



## *Umetna inteligenca*

# *preoblikuje logistične procese*

KAKO UMETNA INTELIGENCA PREOBLIKUJE LOGISTIČNE PROCESE? KJE SO MEJE AVTOMATIZACIJE IN KAKO DALEČ ŽE SEGAJO

REŠITVE, KI JIH RAZVIJAMO V SODELOVANJU Z INDUSTRIJO? V SVETU, KJER ODLOČANJE POSTAJA VSE BOLJ KOMPLEKSNO IN

ČASOVNO OBČUTLJIVO, DIGITALNA ORODJA NISO VEČ ZGOLJ PODPORA – POSTAJAJO KLJUČNI IGRALCI V IGRI UČINKOVITOSTI.

V tokratni rubriki Aktualno s predavatelji vas vabimo k branju prispevka **asist. dr. JAKOBA MAROLTA**, ki odstira vpogled v konkretne projekte, domače in globalne primere ter vlogo umetne inteligence v sodobni logistiki. Spoznajte, kako se znanje iz laboratorija prenese v prakso in kako se s pomočjo umetne inteligence premikamo od statičnih sistemov k dinamični, podatkovno podprti prihodnosti.



### **Digitalizacija kot temelj sodobne logistike**

V zadnjem desetletju smo pričali hitremu razvoju digitalizacije, ki močno vpliva na vse panoge, še posebej pa na logistiko. V Sloveniji so številna podjetja že uvedla napredne informacijske rešitve, kot so sistemi za upravljanje skladišč (WMS), ki so povezani z drugimi poslovnimi sistemi (ERP).

Pri uvedbi takšnih sistemov je ključno sodelovanje med strokovnjaki za informacijske rešitve in podjetji, ki imajo poglobljeno znanje o lastnih procesih, saj lahko le tako nastanejo rešitve, ki so resnično prilagojene potrebam posamezne panoge.

Eden od primerov uspešnega sodelovanja z naše strani je razvoj rešitve za svetlobno komisioniranje »Pick to Light«. Sistem omogoča učinkovitejše delo v skladišču in je hkrati izjemno didaktičen, saj ga uporabljamo tudi pri laboratorijskih vajah s študenti. Razvit je bil v sodelovanju med podjetjem Leoss d.o.o. in našim Laboratorijem za Kognitivne Sisteme v Logistiki (LKSL), kjer smo izkoristili prilagodljivost njihovega WMS sistema. Le ta namreč omogoča učinkovito komunikacijo z moduli za svetlobno usmerjanje. Takšna integracija dokazuje, kako lahko modularnost in sodelovanje med industrijo ter raziskovalno sfero pripeljeta do praktičnih in uporabnih rešitev.



## Umetna inteligenca: nova dimenzija v logistiki

Umetna inteligenca (UI) je široko področje računalništva, ki si prizadeva razviti sisteme, sposobne opravljanja nalog, ki običajno zahtevajo človeško inteligenco. Osnovno ločimo tri glavne veje UI: nadzorovano učenje (angl. supervised learning), nenadzorovano učenje (angl. unsupervised learning) in spodbudno učenje (angl. reinforcement learning) [1].


Nadzorovano učenje temelji na podatkih z znanimi oznakami in se pogosto uporablja za napovedovanje in klasifikacijo. Nenadzorovano učenje išče vzorce in povezave v podatkih brez predhodnih oznak. Spodbudno učenje pa omogoča agentom, da se učijo preko interakcije z okoljem in povratnimi informacijami. Čeprav so bili prvi koraki umetne inteligence usmerjeni predvsem v bolj preproste naloge, kot so kategorizacija podatkov in napovedovanje, danes UI že aktivno sodeluje pri reševanju kompleksnih logističnih problemov. Tako lahko na mednarodnih znanstvenih konferencah vse pogosteje zasledimo uporabo spodbudnega učenja in nadzorovanega učenja za optimizacijo raznih logističnih procesov.

Iz vidika logističnih procesov je odločanje (angl. decision problems) eden najpomembnejših dejavnikov, ki vplivajo na učinkovitost sistema. Način, kako sistem sprejema odločitve, določa njegovo sposobnost odzivanja na spremembe, obvladovanja kompleksnosti in doseganja optimalnih rezultatov. Ena ključnih prednosti umetne inteligence v logistiki je njena sposobnost hitrega odločanja, kar je povezano s kompleksnimi in hitro spreminjajočimi se razmerami. Med najpogostejše odločitvene probleme sodijo: katero naročilo obdelati najprej, kako optimalno razporediti naloge, in kako se odzvati na nepričakovane spremembe v povpraševanju. Ti problemi zahtevajo neprestano taktično prilagajanje – ne le dolgoročno planiranje, ampak tudi odločanje v realnem času.

Spodbudno učenje omogoča sistemom, da se učijo na podlagi povratnih informacij iz okolja. To pomeni, da se UI lahko sama uči, kako se odzvati v različnih situacijah, brez potrebe po vnaprejšnjem programiranju vseh možnih scenarijev. Znanih je več uspešnih primerov uporabe UI v praksi, kot so AlphaGo [3], reševanje Rubikove kocke [11] in igranje strateških iger, kot je StarCraft II [4]. Ti dosežki ne le navdušujejo javnost, temveč dokazujejo, da so UI sistemi sposobni učenja, strategije in prilagajanja tudi v zelo kompleksnih okoljih.

To je še posebej pomembno v logistiki, kjer so razmere pogosto dinamične in nepredvidljive. V praksi to pomeni, da lahko UI pomaga pri napovedovanju povpraševanja, optimizaciji poti dostavnih vozil, avtomatizaciji skladiščnih operacij in celo pri nadzoru nad kakovostjo storitev. Nekatera logistična podjetja uporabljajo UI za analizo podatkov v realnem času, da lahko hitro prepoznajo ozka grla v dobavni verigi in predlagajo rešitve. Amazon, denimo, uporablja sisteme UI za usmerjanje svojih robotov po skladiščih [5], DHL pa z uporabo UI analizira ogromno podatkov za boljše napovedovanje in planiranje transporta [6]. V Sloveniji je mogoče opaziti začetke uporabe tovrstnih tehnologij, predvsem v večjih logističnih centrih, kjer se združujejo podatkovna analitika, avtomatizacija in UI za dosego večje učinkovitosti in nižjih stroškov.

V okviru enega izmed raziskovalnih projektov večglobinskega avtomatiziranega skladiščnega sistema smo razvili napreden pristop za minimizacijo premeščanja transportno-skladiščnih enot (TSE). Primerjali smo učinkovitost klasične optimizacije z linearnim programiranjem in pristopov, temelječih na spodbudnem učenju. Posebnost tega sistema je skladiščenje z več odlagalnimi globinami, kar pomeni, da je pogosto potrebno premeščati TSE, da pridemo do željenega tovora.



Slika 1: Rezultati primerjalnega eksperimenta med agenti spodbudnega učenja (DQN, PPO), optimalno metodo in hevrstico (NN)

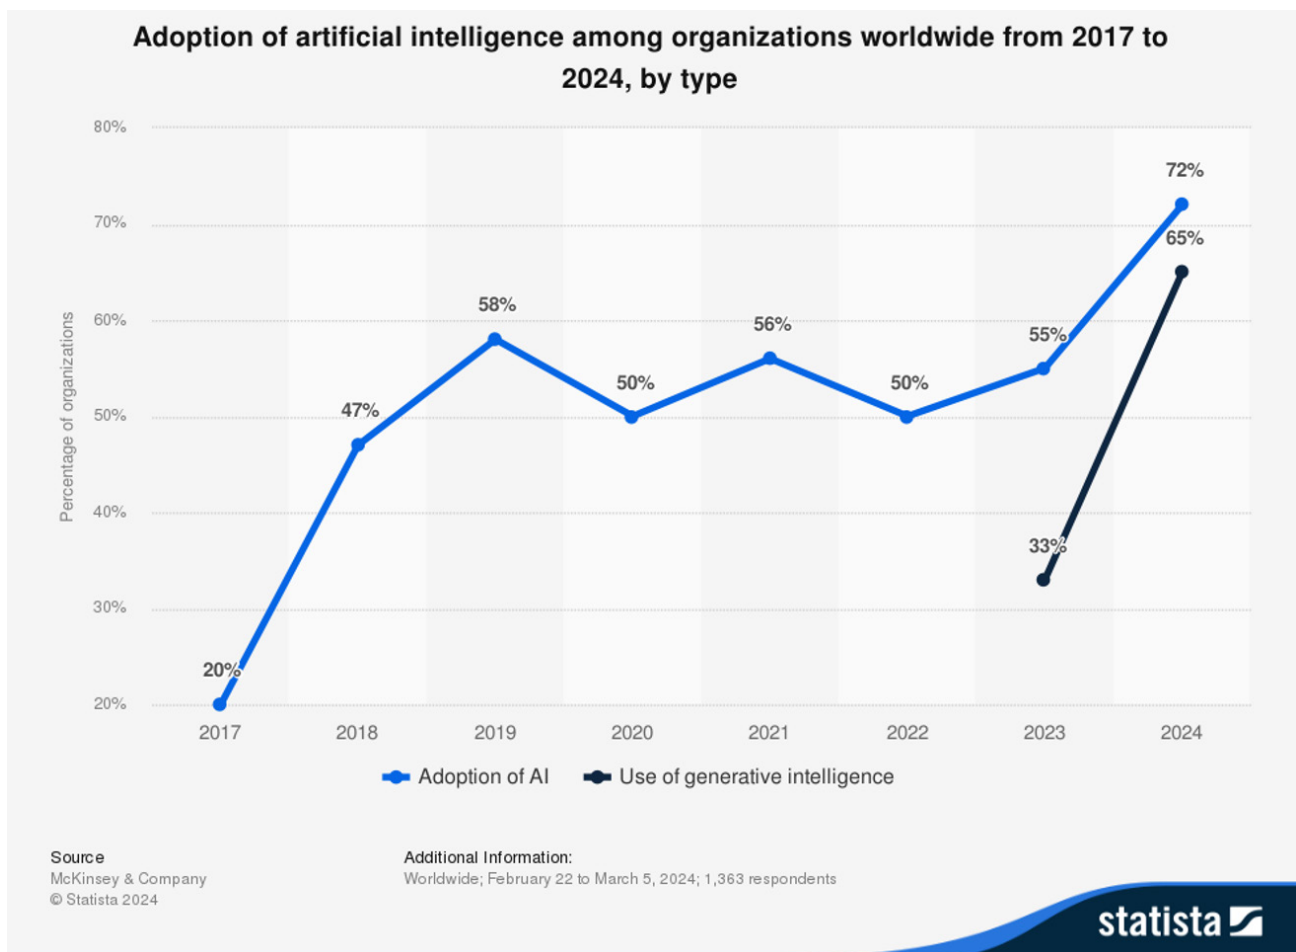
Pokazali smo, kako lahko UI z uporabo algoritmov spodbudnega učenja, kot sta Deep Q-Network (DQN) [7] in Proximal Policy Optimization (PPO) [8], samostojno razvija strategije, ki zmanjšujejo nepotrebna premeščanja in s tem povečujejo pretočnost sistema ter znižujejo porabo energije. Rezultati raziskave so pokazali, da so agenti, izurjeni s pristopom spodbudnega učenja (t. i. »SU Minimum«), v povprečju potrebovali le 0,5 premestitve več kot optimalna rešitev pridobljena z linearnim programiranjem.

Pri tem je pomembno poudariti, da linearno programiranje ponuja optimalne rešitve, vendar postane numerično zelo zahtevno pri večjih problemih zaradi eksponentno naraščajočega števila kombinacij. Nasprotno pa pristopi s spodbudnim učenjem omogočajo učenje odločanja na podlagi izkušenj in so bistveno bolj skalabilni – torej primerni za kompleksne in večje sisteme, kjer tradicionalne metode odpovejo zaradi časovne ali računske neučinkovitosti.

### Kaj prinaša prihodnost?

UI ni omejena le na kompleksne skladiščne sisteme. Generativna orodja, kot so ChatGPT, Gemini, DeepSeek, Claude, Mistral in LLaMA, so že danes del vsakdana številnih uporabnikov [9] – od pisanja besedil in programiranja do ustvarjanja vsebin za predstavitve. Tudi študenti jih uporabljajo za pisanje seminarskih in diplomskih nalog. Čeprav nekateri opozarjajo na nevarnosti zlorabe teh orodij, menimo, da je ključno, da znamo ta orodja uporabljati odgovorno in učinkovito. Generativna UI ne pomeni konca ustvarjalnosti, ampak novo priložnost za izboljšanje kakovosti vsebin. Hkrati postajajo uporabniki teh orodij opazno bolj produktivni. Danes lahko posameznik ali manjša ekipa opravi naloge, ki so še pred nekaj leti zahtevale velike ekipe programerjev in bistveno več časa. Posledično kot družba dosegamo višjo stopnjo učinkovitosti – z manj napora ustvarimo več in to v krajšem časovnem okviru.

Podatki raziskave podjetja McKinsey (2024), objavljeni na platformi Statista [10], kažejo na skokovito rast uporabe umetne inteligence v podjetjih, slika 2. Leta 2017 je umetno inteligenco uporabljalo le 20 % organizacij, medtem ko jih je v letu 2024 ta delež narasel na kar 72 %. Še bolj izrazita pa je rast uporabe generativne umetne inteligence, ki je v enem letu (2023–2024) narasla z 33 % na 65 %.



Slika 2: Trend uporabe AI in generativne inteligence med organizacijami po svetu

Takšna rast potrjuje, da postaja umetna inteligenca standarden del poslovne in posledično logistične prakse. Hkrati pa nakazuje, da podjetja prepoznajo konkurenčne prednosti, ki jih prinašajo napredna orodja, predvsem na področju odločanja, avtomatizacije in analize podatkov. Prihodnost logistike bo nedvomno zaznamovana s tesnim prepletanjem med digitalizacijo, umetno inteligenco in avtomatizacijo. Podjetja, ki bodo znala pravočasno vključiti UI v svoje procese, bodo imela konkurenčno prednost. Kljub temu pa se je treba zavedati, da umetna inteligenca ni čudežna rešitev za vse težave. Vsaka implementacija zahteva premišljen pristop, razumevanje konteksta in jasno definirane cilje. Pretirano zanašanje na UI brez kritične presoje lahko vodi v napačne odločitve ali celo neučinkovite rešitve. Zato je ključno, da ohranimo ravnovesje med navdušenjem nad tehnologijo in realističnim pričakovanjem glede njenih zmožnosti.

Umetna inteligenca ne nadomešča človeka – ga pa dopolnjuje tam, kjer podatki postanejo preobsežni, odločitve prehitre in okolje preveč kompleksno. Prava moč ni v tehnologiji sami, temveč v tem, kako jo znamo pametno vključiti v svoje procese.

#### VIRI

- [1] Mnih, V. et al. (2013). Playing Atari with Deep Reinforcement Learning. <https://arxiv.org/abs/1312.5602>
- [2] Marolt, J., Kosanić, N., & Lerher, T. (2023). Relocation and storage assignment strategy evaluation in a multiple-deep tier captive automated vehicle storage and retrieval system with undetermined retrieval sequence. *International Journal of Advanced Manufacturing Technology*, 118(9–10), 3403–3420. <https://doi.org/10.1007/s00170-021-08169-x>
- [3] Silver, D. et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489. <https://doi.org/10.1038/nature16961>
- [4] Vinyals, O. et al. (2019). Grandmaster level in StarCraft II using multi-agent reinforcement learning. *Nature*, 575(7782), 350–354. <https://doi.org/10.1038/s41586-019-1724-z>
- [5] Amazon Science (2023). The quest to deploy autonomous robots within Amazon fulfillment centers. <https://www.amazon.science/latest-news/the-quest-to-deploy-autonomous-robots-within-amazon-fulfillment-centers>
- [6] DHL (2024). AI in logistics & supply chains. <https://www.dhl.com/global-en/delivered/innovation/ai-in-logistics.html>
- [7] Mnih, V. et al. (2013). Playing Atari with Deep Reinforcement Learning. <https://arxiv.org/abs/1312.5602>
- [8] Schulman, J. et al. (2017). Proximal Policy Optimization Algorithms. <https://arxiv.org/abs/1707.06347>
- [9] Generative AI comparison. (2024). <https://arxiv.org/abs/2503.04765>
- [10] McKinsey & Company, Statista (2024). Adoption of artificial intelligence among organizations worldwide from 2017 to 2024. <https://www.statista.com/statistics/1281313/artificial-intelligence-adoption-rate-worldwide/>
- [11] F. Agostinelli, S. McAleer, A. Shmakov, and P. Baldi, "Solving the Rubik's cube with deep reinforcement learning and search," *Nat. Mach. Intell.*, vol. 1, no. 8, pp. 356–363, 2019, doi: 10.1038/s42256-019-0070-z.