15. MEĐUNARODNI SIMPOZIJ · OSIJEK

1.–2. LISTOPADA 2026.

KOPAČKI RIT
JUČER, DANAS, SUTRA

Skriveni ekološki otisak umjetne inteligencije

utjecaj tehnologija umjetne inteligencije na vodne i energetske resurse

Hidden ecological footprint of artificial intelligence: the impact of artificial intelligence technologies on water and energy resources

Martina Nemet, Dora Dulemba Fakultet za odgojne i obrazovne znanosti Osijek

312–765
milijardi litara vode
procijenjeni globalni vodeni otisak sustava UI u 2025. [3]

5,4 mil.
litara vode
za treniranje samo jednog velikog jezičnog modela (GPT-3) [6]

448 → 945
TWh električne energije
potrošnja podatkovnih centara 2025. → 2030. (projekcija) [1, 5]

≈ New York
ugljični otisak UI
32,6–79,7 mil. t CO_2 u 2025.; New York: 52,2 mil. t (2023.) [3]

Uvod i cilj

Nagli razvoj i masovna svakodnevna primjena umjetne inteligencije (UI) donijeli su izniman napredak, ali i često nevidljiv ekološki otisak. Treniranje i korištenje modela UI troši znatne količine električne energije i vode za hlađenje opreme podatkovnih centara.

Cilj je prikazati dostupne procjene potrošnje vode i energije povezane s tehnologijama UI te ukazati na posljedice za prirodne ekosustave i vodene resurse. **Metoda:** pregled recentne znanstvene literature.

Tri puta potrošnje vode

Izravno
hlađenje poslužitelja i postrojenja podatkovnih centara

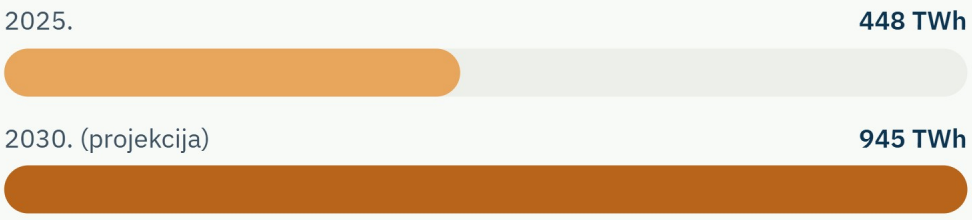
Neizravno
voda utrošena u proizvodnji električne energije

Opskrbni lanac
voda vezana uz proizvodnju poluvodičke opreme

Ključni problem: nedostatak transparentnosti

Operatori podatkovnih centara rijetko objavljuju stvarnu potrošnju vode i energije, što znatno otežava praćenje i smanjenje ekološkog otiska tehnologija UI.

Energija podatkovnih centara



Gotovo dvostruko za pet godina – a s time i neizravna potrošnja vode [1, 5].

Smjer rješenja

Učinkovitiji poslužitelji i hlađenje, bolji odabir lokacije i dekarbonizirana mreža [7]; otpadna toplina za pročišćavanje vode i hvatanje ugljika [4].

Zaključak

Ekološku dimenziju UI potrebno je uključiti u raspravu o zaštiti prirodnih resursa i vodenih ekosustava te razvijati transparentne i odgovorne prakse u tehnološkom sektoru.

Vlažna staništa poput Kopačkog rita ovise o očuvanom vodnom režimu, a pritisak podatkovnih centara na lokalne vodne resurse snažno ovisi o njihovoj lokaciji [2].

Okvir upravljanja: šest načela

prijedlog znanstvene zajednice, s odgovornostima za dionike ekosustava UI

1. Transparentnost
2. Učinkovitost dizajna
3. Jednakost i ekološka pravda
4. Odgovornost za životni ciklus
5. Globalna suradnja
6. Održiva upotreba

Literatura

[1] Aczel, M., Chamanara, S., Matin, M., Farsi, A., Marwala, T., Madani, K. (2026). *Environmental Cost of AI's Energy Use: Carbon, Water and Land Footprints*. UNU-INWEH. doi:10.53328/INR26RMA002

[2] Akinade, B. A., Amanambu, A. C., Frame, J. M., Ren, S. (2026). AI Data Centers and the Water Use Feedback Loop. *arXiv*:2606.21760

[3] de Vries-Gao, A. (2025). The carbon and water footprints of data centers and what this could mean for artificial intelligence. *Patterns*. doi:10.1016/j.patter.2025.101430

[4] Diaz-Marin, C. D., Berquist, Z. J. (2025). Flipping the switch: carbon-negative and water-positive data centers through waste heat utilization. *Energy & Environmental Science*, 18, 8403–8413. doi:10.1039/d5ee02676h

[5] IEA (2025). *Energy and AI*. International Energy Agency, Paris.

[6] Li, P., Yang, J., Islam, M. A., Ren, S. (2025). Making AI less "thirsty": uncovering and addressing the secret water footprint of AI models. *arXiv*:2304.03271

[7] Xiao, T., Fuso Nerini, F., Matthews, H. D., Tavoni, M., You, F. (2025). Environmental impact and net-zero pathways for sustainable artificial intelligence servers in the USA. *Nature Sustainability*. doi:10.1038/s41893-025-01681-y