

# UMETNA INTELIGENCA ALI UMETNA INTELIGENTNOST: KJE SMO IN KAM GREMO

ANDREJ KASTRIN

Univerza v Ljubljani, Medicinska fakulteta, Inštitut za biostatistiko in medicinsko informatiko, Ljubljana, Slovenija.  
E-pošta: andrej.kastrin@mf.uni-lj.si

**Povzetek** Zdi se, da kljub nedorečeni definiciji področja, o umetni inteligentnosti (UI) danes vsi vse vemo. V ožjem, raziskovalnem smislu, se UI povezuje tako z razvojem novih računskih metod kot njihovo uporabo v praksi. V prispevku poročamo o rezultatih analize bibliografskih zapisov s področja UI od leta 2000 do danes. Predstavimo konstrukcijo omrežja sopojavnosti ključnih besed v času in analiziramo tematike, s katerimi so se ukvarjali raziskovalci v preteklih dveh desetletjih.

**Ključne besede:**

umetna  
inteligentnost,  
analiza  
sopojavnosti,  
tematski  
diagram,  
iMetrika,  
zbirka  
WoS

# SCIENCE MAPPING OF THE KNOWLEDGE BASE ON ARTIFICIAL INTELLIGENCE

ANDREJ KASTRIN

University of Ljubljana, Faculty of Medicine, Institute of Biostatistics and Medical Informatics, Ljubljana, Slovenia.  
E-mail: andrej.kastrin@mf.uni-lj.si

**Keywords:**


artificial  
intelligence,  
cword  
analysis,  
thematic  
diagram,  
iMetrics,  
WoS  
database

**Abstract** It seems that despite the vague definition of artificial intelligence (AI), we are all now top experts in the field. In a narrow sense, AI refers to the development of new computational methods and their application in practice. In this paper, we report the results of an analysis of bibliographic records in the field of AI from 2000 to the present. We present the construction of a keyword co-occurrence network over time and analyze the topics that researchers have worked on over the last two decades.

## 1 Uvod

Z umetno inteligentnostjo se danes srečujemo že praktično na vsakem koraku. Domuje ne le v znanosti in industriji, temveč na tak ali drugačen način kroji življenje slehernega posameznika. V znanosti praktično ne najdemo področja, ki k sodobnemu pojmovanju umetne inteligentnosti ni pristavilo vsaj kančka svojstvenosti.

Površen vpogled v količino in hitrost pridobivanja znanstvenega védenja nam običajno nudi že hiter sprehod po eni od splošnonamenskih bibliografskih zbirk. Za ilustracijo obsega znanja na področju umetne inteligentnosti je na sliki 1 prikazana rast št. bibliografskih zapisov povezanih s predmetno oznako *Artificial Intelligence*. Prikaz je narejen ločeno za zbirki Scopus in Web of Science (WoS). Denimo, da zanemarimo sicer pomembno razliko v št. publikacij med zbirkama in opazujemo le hitrost naraščanje publikacij v času. Brez zadržkov bomo hitro prišli do zaključka, da je rast literature v zadnjih treh desetletjih enormna.



Slika 1: Rast št. bibliografskih zapisov povezanih s tematiko umetne inteligentnosti v zbirkah Scopus in Web of Science

Vir: lasten

Redno sledenje novim objavam je na tako obsežnem in kompleksnem področju kot je umetna inteligenca, praktično nemogoče. Empirična evidenca pa opozarja, da je vsaj površinsko poznavanje ustroja znanstvenega védenja *conditio sine qua non* za “dobre” raziskovalne dosežke in nove ustvarjalne preboje na področju umetne

inteligentnosti (Chen, 2011). Priročen instrumentarij, ki nam pri iskanju in razumevanju skritih zakonitosti v bibliografskih podatkih lahko pomaga, najdemo v ti. znanosti o znanosti (angl. *Science of Science*).

Za znanost o znanosti—v nadaljevanju bomo uporabljali kratico SciSci—lahko rečemo, da ima dolgo preteklost, a kratko zgodovino. V zadnjih letih je področje, predvsem zaradi uspešnega interdisciplinarnega sodelovanja glavnih akterjev (med katerimi najdemo tudi zveneča imena kot je npr. Albert-László Barabási), dobilo nov raziskovalni zagon (Wang & Barabási, 2021). V prvi vrsti se to odraža v objavah v eminentnih znanstvenih časopisih; revija *Science* pa je predstavitvi discipline nedavno namenila celo številko (glej npr. Fortunato in sod., 2018). Kvantitativni metodološki aparat SciSci s pridom črpa s področij bibliometrike in scientometrike.<sup>1</sup>

Na področju SciSci ločimo med pristopi za ocenjevanje uspešnosti raziskovalnih entitet (npr. raziskovalcev, raziskovalnih skupin) in pristopi, ki omogočajo vpogled v strukturo in dinamiko razvoja znanja na izbranem znanstvenem področju. Med zadnjimi najpogosteje srečamo ti. kartiranje znanosti (Small, 2006), analizo socitiranosti dokumentov (Small, 1973) in analizo sopojavnosti (ključnih) besed oz. terminov (Callon in sod., 1991). Nekateri od teh so bili s pridom uporabljeni tudi za pregled znanstvenega védenja na področju umetne inteligentnosti (Alonso in sod., 2018; Darko in sod., 2020; Yu in sod., 2019).

Namen prispevka je dvojen:<sup>2</sup> (i) z analizo sopojavnosti ključnih besed v znanstveni literaturi želimo predstaviti dinamiko razvoja področja umetne inteligentnosti v svetu in (ii) bralcu želimo nakazati pomen in pomembnost metodologije SciSci za spremljanje in načrtovanje uspešne raziskovalne poti.

---

<sup>1</sup> Poleg obeh naštetih je moč v literaturi zaslediti še poimenovanja kot so npr. informetrika, webometrika, almetrika, zato Milojević in Leydesdorff (2013) predlagata uporabo krovne skovanke iMetrika, s katero zajamemo pisano paleto postopkov in metod, ki so bile razvite pod okriljem različnih pristopov k proučevanju znanosti.

<sup>2</sup> V okviru predavanja bomo problematiko razvoja umetne inteligentnosti naslovili širše in osvetlili tudi dosežke domače raziskovalne skupnosti.

## 2 Metode

### 2.1 Pridobivanje podatkov

Raziskovalec ima danes na voljo pisano paleto bibliografskih zbirk, ki se med seboj razlikujejo ne samo po namembnosti in obsegu indeksiranih publikacij, pač pa tudi po kvaliteti vnešenih bibliografskih zapisov in predvsem ceni dostopa. Zbirkam WoS, Scopus in PubMed so se v preteklem desetletju pridružile prostodostopne alternative, med katerimi velja izpostaviti zlasti zbirke Dimensions, OpenCitations, Semantic Scholar in OpenAlex. Sami smo podatke pripravili na osnovi zbirke WoS, ki po naših izkušnjah zagotavlja optimalno razmerje med kvaliteto bibliografskih zapisov in obsegov vključenih publikacij. Podatke smo zajeli 1. februarja 2022, pri priklicu pa smo se omejili na zapise objavljene v angleškem jeziku in uvrščene v kategorijo *Computer Science, Artificial Intelligence*.<sup>3</sup>

V zbirki WoS smo prešteli 747.018 zapisov z oznako *Computer Science, Artificial Intelligence*, med katerimi je bilo 742.376 (99 %) publikacij v angleškem jeziku. V nadaljevanju smo izdvojili samo zapise za publikacije objavljene v obdobju 2000–2020. Za potrebe identifikacije tematik v času smo 20-letno obdobje še dodatno razbili v štiri manjša obdobja, v vsakem razbitju pa upoštevali samo prvih 2000 zapisov z najvišjim št. citatov.

### 2.2 Omrežje sopojavnosti ključnih besed

Iz vsakega zapisa smo izluščili ključne besede, ki so jih pripravili avtorji (polje DE v zapisu WoS) in jih po potrebi normalizirali. Upoštevali smo samo ključne besede, ki se pojavijo v najmanj petih bibliografskih zapisih. Zaradi preglednosti prikazov smo upoštevali le prvih 250 najpogosteje zastopanih ključnih besed. Ta delovni korak smo zaključili s pripravo štirih matrik sopojavnosti ključnih besed (ena matrika za vsako od štirih časovnih rezin) razsežnosti  $250 \times 250$ .

Matriko sopojavnosti lahko predstavimo kot neusmerjeno uteženo omrežje, v katerem posamezno vozlišče označuje eno od 250 izdvojenih ključnih besed, povezave med vozlišči pa vzpostavi sopojavnost parov ključnih besed v bibliografskem zapisu. Utež na povezavi predstavlja št. sopojavitev izbranega para

---

<sup>3</sup> Zbirka WoS vsakemu bibliografskemu zapisu pripiše eno ali več predmetnih oznak (angl. *Subject Category*). WoS trenutno obsega 252 predmetnih oznak s področij naravoslovja, družboslovja, humanistike, tehnike in umetnosti.

ključnih besed preko vseh zapisov. Surove frekvence sopoavnosti smo normalizirali po obrazcu (Van Eck & Waltman, 2007):

$$a_{ij} = \frac{mc_{ij}}{c_{ii}c_{jj}} \quad \forall i \neq j,$$

kjer je  $c_{ij}$  št. zapisov, v katerih se sopojavita ključni besedi  $i$  in  $j$ ,  $c_{ii}$  št. zapisov v katerih se pojavi ključna beseda  $i$ ,  $m$  pa celotno št. zapisov v izbrani časovni rezini.

### 2.3 Omrežje sopoavnosti ključnih besed

Za identifikacijo raziskovalnih tematik v omrežju smo uporabili Louvainov algoritem gručenja v skupine oz. skupnosti (Blondel in sod., 2008). Algoritem temelji na optimizaciji kriterijske funkcije (ti. modularnosti), s katero merimo razmerje med gostoto povezav znotraj izbrane skupnosti in gostoto povezav zunaj skupnosti. V vsakem od štirih omrežij smo nato izluščili skupnosti vozlišč, za nadaljnjo analizo pa obdržali le tiste, pri katerih je modularnost znašala vsaj 0,7 (tj. skupnosti, ki so močno homogene, hkrati pa zelo heterogene med seboj).

### 2.4 Tematski diagram

Tematski diagram prikazuje porazdelitev izluščenih skupnosti ključnih besed v ravnini, ki jo opišemo s središčnostjo (angl. *centrality*) in gostoto (angl. *density*) (Callon in sod., 1991). S središčnostjo merimo stopnjo izbrane skupnosti (tj. št. sosednjih skupnosti). Višja kot je središčnost skupnosti, močnejša je aktivnost raziskovalne tematike (in njena interdisciplinarna vpetost), ki jo skupnost zrcali. Središčnost izračunamo po obrazcu:

$$c_L = \sum_{i \in L} \sum_{j \in M} w_{ij} \times e_{ij},$$

kjer je  $i$  izbrano vozlišče v skupnosti  $L$ ,  $M$  množica preostalih skupnosti,  $j$  pa kazalec na izbrano vozlišče v  $M$ . Utež na povezavi med vozliščema  $i$  in  $j$  označimo z  $w_{ij}$ . Indikatorska spremenljivka  $e_{ij}$  ob povezavi vozlišč  $i$  in  $j$  zavzame vrednost 1 in 0 sicer. Z gostoto nasprotno merimo homogenost posamezne skupnosti. Izrazimo jo kot

razmerje med dejanskim ter največjim možnim št. povezav v skupnosti in jo izračunamo po obrazcu:

$$D_L = \frac{2E}{N(N-1)},$$

kjer je  $E$  št. povezav in  $N$  št. vozlišč v skupnosti  $L$ . Gostota skupnosti odraža razvojni potencial raziskovalne tematike.

Glede na porazdelitev središčnosti in gostote lahko vsako od identificiranih tematik uvrstimo v enega od štirih kvadrantov pravokotnega koordinatnega sistema:

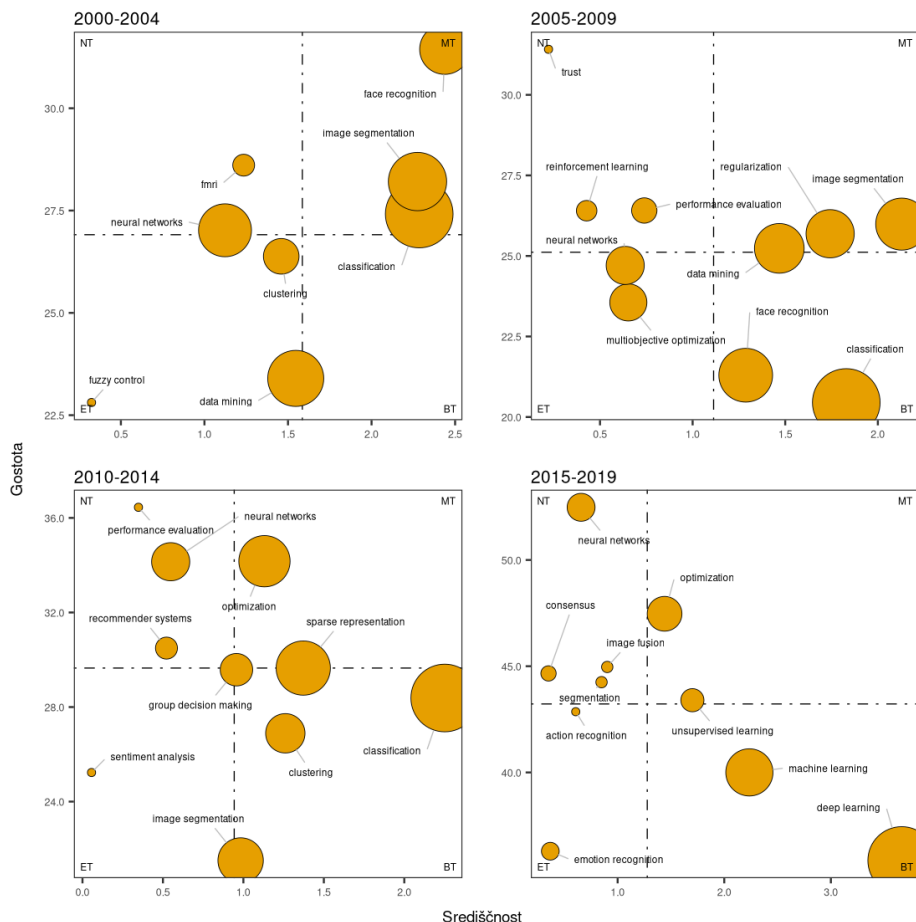
- (I) Skupnosti z močno izraženo središčnostjo in gostoto, ki odražajo pomembne in dobro razvite raziskovalne tematike;
- (II) Skupnosti s šibko izraženo središčnostjo in močno izraženo gostoto, ki zrcalijo sicer dobro razvite raziskovalne tematike, a brez povezanosti z ostalimi področji;
- (III) Skupnosti s šibko izraženo središčnostjo in gostoto odražajo obrobne in slabo razvite raziskovalne tematike, ki so bodisi že v zatonu bodisi se v znanstveni skupnosti šele porajajo;
- (IV) Skupnosti z močno izraženo središčnostjo, a šibko gostoto, ki so za izbrano raziskovalno področje sicer pomembne, nimajo pa razvojnega zagona.

## 2.5 Ponovljivost rezultatov

Programska koda, ki omogoča reprodukcijo predstavljenih rezultatov, je prostodostopna v avtorjevem podatkovnem prostoru na spletišču GitHub: <https://github.com/akastrin/rosus-2022>.

## 3 Rezultati in razprava

Na sliki 2 je prikazana semantična ravnina, ki jo razpenjata središčnost in gostota, definirana zgoraj v razdelku 2.4. Za vsako od štirih časovnih rezin v obdobju 2000–2020 je na prikazu predstavljena porazdelitev identificiranih skupnosti oz. raziskovalnih tematik, ki jih te zrcalijo. V nadaljevanju sledi kratek vsebinski pregled raziskovalnih tematik v posameznih časovnih rezinah.



**Slika 2: Tematski diagrami z identificiranimi raziskovalnimi tematikami s področja umetne inteligentnosti v obdobju 2000–2020**

Vir: lasten

Začnimo z obdobjem 2000–2004, v katerem smo identificirali 43.003 bibliografskih zapisov povezanih s predmetnim področjem *Artificial Intelligence*. Porazdelitev zapisov narašča od 5.790 v letu 2000, do 12.617 v letu 2004. Kar dobrih 46 % publikacij je bilo objavljenih v zbirkah *Lecture Notes in Computer Science* in *Lecture Notes in Artificial Intelligence* pri založbi Springer. Po št. citatov (46.933) se na vrh lestvice uvršča članek z naslovom *Random Forests*, ki je bil objavljen v reviji *Machine Learning* (Breiman, 2001). Med 10 najpogosteje citiranimi najdemo še naslova *Latent Dirichlet Allocation* (Blei in sod., 2003) in *SMOTE: Synthetic Minority Over-sampling Technique* (Chawla in sod., 2002). V množici izluščenih ključnih besed smo identificirali osem



tematik; najmanjša (*fuzzy control*) združuje 46, največja (*classification*) pa 253 ključnih besed. Slednja se, skupaj s tematikama *image segmentation* in *face recognition*, ponaša tako z visoko središčnostjo, kot gostoto. Za tematiko *neural networks* je značilna podpovprečna središčnost, ki v kombinaciji s povprečno gostoto govori v prid razvitemu, a šibko aktivnemu področju raziskovanja nevronske mreže. Obrnjeno je v tem obdobju tematika *data mining* sicer aktivna, vendar se še razvija.

V časovni rezini 2005–2009 smo identificirali 57.268 bibliografskih zapisov s proučevanega domenskega področja. Št. zapisov upada od leta 2005, v katerem je bilo objavljenih 16.296 prispevkov, do leta 2009, v katerem smo zabeležili le 9.041 vnosov v WoS. Med publikacijami najvišji mesti zasedata že omenjeni Springerjevi publikaciji iz serije *Lecture Notes*. Primat po št. citatov (12.582) pripada članku *Visualizing Data using t-SNE* (van der Maaten & Hinton, 2008), na neskončnem sedmem mestu pa najdemo tudi prispevek domačega avtorja (Demšar, 2006), ki je po naših poizvedbah najpogosteje navajan članek s širšega področja umetne inteligentnosti, znanosti o podatkih in uporabne statistike. Louvainov algoritem je iz omrežja sopojavnosti izdvojil 10 raziskovalnih tematik, med katerimi je najmanjša (*trust*) vključevala le 10, največja (*classification*) pa 310 ključnih besed. Pozoren bralec bo opazil, da tematika *image segmentation* v primerjavi s časovno rezino 2000–2004 ostaja v istem kvadrantu. Podobno je pozicionirana tudi tematika *neural networks*, ki pa je po obsegu nekoliko manjša, saj se je del pomensko sorodnih ključnih besed porojil v tematiko *reinforcement learning*. Tematika *data mining* je v obdobju 2005–2009 postala bolj aktivna in raziskovalno zanimiva, hkrati pa beležimo tudi njen hitrejši razvoj.

Pomaknimo se po časovnem traku naprej. Obdobje 2010–2014 je v zbirki WoS zastopano z 170.973 predmetnimi zapisi, kar je v primerjavi s predhodnim obdobjem skoraj trikrat več. Od 9.246 zapisov v letu 2010, se števec ob koncu leta 2014 ustavi pri 47.449 bibliografskih vnosih. Pomembna sprememba nastopi v porazdelitvi tipov objav, saj so raziskovalci kar 64 % prispevkov objavili v obliki konferenčnega članka. Št. člankov kitajskih avtorjev tudi prvič preseže št. člankov, ki jih objavijo raziskovalci iz ZDA. Na lestvici najpogosteje citiranih izstopata aplikativna prispevka *Scikit-Learn: Machine Learning in Python* (Pedregosa in sod., 2011) in *LIBSVM: A Library for Support Vector Machines* (Pedregosa in sod., 2011) ter konferenčni članek *Generative Adversarial Nets* (Goodfellow in sod., 2014). Prva dva naslova sta dovolj povedna, da bo vsebino zlahka prepoznal že slušatelj dodiplomskega študija, v zadnjem pa avtorji predstavijo idejo generativnih

kontradiktornih mrež (angl. *Generative Adversarial Nets*). Med izluščenimi ključnimi besedami smo podobno kot zgoraj identificirali 10 raziskovalnih tematik. Najmanjšo skupnost (*sentiment analysis*) sestavlja 10 elementov, največjo (*classification*) pa 250 ključnih besed. V kvadrantu I se pojavi nova tematika (*optimization*), ki predstavlja pomembno gonilno silo razvoja. Podobno se razvojni potencial okrepi pri tematici *classification*, ki hkrati pridobi tudi večjo pozornost raziskovalcev. Nasprotno ugotavljamo počasen zaton tematike *image segmentation*, pri kateri je stopnja razvoja in povezovanja s sorodnimi področji zelo nizka. Vsebinsko široka tematika *sparse representation* je povezana s prizadevanjem raziskovalcev po obvladovanju masivnih podatkov. V kvadrantu III se poraja nova tematika *sentiment analysis*.

Zadnje obdobje je po obsegu vključenih bibliografskih enot najbogatejše. V rezini 2015–2019 smo v zbirki WoS identificirali 313 602 zapisov. Porazdelitev zapisov po letih je v primerjavi s prejšnjimi časovnimi rezinami bolj enakomerna; leta 2015 beležimo 54.879 zapisov, največje št. (69.639) pa leta 2017. Delež prispevkov, objavljenih v obliki konferenčnega članka se še poveča (70 %). Najpogosteje citiran je konferenčni članek z naslovom *Deep Residual Learning for Image Recognition* (He in sod., 2016). Vseh 10 najpogosteje citiranih člankov se ukvarja z globokim učenjem v povezavi s širšim področjem računalniškega vida. V postopku priprave tematskega diagrama smo identificirali 10 skupnosti ključnih besed. Najmanjša skupnost (*action recognition*) vključuje 11 ključnih besed, najobsežnejša (*deep learning*) pa 357 ključnih besed. Tematika *deep learning* v povezavi s tematiko *machine learning* tvori bazično področje delovanja raziskovalcev. Pomembnih gonilnih tematik v tem obdobju ne identificiramo. Povedna je transformacija tematike *sentiment analysis*, ki smo jo identificirali v obdobju 2010–2014, v tematiko *emotion recognition*, ki zrcali prizadevanja po obvladovanju večrazrednega napovedovanja/razvrščanja emocij v različnih modalnostih.

#### 4 Zaključek

V prispevku smo na kratko osvetlili pot razvoja umetne inteligentnosti v zadnjih dvajsetih letih. Predstavljena analiza nikakor ni izčrpana, je pa dovolj povedna, da bo bralec dobil prvi vpogled v dinamiko razvoja področja. Zaradi specifičnosti podatkovnega modela bibliografske zbirke WoS, v analizo nismo vključili raziskovalnih področij, ki umetno inteligentnost pravzaprav definirajo (npr. filozofija, vedenjske in kognitivne znanosti).

## Literatura

- Alonso, J. M., Castiello, C., & Mencar, C. (2018). A bibliometric analysis of the explainable artificial intelligence research field. V J. Medina, M. Ojeda-Aciego, J. L. Verdegay, D. A. Pelta, I. P. Cabrera, B. Bouchon-Meunier & R. R. Yager (Ur.), *Information Processing and Management of Uncertainty in Knowledge-Based Systems. Theory and Foundations* (str. 3–15). Springer. doi:10.1007/978-3-319-91473-2\_1
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent Dirichlet allocation. *The Journal of Machine Learning Research*, 3, 993–1022.
- Blondel, V. D., Guillaume, J.-L., Lambiotte, R., & Lefebvre, E. (2008). Fast unfolding of communities in large networks. *Journal of Statistical Mechanics: Theory and Experiment*, 2008(10), P10008. doi:10.1088/1742-5468/2008/10/P10008
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. doi:10.1023/A:1010933404324
- Callon, M., Courtial, J. P., & Laville, F. (1991). Co-word analysis as a tool for describing the network of interactions between basic and technological research: The case of polymer chemistry. *Scientometrics*, 22(1), 155–205. doi:10.1007/BF02019280
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), 1–27. doi:10.1145/1961189.1961199
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. doi:10.1613/jair.953
- Chen, C. (2011). *Turning points: The nature of creativity*. Springer.
- Darko, A., Chan, A. P. C., Adabre, M. A., Edwards, D. J., Hosseini, M. R., & Ameyaw, E. E. (2020). Artificial intelligence in the AEC industry: Scientometric analysis and visualization of research activities. *Automation in Construction*, 112, 103081. doi:10.1016/j.autcon.2020.103081
- Demšar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *The Journal of Machine Learning Research*, 7, 1–30.
- Fortunato, S., Bergstrom, C. T., Börner, K., Evans, J. A., Helbing, D., Milojević, S., Petersen, A. M., Radicchi, F., Sinatra, R., Uzzi, B., Vespignani, A., Waltman, L., Wang, D., & Barabási, A.-L. (2018). Science of Science. *Science*, 359(6379), eaao185. doi:10.1126/science.aa0185
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2*, 2672–2680.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition*, 770–778. doi: 10.1109/CVPR.2016.90
- Milojević, S., & Leydesdorff, L. (2013). Information metrics (iMetrics): A research specialty with a socio-cognitive identity? *Scientometrics*, 95(1), 141–157. doi:10.1007/s11192-012-0861-z
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-Learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830.
- Small, H. (1973). Co-citation in the scientific literature: A new measure of the relationship between two documents. *Journal of the American Society for Information Science*, 24(4), 265–269. doi:10.1002/asi.4630240406
- Small, H. (2006). Tracking and predicting growth areas in science. *Scientometrics*, 68(3), 595–610. doi:10.1007/s11192-006-0132-y
- van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of Machine Learning Research*, 9(86), 2579–2605.
- Van Eck, N. J., & Waltman, L. (2007). Bibliometric mapping of the computational intelligence field. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 15(05), 625–645. doi:10.1142/S0218488507004911
- Wang, D., & Barabási, A.-L. (2021). *The science of science*. Cambridge University Press. doi:10.1017/9781108610834

Yu, D., Xu, Z., & Fujita, H. (2019). Bibliometric analysis on the evolution of applied intelligence. *Applied Intelligence*, 49(2), 449–462. doi:10.1007/s10489-018-1278-z