Journal of Geographical Information Science*, 19, 8–9, 859–870, <https://doi.org/10.1080/13658810500161104>, (16. 8. 2019.).
- Jonson, D. S., Basoglu, U. (1989): The use of artificial intelligence in the automated placement of cartographic names, *Auto-Carto 9*, American Congress on Surveying and Mapping, Bethesda, Maryland, 225–230, <https://pdfs.semanticscholar.org/4331/1f55d012a65b2ad7b3ad51c597aff746ddc2.pdf>, (20. 8. 2019.).
- Kakoulis, K. G., Tollis, I. G. (2018): Automatic Placement of Labels in Maps and Drawings, In: *Handbook of Approximation Algorithms and Metaheuristics*, Second Edition, Contemporary and Emerging Applications, Vol. 2, ed. by T. F. Gonzales, Taylor & Francis, ch. 7. (Google Books).
- Kazemi, S., Lim, S., Ge, I. (2005): Integration of Cartographic Knowledge with Generalization Algorithms, Proceedings, 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005, IGARSS '05, 3502–3505, doi: 10.1109/IGARSS.2005.1526600, (16. 8. 2019.).
- Lapaine, M., Usery, E. L. (Eds.) (2017): *Choosing a Map Projection*, Springer, <https://link.springer.com/book/10.1007/978-3-319-51835-0>, (15. 8. 2019.).
- Nivala, A.-M., Sarjakoski, L. T. (2003): An Approach to Intelligent Maps: Context Awareness, In: *The 2nd Workshop on 'HCI in Mobile Guides'*, in adjunction to: MobileHCI'03, 5th International Conference on Human Computer Interaction with Mobile Devices and Services, September 8th, 2003, Udine, Italy.
- Stoter, J., Post, M., van Altena, V., Nijhuis, R., Bruns, B. (2014): Fully automated generalization of a 1 : 50k map from 1 : 1 10k data, *Cartography and Geographic Information Science*, 41, 1, 1–13, <https://doi.org/10.1080/15230406.2013.824637>, (16. 8. 2019.).
- Šapina, M. (2016): Primjena umjetnih neuronskih mreža u kartiranju ležišta ugljikovodika, primjer EK markera Rs5 u Bjelovarskoj subdepresiji, *Matematičke metode i nazivlje u geologiji*, I. hrvatski znanstveni skup iz geomatematike i nazivlja u geologiji, Rudarsko-geološko-naftni fakultet, Zagreb, 29. 10. 2016., *Zbornik radova*, 21–27, <https://bib.irb.hr/datoteka/837542.Binder4.pdf#page=33>, (19. 8. 2019.).
- Yoeli, P. (1972): The logic of automated map lettering, *The Cartographic Journal*, 2, 99–108.
- Župan, R., Frangeš, S. (2012): Today's Common Errors for Display Toponyms on Web Maps and Solutions, *Geodetski list*, 3, 197–208, <https://hrcak.srce.hr/95830>, (19. 8. 2019.).