Doc. dr. sc. Robertina Zdjelar

Organizacijska spremnost i odgovorno uvođenje umjetne inteligencije u javnom sektoru s osvrtom na Republiku Hrvatsku

Stručni rad | rujan 2026

SAŽETAK

Cilj rada je utvrditi čimbenike organizacijske spremnosti za odgovornu primjenu umjetne inteligencije u javnom sektoru te procijeniti polazište Republike Hrvatske. U istraživanju je korišten pregled novijih znanstvenih radova i službenih izvještaja iz 2025. i 2026. godine te je ustvrđeno da tehnička infrastruktura i podaci jesu nužni, ali nisu dostatni. Uspjeh ponajprije ovisi o vodstvu, kompetencijama, upravljanju promjenama, interdisciplinarnim timovima, pravnoj usklađenosti i povjerenju javnosti. Hrvatska ima razvijenu digitalnu osnovu, široku uporabu sustava e-Građani i prve ciljane primjene u pravosuđu, ali dokazi još ne upućuju na ujednačeno, mjerljivo i transparentno širenje umjetne inteligencije u sustavu javne uprave. Predlaže se model koji povezuje definiranje potreba od javne, opće vrijednosti, procjenu spremnosti i rizika, kontrolirani pilot, vrednovanje učinaka te širenje primjene uz ljudski nadzor i javnu odgovornost.

Ključne riječi *javni sektor, javna vrijednost, organizacijska spremnost, umjetna inteligencija*

1. Uvod

Umjetna inteligencija u javnoj upravi obuhvaća automatizaciju administrativnih poslova, analizu velikih skupova podataka, otkrivanje nepravilnosti, potporu stručnim odlukama i komunikaciju s građanima. Njezina je privlačnost razumljiva: javna tijela djeluju pod pritiskom nedostatka kadrova, rastućih očekivanja korisnika i potrebe za bržim, dostupnijim uslugama. Ipak, nabava alata ne stvara sama po sebi javnu vrijednost. Primjena zadire u zakonitost postupanja, jednakost građana, obrazloženost odluka i mogućnost pravnog lijeka, pa pogreške mogu imati šire posljedice nego u komercijalnom okruženju.

Dosadašnja istraživanja opisuju raskorak između brojnih pilot-projekata i malog broja rješenja koja su sigurno uključena u redovne procese. Studije javnih organizacija u Švicarskoj, Brazilu, Finskoj i Keniji povezuju uspjeh s kvalitetom podataka, podrškom vodstva, stručnim znanjem, upravljanjem promjenama i suradnjom, a ne samo s izborom tehnologije (Neumann et al., 2024; Guedes i Oliveira Júnior, 2024; Jonathan et al., 2025; Alamäki, 2026).

Polazišna je teza rada da je spremnost sociotehničko i upravljačko svojstvo organizacije.

Rad odgovara na tri pitanja:

1. Koji čimbenici određuju spremnost javne organizacije za primjenu UI?
2. Kakvo je aktualno polazište hrvatskog javnog sektora po pitanju primjene UI u javnoj upravi?
3. Kojim redoslijedom treba uvoditi UI da bi se korist mogla dokazati, a rizici nadzirati?

Zaključak je da Hrvatska raspolaže dobrom digitalnom infrastrukturom i vrijednim sektorskim iskustvima, ali daljnja primjena UI zahtijeva zajednička pravila, popis kritičnih elemenata sustava kod kojih je primjena UI upitna i kod kojih je primjena UI poželjna, ciljano osposobljavanje i usporedive pokazatelje učinka.

Rezultati analize recentnih izvora su tematski sintetizirani prema tehnološko-organizacijsko-okolišnom okviru, javnoj vrijednosti i fazama primjene.

2. Konceptualni okvir organizacijske spremnosti

Tehnološko-organizacijsko-okolišni okvir razlikuje tri skupine uvjeta. **Tehnološka dimenzija** obuhvaća dostupnost i kvalitetu podataka, infrastrukturu, kibernetičku sigurnost i povezivanje s naslijeđenim sustavima. **Organizacijska dimenzija** obuhvaća vodstvo, strategiju, resurse, kompetencije, kulturu i upravljanje promjenama. **Okolišna dimenzija** uključuje propise, javnu nabavu, dobavljače, partnerstva, očekivanja građana i političku odgovornost. Prednost okvira jest to što sprječava svođenje spremnosti na nabavu računalne opreme.

Spremnost se mijenja s iskustvom. Organizacije niske zrelosti ovise o motiviranim pojedincima i vanjskim partnerima te najčešće započinju jednostavnijim rješenjima. U srednjoj fazi rastu važnost strateške potpore, proračuna, unutarnjeg znanja, promjene procesa i prihvaćanja korisnika. U višoj fazi ključno postaje širenje kroz organizaciju, pri čemu mogu porasti unutarnji otpor i pitanja vlasništva nad rješenjem (Neumann et al., 2024). Kenijska studija dodatno pokazuje da infrastruktura, podaci, vodstvo, kompetencije, kultura, propisi, povjerenje i partnerstva djeluju međusobno, a njihova vrijednost ovisi o mandatu i veličini tijela (Jonathan et al., 2025).

Dinamičke sposobnosti objašnjavaju kako se početni resursi pretvaraju u trajnu praksu: organizacija mora prepoznati prikladan problem/potrebu, usmjeriti sredstva, učiti iz pilota i preoblikovati proces. Krajnji kriterij nije broj algoritama, nego javna vrijednost izražena boljom dostupnošću, kvalitetom, učinkovitošću, pravičnošću, transparentnošću i povjerenjem. Pregled 125 radova iz 2026. potvrđuje da su vodstvo, kultura i strateška usklađenost dosljedniji prediktori ishoda od samog ulaganja u tehnologiju (Jonathan, 2026).

Tablica 1 Dimenzije spremnosti javne organizacije za primjenu UI-ja

Dimenzija	Što se procjenjuje	Upravljački odgovor
Tehnološka	Kvaliteta, zakonitost i dostupnost podataka; interoperabilnost; oblak i računalni kapacitet; sigurnost; integracija sa starim sustavima.	Vlasnici podataka i pragovi kvalitete; arhitektura integracije; odvojeno testno okruženje; evidencija verzija, pristupa i incidenata.
Organizacijska	Jasna svrha i podrška vodstva; kompetencije; interdisciplinarni tim; proračun; redizajn procesa; uključivanje zaposlenika.	Portfelj prioritetnih slučajeva; odgovorne osobe; osposobljavanje prema ulozi; plan promjene rada; zaštita ljudske prosudbe.
Okolišna i upravljačka	Pravna osnova; Akt o UI-ju i zaštita podataka; nabava; dobavljači; povjerenje, dostupnost i mogućnost prigovora.	Procjena učinka i rizika; ugovorna prava na podatke i reviziju; objava svrhe i ograničenja; ljudski nadzor; neovisna provjera i pritužbeni kanal.

Izvor: sinteza autora prema Neumann et al. (2024), Jonathan et al. (2025), Alamäki (2026) i Tangi et al. (2026).

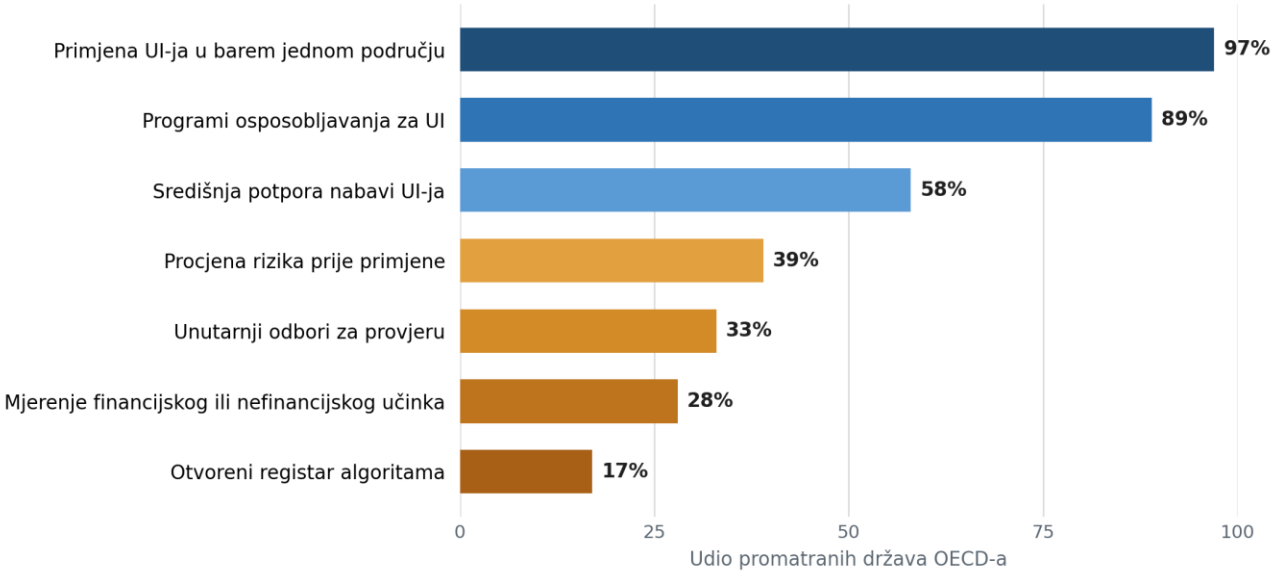
Uvidi iz studija manjih organizacija nadopunjuju okvir. Sustavni pregled Ayinaddisa (2025) razvrstava uvjete u nekoliko područja, od tehnološke i financijske spremnosti do podataka, vještina, potpore uprave, partnerstava i usklađenosti. Felemban et al. (2024) posebno ističu potporu države i rukovodstva te stavove zaposlenika, dok Markic et al. (2025) naglašavaju strukturirano osposobljavanje, centralizirano upravljanje podacima i međufunkcijsku suradnju. Ti su nalazi primjenjivi i na manja lokalna tijela, uz oprez zbog različite svrhe privatnog i javnog sektora.

3. Koristi, dokazani učinci i rizici

Najčešći slučajevi uporabe u upravi jesu razvrstavanje i pretraživanje dokumenata, transkripcija, anonimizacija, otkrivanje prijevara, prognoziranje opterećenja, pomoć pri sastavljanju akata te razgovorni asistenti. Najsigurnija početna točka obično je zadatak s velikim obujmom, jasnom početnom vrijednošću i mogućnošću ljudske provjere. UI ne bi trebalo uvoditi zato što je dostupna, nego zato što dokazivo rješava određeni javni problem.

Studija brazilskog carinskog sustava SISAM pokazuje potencijal zrele primjene. Sustav u stvarnom vremenu procjenjuje nepravilnosti u uvoznim deklaracijama, objašnjava nalaz službeniku i ostavlja mu konačnu odluku. Nakon uvođenja broj fizički pregledane robe smanjen je približno 25 posto uz bolju poreznu usklađenost; interoperabilnost, kvaliteta preporuka, podrška vodstva i razumljivo obrazloženje bili su važni za prihvaćanje (Guedes i Oliveira Júnior, 2024). Noviji kvazieksperiment s 80 državnih službenika utvrdio je da je specijalizirani generativni sustav ubrzao pripremu odgovora građanima za oko 4,05 minuta u odnosu na kontrolnu skupinu, osobito kod novih zaposlenika. Autor pritom mjeri učinak zadatka, a ne ukupnu kvalitetu uprave ili javnu vrijednost (Kim, 2026).

Grafikon 1 Raširenost primjene UI-ja i zrelost upravljačkih kontrola u državama OECD-a



Izvor: OECD Digital Government Outlook 2026; uzorak od 36 država.

Grafikon pokazuje da širenje primjene ne prati jednako brzo razvoj kontrola. Dok 97 posto promatranih država koristi UI u barem jednom području, samo 28 posto izvještava o financijskom ili nefinancijskom mjerenju učinka, a 17 posto ima otvoreni registar algoritama (OECD, 2026). Bez početnih mjerenja, nadzora nakon uvođenja i povratnih informacija građana pilot može izgledati uspješno iako samo premješta trošak, povećava broj pogrešaka ili neravnomjerno utječe na skupine korisnika.

Ključni rizici su diskriminirajući podaci, neobjašnjivi zaključci, povreda privatnosti, automatizacijska pristranost službenika, kibernetički napadi, isključenje digitalno slabijih građana i ovisnost o dobavljaču. Akt o umjetnoj inteligenciji primjenjuje se u najvećem dijelu od 2. kolovoza 2026., dok su zabrane i obveze certificiranja i pismenosti o UI-ju započele ranije, a pojedine obveze za visokorizične sustave primjenjuju se fazno. Za javna tijela to znači da transparentnost, upravljanje rizikom i ljudski nadzor moraju biti ugrađeni u proces, a ne dodani nakon nabave alata I uvođenja istoga (Europska komisija, 2026b).

4. Stanje u javnom sektoru u RH

4.1. Digitalna osnova i strateški smjer

Strategija digitalne Hrvatske do 2032. postavlja digitaliziranu javnu upravu kao jedan od četiri strateška cilja te povezuje infrastrukturu, digitalne procese, kompetencije i uključivanje svih razina vlasti i građana (MPUDT, 2022). Do svibnja 2026. sustav e-Građani koristilo je više od 2,2 milijuna građana kroz više od 121 usluge. Hrvatska je u lipnju 2026. bila među pet država članica s funkcionalnim postupcima prekogranične razmjene podataka prema načelu samo jednom u produkcijskom okruženju (MPUDT, 2026a; MPUDT, 2026c). To su važni preduvjeti jer kvalitetni registri, identitet i interoperabilnost smanjuju trošak budućih rješenja.

Ipak, digitalna usluga nije isto što i organizacijska spremnost za UI. Izvješće Europske komisije u 2026. godini navodi daljnje širenje e-Građana, interoperabilne infrastrukture i digitalnog identiteta, ali i neujednačene usluge za poduzeća, nepotpuno digitalizirane postupke od početka do kraja te manjkove digitalnih vještina i stručnjaka za informacijske tehnologije. Hrvatski plan Digitalnog desetljeća obuhvaća 31 mjeru vrijednu 635 milijuna eura, no Komisija upozorava da se koristi digitalizacije još ne ostvaruju ravnomjerno (Europska komisija, 2026a). Zaključak je da postoji dobra infrastrukturna baza, ali različita sposobnost pojedinih tijela da podatke i tehnologiju pretvore u održivu promjenu procesa.

4.2. Postojeće primjene i procjena zrelosti

U pravosuđu su 2026. predstavljeni projekti automatizirane anonimizacije i objave sudskih odluka, audio snimanja i automatske transkripcije rasprava, modernizacije sustava eSpis te izrade smjernica za generativni UI u radu sudaca. Zajedničko im je da podupiru obradu dokumenata i rad stručnjaka, dok ljudsko odlučivanje ostaje u središtu postupka (MPUDT, 2026b). *Na regionalnoj razini* uspostavljen je Centar za digitalizaciju i umjetnu inteligenciju Šibensko-kninske županije, usmjeren na kompetencije građana, zaposlenika javne uprave i poduzetnika (MPUDT, 2026a). Primjeri potvrđuju aktivno eksperimentiranje i razvoj kapaciteta, ali javno dostupni izvori ne nude cjelovit popis sustava ni usporedive pokazatelje njihovih učinaka.

Prema tehnološkoj dimenziji, prednosti su nacionalni digitalni identitet, registri, e-usluge, prekogranična razmjena podataka i ulaganja u oblak i povezivost. Slabosti su neujednačena kvaliteta podataka, naslijeđeni sustavi i razlike između sektora i razina vlasti. **Prema organizacijskoj dimenziji**, strateška potpora postoji, ali nedostatak specijalista i provedbenih znanja otežava prelazak iz pilota u redovni rad. **Prema okolišnoj dimenziji**, europski propisi i fondovi stvaraju poticaj, dok zaštita prava, javna nabava, kibernetička sigurnost i povjerenje traže snažnije kontrole i snažnu kontrolnu ulogu u ljudskom faktoru.

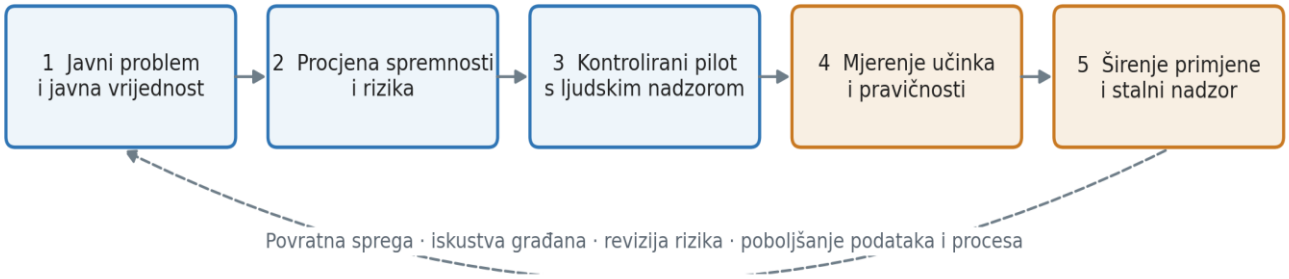
Stavovi građana potvrđuju potrebu za opreznim širenjem. U Eurobarometru Digitalnog desetljeća 2026. 79 posto ispitanika u Hrvatskoj smatra da razvoj UI-ja treba pažljivo regulirati radi sigurnosti. Najčešće brige povezane s generativnim alatima bile su netočnost informacija, privatnost i mogući gubitak radnih mjesta (Europska komisija, 2026a). Organizacijska procjena stoga nije samo tehnički pregled, nego i provjera može li tijelo objasniti svrhu sustava, omogućiti prigovor i zadržati jednako dostupnu uslugu izvan digitalnog kanala.

Sveukupno, hrvatski javni sektor nalazi se u prijelazu od napredne digitalizacije prema ranoj, sektorski neujednačenoj primjeni UI-ja. Najvažniji rizik nije sporost sama po sebi, nego fragmentirano uvođenje bez zajedničkih kriterija, ponovna izgradnja istih komponenti i nemogućnost usporedbe stvarnih rezultata.

5. Model odgovorne primjene za hrvatski javni sektor

Predloženi model polazi od javnog problema odnosno javne potrebe, a ne od ponuđenog alata. Svaka faza ima odluku o nastavku: postoji li jasna javna korist, jesu li podaci zakoniti i dovoljno kvalitetni, može li se rezultat ljudski provjeriti, pokazuje li pilot bolji ishod od početnog stanja te postoje li resursi za nadzor tijekom cijelog životnog ciklusa. Takav redoslijed povezuje preporuke novijih istraživanja o tehnološkom dizajnu, upravljanju projektom i mrežnoj suradnji s obvezama odgovorne primjene (Alamäki, 2026; Tangi et al., 2026).

Shema 1 Ciklus odgovorne primjene UI-ja u javnoj organizaciji



Izvor: izrada autora prema Jonathan et al. (2025), Alamäki (2026) i Tangi et al. (2026).

Za provedbu modela potrebno je šest povezanih upravljačkih mjera.

- **Jedinstveno upravljanje i evidencija.** Uspostaviti središnju metodologiju, imenovati odgovorne u svakom tijelu te voditi ažuran popis UI sustava, njihove svrhe, podataka, dobavljača, razine rizika i vlasnika odluke.
- **Odabir prema javnoj vrijednosti.** Prednost dati velikom administrativnom opterećenju i ponavljajućim poslovima s jasnom početnom mjerom. Visokorizične odluke ne uvoditi bez pravne osnove, procjene učinka i dokazivog ljudskog nadzora.
- **Zajednički podatkovni i tehnički temelji.** Uvesti pragove kvalitete podataka, kataloge, standardna sučelja, sigurna testna okruženja i ponovljivo tehničko ocjenjivanje kako lokalna tijela ne bi zasebno nabavljala iste komponente.
- **Kompetencije i promjena rada.** Razlikovati osnovnu pismenost svih službenika od naprednih znanja naručitelja, pravnika, stručnjaka za podatke, revizora i rukovoditelja. Zaposlenike i sindikalne predstavnike uključiti prije redizajna poslova.
- **Nabava s kontrolom životnog ciklusa.** Ugovoriti pravo na sigurnost podataka, tehničku dokumentaciju, reviziju, prijenos sustava, prijavu incidenata i izlaz iz odnosa s dobavljačem. Ocjenjivati ukupni trošak održavanja, a ne samo cijenu pilota.
- **Mjerenje i transparentnost.** Prije pilota utvrditi početne vrijednosti, a zatim pratiti vrijeme i trošak, kvalitetu i stopu pogreške, pravičnost među skupinama, zadovoljstvo korisnika, broj prigovora i radno opterećenje. Sažetak rezultata i ograničenja javno objaviti.

Središnja potpora posebno je važna manjim gradovima, općinama i ustanovama. Ona može objediniti pravne obrasce, provjerene tehničke komponente, stručnjake i edukaciju, dok odluka o procesu i kontakt s građanima ostaju kod nadležnog tijela. Time se smanjuje ovisnost o dobavljačima i omogućuje usporedba projekata.

6. Rasprava

Konzultirani izvori, premda nastali u različitim državama i sektorima, dosljedno pokazuju da su podaci i infrastruktura tek početni uvjet. Projekti se šire kada vodstvo poveže UI sa strategijom i procesom, osigura interdisciplinarni tim, uključi zaposlenike i korisnike te uvede mjerljive kontrole.

Novija finska studija sažima te zahtjeve u tehnološki dizajn, upravljanje projektom i umrežavanje, dok OECD upozorava da su upravo mjerenje učinka, nabavna podrška i operativne kontrole slabije razvijeni od same uporabe (Alamäki, 2026; OECD, 2026).

Za Hrvatsku je važna razlika između digitalne i UI zrelosti. e-Građani, registri i prekogranična interoperabilnost smanjuju tehničku zapreku, ali ne odgovaraju na pitanja tko smije upotrijebiti model, za koju svrhu, na kojim podacima, kako se provjerava pogreška i kome se građanin može žaliti.

Sektorski projekti u pravosuđu i regionalni centar mogu poslužiti kao mjesta učenja ako se njihovi rezultati mjere i prenose kroz upravu.

Rano uvođenje zajedničke evidencije i standarda moglo bi spriječiti naknadno skupu konsolidaciju nepovezanih rješenja.

Javni sektor pritom ne smije preuzeti privatni kriterij povrata ulaganja bez prilagodbe. Ušteda vremena vrijedi samo ako ne smanjuje kvalitetu obrazloženja, dostupnost usluge, jednakost postupanja ili odgovornost službenika. Najprimjereniji pokazatelji zato kombiniraju učinkovitost s kvalitetom, pravičnošću, povjerenjem i mogućnošću osporavanja odluke.

6.1. Ograničenja i daljnja istraživanja

Analizirani izvori koriste različite definicije UI-ja, uzorke i metode te uglavnom obrađuju pojedinačne organizacije izvan Hrvatske. Za hrvatski javni sektor nisu pronađeni javno objedinjeni podaci o svim UI sustavima, troškovima, pogreškama i učincima; službene objave usto prirodno naglašavaju postignuća. Zbog brzih promjena tehnologije i pravila procjena stanja vremenski je osjetljiva. Zaključke stoga treba čitati kao utemeljenu procjenu spremnosti, a ne kao mjerenje učinka cijelog sustava.

Daljnja istraživanja trebaju provesti reprezentativno istraživanje spremnosti tijela državne, regionalne i lokalne razine; izraditi javni registar slučajeva uporabe; te longitudinalno pratiti prijelaz iz pilota u redovni rad. Kvazieksperimenti i usporedne studije trebaju istodobno mjeriti vrijeme, trošak, kvalitetu, pogreške, raspodjelu učinaka među skupinama, prigovore i povjerenje. Posebno su potrebna istraživanja nabave, ovisnosti o dobavljaču, radnih posljedica, okolišnog troška te učinkovitosti ljudskog nadzora u pravosuđu, socijalnoj zaštiti, zdravstvu i općenito javnoj upravi.

7. Zaključak

Odgovorna primjena umjetne inteligencije u javnom sektoru nije prvenstveno informatički projekt, nego promjena načina rada i odgovornosti. Najbolji izgledi za javnu vrijednost nastaju kada se kvalitetni podaci i interoperabilna infrastruktura povežu s jasnim vodstvom, kompetencijama, upravljanjem promjenama, pravnom usklađenošću, transparentnošću i stvarnim sudjelovanjem korisnika.

Hrvatska ulazi u tu fazu s vrijednom digitalnom osnovom i konkretnim sektorskim inicijativama, ali bez dovoljno javnih dokaza o ujednačenom širenju i učincima UI-ja kroz cijelu upravu. Prioriteti su stoga zajednička evidencija i upravljanje, procjena spremnosti i rizika, osposobljavanje prema ulozi, sigurni i mjerljivi piloti, ugovorna kontrola dobavljača te javno izvještavanje o rezultatima i ograničenjima. Takav pristup omogućuje brže učenje bez odricanja od zakonitosti, jednakosti i povjerenja koji određuju kvalitetu javne službe.

Literatura

1. Neumann, O., Guirguis, K. i Steiner, R. (2024). Exploring artificial intelligence adoption in public organizations: A comparative case study. Public Management Review, 26(1), 114–141. https://doi.org/10.1080/14719037.2022.2048685
2. Guedes, L. i Oliveira Júnior, M. (2024). Artificial intelligence adoption in public organizations: A case study. Future Studies Research Journal: Trends and Strategies, 16(1), e860. https://doi.org/10.24023/FutureJournal/2175-5825/2024.v16i1.860
3. Jonathan, G. M., Yalew, S. D., Gebremeskel, B. K. i Watat, J. K. (2025). AI adoption in the public sector: Organizational readiness and the pursuit of public value. Complex Systems Informatics and Modeling Quarterly, 45, 43–70. https://doi.org/10.7250/csimq.2025-45.03
4. Alamäki, A. (2026). Expanding AI adoption in public sector organizations: perspectives on management practices. Transforming Government: People, Process and Policy, 20(2), 165–187. https://doi.org/10.1108/TG-05-2025-0124
5. Jonathan, G. M. (2026). Public-sector digital transformation in the age of generative AI. Discover Artificial Intelligence, 6, 968. https://doi.org/10.1007/s44163-026-02077-3
6. Tangi, L., Rodriguez Müller, P., Schade, S., André, A.-A., Combetto, M. i Daoud, M. (2026). Advancing AI adoption in EU public administrations: Future directions and opportunities under the Apply AI Strategy. Publications Office of the European Union. https://doi.org/10.2760/3112501
7. Ayinaddis, S. G. (2025). Artificial intelligence adoption dynamics and knowledge in SMEs and large firms: A systematic review and bibliometric analysis. Journal of Innovation & Knowledge, 10(3), 100682. https://doi.org/10.1016/j.jik.2025.100682
8. Felemban, H., Sohail, M. i Ruikar, K. (2024). Exploring the readiness of organisations to adopt artificial intelligence. Buildings, 14(8), 2460. https://doi.org/10.3390/buildings14082460
9. Markic, M., Webster, S., van der Staay, A., Bäßmann, F. N., Janiesch, C. i Poeppelbuss, J. (2025). Advancing AI adoption in SMEs: A framework for nascent AI strategy development. ICIS 2025 Proceedings, 1 (ICIS2025-1075). https://aisel.aisnet.org/icis2025/digitstrategy/digitstrategy/1/
10. Kim, E. (2026). Generative AI in public administration: A quasi-experimental analysis of bureaucratic productivity. Government Information Quarterly, 43(1), 102108. https://doi.org/10.1016/j.giq.2026.102108
11. OECD. (2026). Adopting and governing AI in government. U Digital Government Outlook 2026: From Foundations to Transformational Impact. OECD Publishing. https://www.oecd.org/en/publications/2026/06/digital-government-outlook_4585678e/full-report/adopting-and-governing-ai-in-government_7ef312a9.html
12. Europska komisija. (2026b). AI Act. https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai
13. Hrvatski sabor. (2023). Strategija digitalne Hrvatske za razdoblje do 2032. godine. Narodne novine, 2/2023, br. 17. Donesena 16. prosinca 2022. [U glavnom tekstu navedena kao: MPUDT, 2022.] https://narodne-novine.nn.hr/clanci/sluzbeni/2023_01_2_17.html
14. Ministarstvo pravosuđa, uprave i digitalne transformacije. (2026a). Ministar Habijan potpisao Sporazum o uspostavi Centra za digitalizaciju i umjetnu inteligenciju Šibensko – kninske županije. https://mpudt.gov.hr/vijesti-8/ministar-habijan-potpisao-sporazum-o-uspostavi-centra-za-digitalizaciju-i-umjetnu-inteligenciju-sibensko-kninske-zupanije/30851
15. Ministarstvo pravosuđa, uprave i digitalne transformacije. (2026c). Hrvatska kao digitalni lider: Na OOTS konferenciji na Malti potvrđen ulazak među pet najnaprednijih država Unije. https://mpudt.gov.hr/vijesti-8/hrvatska-kao-digitalni-lider-na-oots-konferenciji-na-malti-potvrdjen-ulazak-medju-pet-najnaprednijih-drzava-unije/30909
16. Europska komisija. (2026a). Croatia's 2026 Digital Decade Country Report. https://digital-strategy.ec.europa.eu/en/factpages/croatias-2026-digital-decade-country-report
17. Ministarstvo pravosuđa, uprave i digitalne transformacije. (2026b). Hrvatska u okviru predsjedanja MED9 stavila fokus na primjenu umjetne inteligencije u pravosudnim sustavima. https://mpudt.gov.hr/vijesti-8/hrvatska-u-okviru-predsjedanja-med9-stavila-fokus-na-primjenu-umjetne-inteligencije-u-pravosudnim-sustavima/30894