ULOGA VJEŠTAČKE INTELIGENCIJE U TRANSFORMACIJI IT POSLOVA: SMANJENJE POTREBE ZA VJEŠTINAMA I RUTINSKIM ZADACIMA U FINANSIJSKOM SEKTORU

Alen Kamiš[1], Jelena Ružić[2], Stevan Stankovski[3], Aleksandra Marković[4]

[1]Visoka škola za uslužni biznis, Cara Lazara bb, 71 350 Sokolac - East Sarajevo, Bosna i Hercegovina, alen@vub.edu.ba
[2]Fakultet za projektni i inovacioni menadžment, Bože Jankovića 14, 11 000 Beograd, Srbija, jruzic45@gmail.com
[3]Univerzitet u Novom Sadu, Fakultet tehničkih nauka, Trg Dositeja Obradovića 6, 21 000 Novi Sad, Srbija, stevan@uns.ac.rs
[4]Toplička akademija strukovnih studija – Odjeljenje za poslovne studije, Kralja Petra I Karađorđevića 1, 18 420 Blace, Srbija, aleksandra.markovic@vpskp.edu.rs

SHORT SCIENTIFIC PAPER

Received: 26 Jun 2026.
Accepted: 13 November 2026.
Published: 16 November 2026.
DOI: https://doi.org/10.63395/STEDConf15022026128K331

Corresponding Author: Alen Kamiš, The College of Service Business, Cara Lazara bb, 71 350 Sokolac - East Sarajevo, Bosnia and Herzegovina, alen@vub.edu.ba

Copyright © 2026 Alen Kamiš et al.; published by UNIVERSITY PIM. This work licensed under the Creative Commons Attribution-NonCommercial-NoDerivs 4.

Citation: Kamiš, A., et al. (2026). The role of artificial intelligence in restructuring IT jobs: Deskilling and reducing the need for routine tasks in the financial sector. In Kojić, D. & Sredić. D. (eds.) *Conference proceedings, XV International Conference on Social and Technological Development: STED 2026* (pp. 331-338). Trebinje, B&H: University PIM.

SAŽETAK

Ovaj rad razmatra uticaj vještačke inteligencije (AI) na transformaciju IT poslova u finansijskom sektoru, s posebnim osvrtom na automatizaciju rutinskih zadataka i fenomen deskillinga. Pojam deskilling označava promjene u organizaciji rada koje mogu smanjiti nivo vještina potrebnih za obavljanje pojedinih zadataka ili ograničiti mogućnosti zaposlenih da razvijaju i održavaju praktična znanja i stručnu samostalnost.

Empirijski dio rada zasniva se na anketnom istraživanju provedenom među 138 zaposlenih u finansijskom i IT okruženju, s ciljem ispitivanja njihovih stavova o primjeni AI alata, automatizaciji radnih zadataka, sigurnosti zaposlenja i razvoju kompetencija. Rezultati ukazuju na to da ispitanici prepoznaju mogućnosti povećanja produktivnosti i smanjenja vremena potrebnog za rutinske zadatke, ali istovremeno izražavaju zabrinutost zbog mogućeg smanjenja potrebe za pojedinim početnim IT pozicijama i rizika od slabljenja praktičnih znanja uslijed pretjeranog oslanjanja na automatizovane sisteme.

Rad ukazuje na značaj kontinuiranog stručnog usavršavanja, mentorstva i očuvanja prilika za samostalno rješavanje problema. Budući da se istraživanje zasniva na samoprocjeni, nalazi se

tumače kao percepcija zaposlenih o mogućim posljedicama primjene AI, a ne kao neposredno mjerenje promjena njihovih kompetencija.

Ključne riječi: vještačka inteligencija, deskilling, IT poslovi, finansijski sektor, automatizacija.

UVOD

Razvoj vještačke inteligencije (AI) mijenja način organizacije rada, raspodjelu radnih zadataka i kompetencije koje se očekuju od zaposlenih. U finansijskom sektoru, u kojem su obrada podataka, upravljanje rizicima, korisnička podrška i usklađivanje poslovanja s regulatornim zahtjevima važni dijelovi svakodnevnog rada, AI alati mogu ubrzati pojedine procese i smanjiti obim rutinskih aktivnosti. Istovremeno, automatizacija otvara pitanja o promjenama u strukturi zaposlenosti, budućim potrebama za stručnim profilima i mogućnostima zaposlenih da kroz praktičan rad stiču i održavaju profesionalne vještine.

Jedan od teorijskih pristupa kojim se razmatraju ove promjene jeste koncept tehnologijom omogućenog deskillinga. Za razliku od pristupa koji naglašavaju rast potražnje za visokokvalifikovanim radnicima ili polarizaciju zaposlenosti, ovaj koncept razmatra mogućnost da tehnologija preuzme složenije dijelove posla, dok zaposlenima ostaju standardizovaniji zadaci koji zahtijevaju uži skup vještina. U savremenom okruženju AI može preuzeti dio analize, pripreme sadržaja, obrade podataka ili početne dijagnostike problema. Takve mogućnosti mogu povećati efikasnost, ali istovremeno uticati na način na koji zaposleni razvijaju praktično iskustvo i samostalnost.

Važno je razlikovati smanjenje nivoa vještina potrebnih za obavljanje određenog zadatka od stvarnog gubitka znanja kod pojedinca. Prvo se odnosi na promjenu zahtjeva posla, dok drugo podrazumijeva slabljenje ili nedovoljno razvijanje kompetencija zaposlenog. U ovom radu pojam deskilling koristi se kao teorijski termin za razmatranje tih povezanih, ali ne i istovjetnih pojava. Empirijski dio istraživanja ne mjeri neposrednu promjenu kompetencija, nego ispituje percepciju zaposlenih o mogućem riziku takvih promjena.

Cilj rada je analizirati percepciju zaposlenih u finansijskom sektoru o uticaju AI na transformaciju IT poslova, s posebnim fokusom na automatizaciju rutinskih zadataka, promjene u potrebnim kompetencijama i rizik deskillinga. Istraživanje nastoji sagledati kako zaposleni procjenjuju koristi AI alata, moguće promjene u početnim IT pozicijama i značaj kontinuiranog stručnog usavršavanja.

METODOLOGIJA ISTRAŽIVANJA

Radi ispitivanja percepcije zaposlenih o uticaju AI na IT poslove u finansijskom sektoru provedeno je anketno istraživanje među zaposlenima u bankama i drugim finansijskim institucijama. Istraživanje je realizovano od novembra 2025. do maja 2026. godine putem onlajn upitnika.

U istraživanju je učestvovalo 138 ispitanika koji obavljaju različite poslove u IT i finansijskom okruženju, uključujući sistemsku administraciju, programiranje, IT podršku, upravljanje IT funkcijom i bankarske poslove. Upitnik je sadržavao 15 pitanja organizovanih u tri tematske cjeline:

- primjena AI alata u svakodnevnom radu;
- uticaj AI na radna mjesta i automatizaciju zadataka;
- uticaj AI na razvoj i očuvanje kompetencija zaposlenih.

Struktura ispitanika prema radnoj poziciji prikazana je u Tabeli 1. Uzorak obuhvata više profesionalnih grupa, što omogućava sagledavanje stavova zaposlenih koji obavljaju različite vrste poslova. Ipak, struktura uzorka sama po sebi ne potvrđuje reprezentativnost za cjelokupan finansijski sektor, te nalaze treba tumačiti u okviru obuhvaćene grupe ispitanika.

Tabela 1. Struktura ispitanika prema radnoj poziciji

Radna pozicija	Broj ispitanika	Udio %
Sistemski administratori	32	23,2
Programeri	28	20,3
IT podrška	24	17,4
IT menadžeri	16	11,6
Bankarski službenici	38	27,5
Ukupno	138	100

Najveću grupu u uzorku čine bankarski službenici (38 ispitanika; 27,5%), zatim sistemski administratori (32; 23,2%), programeri (28; 20,3%), zaposleni u IT podršci (24; 17,4%) i IT menadžeri (16; 11,6%). Brojevi i procenti prikazuju se odvojeno kako bi se izbjeglo poistovjećivanje apsolutnog broja ispitanika s njihovim udjelom u uzorku.

Za tvrdnje koje su se odnosile na stavove ispitanika korištena je Likertova skala od pet stepeni, pri čemu je vrijednost 1 označavala potpuno neslaganje, a vrijednost 5 potpuno slaganje s ponuđenom tvrdnjom. Procenti prikazani u rezultatima predstavljaju udio ispitanika koji su, prema obradi odgovora, iskazali slaganje s odgovarajućim tvrdnjama.

Istraživanje je usmjereno na procjenu toga da li zaposleni prepoznaju uticaj AI na smanjenje obima rutinskih zadataka, promjene u potrebnim kompetencijama i mogući rizik deskillinga. Budući da se podaci zasnivaju na odgovorima ispitanika, istraživanje pruža uvid u njihove stavove i procjene, ali ne omogućava zaključivanje o uzročno-posljedičnom uticaju AI niti neposredno mjerenje stvarnog gubitka vještina.

TEORIJSKI OKVIR O VJEŠTAČKOJ INTELIGENCIJI I TRANSFORMACIJI PROFESIJA

Istorijski razvoj i savremeni trendovi

Rani teorijski pristupi tehnološkim promjenama na tržištu rada uključuju koncept skill-biased technological change, prema kojem tehnološki napredak relativno više koristi visokokvalifikovanim radnicima i može povećati potražnju za njihovim znanjima. Drugi pristup, poznat kao polarizacija poslova, ukazuje na mogućnost istovremenog rasta zaposlenosti u zanimanjima na oba kraja raspodjele kvalifikacija i smanjenja udjela pojedinih srednjekvalifikovanih poslova, posebno onih koji sadrže rutinske zadatke. Okvir zasnovan na zadacima dodatno razlikuje rutinske i nerutinske, kognitivne i manuelne aktivnosti te naglašava da se uticaj tehnologije ne može objasniti samo nivoom formalnih kvalifikacija zaposlenih.

U radu Xue i saradnika (2022), zasnovanom na panel-podacima za više od 1.300 javno kotiranih preduzeća u Kini u periodu 2007–2018, analiziran je odnos primjene AI i obrazovne strukture radne snage [1]. Autori izvještavaju da je upotreba AI povezana s većim rastom potražnje za radnicima na poslovima koji zahtijevaju niži nivo formalnog obrazovanja nego za radnicima na poslovima koji zahtijevaju viši nivo obrazovanja, pri čemu je obrazac bio izraženiji u uslužnom nego u proizvodnom sektoru. Na osnovu tih nalaza autori predlažu koncept tehnologijom omogućenog deskillinga kao jedno od objašnjenja promjena u strukturi zaposlenosti [1].

Ove teorijske perspektive ne treba posmatrati kao međusobno isključive u svim okolnostima. Posljedice tehnoloških promjena mogu zavisiti od vrste djelatnosti, načina uvođenja tehnologije, organizacije rada i zadataka koji se automatizuju. Za finansijski sektor to znači da AI može istovremeno povećavati produktivnost, mijenjati strukturu radnih mjesta i stvarati nove potrebe za analitičkim, nadzornim i upravljačkim kompetencijama.

Fenomen deskiliranja i promjene radnih zadataka

Pojam deskilling u literaturi o ekonomiji rada, organizaciji rada i tehnološkim promjenama označava proces u kojem se smanjuje nivo vještina potrebnih za obavljanje određenog posla ili se rad organizuje tako da zaposleni imaju manje prilika da koriste i razvijaju složenije kompetencije.

Pojam može obuhvatiti promjenu sadržaja posla, sužavanje raspona zadataka, smanjenje stručne samostalnosti ili rizik od slabljenja praktičnih znanja. Ove pojave su povezane, ali nisu istovjetne: smanjenje potrebnih vještina za zadatak ne znači automatski da je pojedinac izgubio prethodno stečeno znanje.

U kontekstu AI, deskilling se može javiti kada automatizovani sistemi preuzmu aktivnosti koje su ranije zahtijevale samostalnu analizu, dijagnostiku, procjenu ili rješavanje problema, dok zaposlenima ostaju zadaci nadzora, provjere ili obrade standardizovanih izlaza. Ako se takva promjena odvija bez odgovarajuće obuke i praktičnog rada, zaposleni mogu imati manje prilika da razvijaju ili održavaju vještine koje su ranije sticali kroz neposredno izvršavanje zadataka. Ovaj rizik može biti naročito relevantan za zaposlene na početku karijere, kojima rutinski zadaci često služe kao osnova za sticanje iskustva prije preuzimanja složenijih odgovornosti.

U ovom radu izvorni termin deskilling zadržava se zbog njegovog specifičnog teorijskog značenja i zastupljenosti u međunarodnoj literaturi. Izrazi „smanjenje potrebnih vještina" i „gubitak praktičnih znanja i vještina" koriste se kao objašnjenja pojedinih aspekata fenomena, ali nisu uvijek potpune zamjene za njega. Empirijski dio rada ispituje percepciju zaposlenih o riziku deskillinga, a ne neposredno mjeri promjene njihovih kompetencija.

Upravo je ta razlika važna pri tumačenju rezultata ankete: slaganje s tvrdnjom da AI može dovesti do gubitka praktičnih znanja predstavlja procjenu ispitanika o mogućem riziku, a ne dokaz da je do gubitka znanja već došlo. Za pouzdanije utvrđivanje stvarnog deskillinga bilo bi potrebno longitudinalno praćenje zaposlenih ili neposredno mjerenje promjena u njihovim vještinama i radnim zadacima.

AI U FINANSIJSKOM SEKTORU

Primjene u poslovnim procesima

Primjena AI u finansijskim institucijama obuhvata automatizaciju obrade podataka i dokumenata, podršku korisnicima, prepoznavanje obrazaca u transakcijama, analizu rizika i podršku poslovnom odlučivanju. U bankarstvu se robotska procesna automatizacija (RPA) koristi za ubrzavanje standardizovanih postupaka, kao što su unos podataka, obrada zahtjeva i pojedini administrativni poslovi. AI i RPA mogu smanjiti obim ponavljajućih aktivnosti, naročito u pozadinskim poslovnim operacijama i osnovnoj korisničkoj podršci, ali njihova primjena zavisi od kvaliteta podataka, nadzora, regulatornih zahtjeva i načina integracije u postojeće procese [2].

Zianko i Nechyporenko (2023) razmatraju primjenu AI u finansijskom sektoru Ukrajine [3]. Njihov pregled obuhvata rješenja za prepoznavanje govora, razgovorne agente, mašinski prevod, podršku odlučivanju, kompjuterski vid, analizu tekstualne dokumentacije, prognoziranje i otkrivanje anomalija. Autori ukazuju na potencijal AI za povećanje efikasnosti finansijskih procesa, ali i na pitanja etike, transparentnosti, zaštite podataka i pouzdanosti automatizovanih odluka. Ovaj primjer odnosi se na Ukrajinu, a ne na neimenovanu evropsku državu.

U kreditnim i finansijskim procesima mogu se koristiti modeli za procjenu kreditnog rizika, sistemi za otkrivanje prevara i rješenja za personalizaciju finansijskih usluga. Takve primjene mogu ubrzati obradu zahtjeva i podržati analizu velikih skupova podataka, ali zahtijevaju provjeru kvaliteta modela, praćenje mogućih pristrasnosti i jasno definisanu odgovornost za odluke. Automatizacija zato ne uklanja potrebu za ljudskom stručnošću, nego može promijeniti mjesto na kojem se stručnost primjenjuje: od ručne obrade pojedinačnih slučajeva ka nadzoru, validaciji i tumačenju rezultata sistema.

Pored tehnoloških koristi, uvođenje AI donosi rizike povezane sa sajber sigurnošću, privatnošću, regulatornom neusklađenošću, kvalitetom podataka i nedostatkom odgovarajućih kompetencija. Organizacije stoga trebaju povezati automatizaciju s upravljanjem rizicima, stručnim usavršavanjem i jasnim pravilima za provjeru rezultata AI sistema. Ovakav pristup posebno je važan kada se automatizuju zadaci koji su ranije zaposlenima omogućavali sticanje iskustva.

Percepcija zaposlenih o AI – sigurnost radnih mjesta i nove mogućnosti

Uticaj AI na sigurnost radnih mjesta ne može se svesti samo na pitanje da li će pojedina zanimanja nestati. Automatizacija može smanjiti potrebu za određenim zadacima, promijeniti raspodjelu odgovornosti unutar postojećih radnih mjesta ili stvoriti potrebu za novim kompetencijama. Zbog toga je važno razlikovati ukidanje radnog mjesta od transformacije njegovog sadržaja. Istraživanja o razvoju radne snage naglašavaju značaj prekvalifikacije, kontinuiranog usavršavanja i saradnje između poslodavaca i obrazovnih institucija kako bi zaposleni mogli prelaziti na zadatke koji zahtijevaju složenije analitičke i stručne sposobnosti [4], [5].

U kontekstu deskillinga, posebnu pažnju treba posvetiti mogućnostima učenja kroz rad. Ako AI preuzme jednostavne zadatke koje su početnici ranije obavljali pod nadzorom iskusnijih kolega, može se smanjiti broj prilika za razvoj osnovnih dijagnostičkih, analitičkih i tehničkih vještina. Taj ishod nije neizbježan: organizacije mogu nadomjestiti izgubljene prilike strukturisanim praktičnim zadacima, mentorstvom, rotacijom poslova i obavezom da zaposleni provjeravaju i obrazlažu rezultate AI sistema.

Istovremeno, dostupnost AI alata može otvoriti prostor za nove zadatke povezane s provjerom kvaliteta rezultata, upravljanjem podacima, procjenom rizika, sigurnošću i odgovornom primjenom automatizovanih sistema. Očuvanje zapošljivosti zato zavisi i od spremnosti zaposlenih da razvijaju nove kompetencije i od sposobnosti organizacija da osiguraju pravedne mogućnosti za obuku i profesionalni razvoj. Ove tvrdnje predstavljaju teorijski okvir za tumačenje stavova ispitanika, a ne dokaz da su navedeni ishodi već nastupili u organizacijama iz kojih dolaze ispitanici.

REZULTATI ISTRAŽIVANJA

Rezultati ankete pokazuju da je upotreba AI alata prisutna u svakodnevnom radu ispitanika: 81% navelo je da ih koristi najmanje jednom sedmično, dok ih 46% koristi svakodnevno.

U pogledu uticaja AI na poslovne procese, 86% ispitanika smatra da AI povećava produktivnost zaposlenih, dok 79% navodi da smanjuje vrijeme potrebno za izvršavanje rutinskih zadataka. Ovi rezultati ukazuju na to da ispitanici prepoznaju neposredne koristi alata u organizaciji svakodnevnog rada.

Stavovi o budućnosti radnih mjesta pokazuju određenu zabrinutost: 67% ispitanika smatra da će primjena AI u narednih pet godina smanjiti potrebu za pojedinim početnim IT pozicijama, dok 59% očekuje da će neki rutinski poslovi biti u potpunosti automatizovani.

Posebno je značajno da 72% ispitanika smatra da pretjerano oslanjanje na AI može dovesti do postepenog gubitka praktičnih znanja i vještina. Nadalje, 76% prepoznaje rizik da mlađi stručnjaci neće steći dovoljno iskustva u samostalnom rješavanju problema ako se previše oslanjaju na automatski generisana rješenja. Ovi nalazi odražavaju percepciju mogućeg rizika deskillinga i ne predstavljaju neposredno mjerenje stvarne promjene kompetencija.

Tabela 2 sažima ključne rezultate istraživanja. Procenti se prenose prema obradi odgovora iz ankete; njihovo tumačenje treba vezati za konkretne tvrdnje iz upitnika i način na koji su odgovori na Likertovoj skali grupisani.

Tabela 2. Stavovi zaposlenih prema AI

Tvrdnja	Udio ispitanika koji se slažu
AI povećava produktivnost zaposlenih	86%
AI smanjuje vrijeme potrebno za rutinske zadatke	79%
AI će smanjiti potrebu za pojedinim početnim IT pozicijama	67%
Pretjerano oslanjanje na AI može dovesti do deskillinga	72%
Kontinuirana edukacija zaposlenih je potrebna	91%

Diskusija rezultata

Rezultati ukazuju na dvostruku percepciju primjene AI u finansijskom i IT okruženju. S jedne strane, ispitanici prepoznaju povećanje produktivnosti i smanjenje vremena potrebnog za rutinske zadatke. S druge strane, izražavaju zabrinutost zbog smanjenja potrebe za pojedinim početnim IT pozicijama i mogućnosti da pretjerano oslanjanje na automatizovane alate oslabi razvoj praktičnih kompetencija. Takva kombinacija očekivanih koristi i rizika odgovara širem teorijskom pristupu prema kojem tehnološke promjene ne utiču samo na broj radnih mjesta nego i na sadržaj poslova i raspodjelu zadataka.

Nalazi se mogu razmatrati u odnosu na koncept tehnologijom omogućenog deskillinga koji opisuju Xue i saradnici [1]. Njihova analiza preduzeća u Kini za period 2007–2018 ukazuje na povezanost primjene AI s većim rastom potražnje za radnicima na poslovima koji zahtijevaju niži nivo formalnog obrazovanja u odnosu na poslove koji zahtijevaju viši nivo obrazovanja. Taj nalaz ne znači da se svaki AI sistem nužno povezuje sa smanjenjem vještina, nego ukazuje da automatizacija može promijeniti obrazovnu i kvalifikacionu strukturu rada. Rezultati ankete dopunjuju ovu raspravu informacijom da ispitanici prepoznaju rizik gubitka praktičnih znanja i smanjenja prilika za sticanje iskustva.

Za tumačenje rezultata važno je razlikovati tri nivoa promjene. Prvi je automatizacija pojedinačnih zadataka, odnosno preuzimanje aktivnosti koje su ranije obavljali zaposleni. Drugi je promjena zahtjeva radnog mjesta, kada se od zaposlenih očekuju drugačije kompetencije, na primjer provjera rezultata, nadzor sistema ili tumačenje analitičkih izlaza. Treći je mogući deskilling, koji može nastati ako smanjenje neposrednog učešća u zadacima ograniči prilike za razvijanje i održavanje praktičnih vještina. Anketa pruža uvid u stavove ispitanika o trećem nivou, ali ne dokazuje da se takav proces već dogodio.

Posebno su relevantni odgovori o zaposlenima na početku karijere. Rutinski zadaci mogu djelovati jednostavno, ali često omogućavaju učenje osnovnih postupaka, sistematsku dijagnostiku grešaka i razumijevanje šireg konteksta rada. Ako ih AI u velikoj mjeri preuzme, organizacije trebaju namjerno obezbijediti druge načine učenja: mentorstvo, simulacije, praktične zadatke, pregled i obrazlaganje AI izlaza te postepeno povećavanje složenosti radnih obaveza. U suprotnom postoji rizik da se očekivanja od početnika povećaju, dok se smanjuju prilike kroz koje oni tradicionalno stiču iskustvo.

Rezultat da 91% ispitanika smatra kontinuiranu edukaciju važnom dodatno naglašava značaj organizacijske podrške. Obuka ne bi trebala biti ograničena na tehničko korištenje AI alata, nego bi trebala obuhvatiti kritičku procjenu rezultata, zaštitu podataka, razumijevanje ograničenja modela, prepoznavanje grešaka i očuvanje samostalnih sposobnosti rješavanja problema. Takav pristup može pomoći da AI bude sredstvo proširivanja stručnih mogućnosti, a ne zamjena za učenje i profesionalnu procjenu.

Pri generalizaciji nalaza potrebno je uzeti u obzir ograničenja istraživanja. Uzorak od 138 ispitanika pruža uvid u stavove obuhvaćenih zaposlenih, ali bez dodatnih informacija o načinu odabira uzorka i njegovoj reprezentativnosti ne može se zaključiti da rezultati predstavljaju sve zaposlene u finansijskom sektoru. Uz to, podaci se zasnivaju na samoprocjeni i presječnom prikupljanju odgovora, pa ne omogućavaju utvrđivanje uzročnosti niti praćenje stvarne promjene kompetencija tokom vremena. Buduća istraživanja mogla bi kombinovati ankete s intervjuima, analizom promjena radnih zadataka i longitudinalnim mjerenjem kompetencija.

ZAKLJUČAK

Vještačka inteligencija postaje važan činilac transformacije poslovnih procesa i radnih uloga u finansijskom sektoru. Njena primjena može unaprijediti efikasnost, ubrzati obradu podataka i smanjiti vrijeme potrebno za rutinske aktivnosti. Istovremeno, automatizacija mijenja raspodjelu radnih zadataka i može uticati na kompetencije koje se očekuju od zaposlenih.

Rezultati ankete pokazuju da ispitanici prepoznaju koristi AI za produktivnost, ali i rizike povezane sa smanjenjem potrebe za pojedinim početnim IT pozicijama i mogućim slabljenjem praktičnih znanja. Posebno je važno da se rezultati o deskillingu tumače kao percepcija zaposlenih

o mogućim posljedicama pretjeranog oslanjanja na automatizovane sisteme, a ne kao neposredan dokaz da su njihove kompetencije već smanjene.

Nalazi upućuju na potrebu da organizacije prilikom uvođenja AI razmotre ne samo efikasnost i smanjenje troškova nego i posljedice po profesionalno učenje. Mentorstvo, praktičan rad, kontinuirana obuka i provjera rezultata AI sistema mogu pomoći zaposlenima da razvijaju nove kompetencije, uz očuvanje samostalnog razmišljanja i rješavanja problema.

Može se zaključiti da uspješna integracija AI u finansijski sektor zahtijeva ravnotežu između automatizacije i razvoja ljudskih potencijala. Tehnologija može preoblikovati radna mjesta bez njihovog nužnog potpunog ukidanja, ali način na koji se zadaci raspoređuju i kako se organizuje učenje ima važnu ulogu u očuvanju stručnosti. Buduća istraživanja trebala bi provjeriti da li se percipirani rizici deskillinga odražavaju u mjerljivim promjenama radnih zadataka i kompetencija zaposlenih.

CONFLICT OF INTEREST STATEMENT

The authors declare that there is no conflict of interest regarding the research presented in this paper.

LITERATURA

1. Xue, M., Cao, X., Feng, X., Gu, B., & Zhang, Y. (2022). The Effect of Artificial Intelligence (AI) on Firm Labor Structure. In T. X. Bui (Ed.), Proceedings of the 55th Annual Hawaii International Conference on System Sciences (pp. 7088–7097). IEEE Computer Society. https://hdl.handle.net/10125/80194
2. Chaya, R., & Salman, S. (2023). Artificial Intelligence (AI) and Its Application on Banking and Financial Services Sector in India: A Conceptual Study. *International Journal for Multidisciplinary Research, 5*(2). http://www.ijfmr.com
3. Zianko, V., & Nechyporenko, T. (2023). Artificial intelligence in the financial sector of Ukraine: A driver of development and a factor of modernization. Innovation and Sustainability, 3(3), 6–21. https://doi.org/10.31649/ins.2023.3.6.21
4. Rana, M., Sall, S., Bijoor, V. S., Gaiwad, V., Gaikwad, U. V., Patil, P., & Meher, K. (2024). Obstacles to the Full Realization and Adoption of Artificial Intelligence (AI). SEEJPH, 25.
5. Sidhu, G. S., Sayem, M. A., Taslima, N., Anwar, A. S., Chowdhury, F., & Rowshon, M. (2024). AI and workforce development: A comparative analysis of skill gaps and training needs in emerging economies. International Journal of Business and Management Sciences, 4(8). https://doi.org/10.55640/ijbms-04-08-03
6. Havryk, A., & Nazarova, T. (2024). Artificial intelligence and its role in the labor market and financial sector itself: US point of view. International Science Journal of Management, Economics & Finance, 3(3). https://doi.org/10.46299/j.isjmef.20240303.01
7. Jena, J. R., Biswal, S. K., Panigrahi, R. R., & Shrivastava, A. K. (2024). Investigating the Potential Areas in Artificial Intelligence and Financial Innovation: A Bibliometric Analysis. Journal of Scientometric Research, 13(1). https://doi.org/10.5530/jscires.13.1.6
8. Ma, Y. (2024). Impact of digital economy development on labor force employment. Highlights in Business, Economics and Management EERMR, 33.
9. Savardi, M., Signoroni, A., Benini, S., Vaccher, F., Alberti, M., Ciolli, P., Di Meo, N., Falcone, T., Ramanzin, M., Romano, B., Sozzi, F., & Farina, D. (2025). Upskilling or deskilling? Measurable role of an AI-supported training for radiology residents: A lesson from the pandemic. *Insights into Imaging, 16*, Article 23. https://doi.org/10.1186/s13244-024-01893-4
10. Tee, P. K., Wong, L. C., Dada, M., Song, B. L., & Ng, C. P. (2024). Demand for digital skills, skill gaps and graduate employability: Evidence from employers in Malaysia. F1000Research, 13. https://doi.org/10.12688/f1000research.148514.1

THE ROLE OF ARTIFICIAL INTELLIGENCE IN RESTRUCTURING IT JOBS: DESKILLING AND REDUCING THE NEED FOR ROUTINE TASKS IN THE FINANCIAL SECTOR

Alen Kamis[1], Jelena Ruzic[2], Stevan Stankovski[3], Aleksandra Markovic[4]

[1]The College of Service Business, Sokolac - East Sarajevo, Cara Lazara bb, Bosnia and Herzegovina
[2]Faculty of Project and Innovation Management, Bože Jankovića 14, Belgrade, Republic of Serbia
[3]University of Novi Sad, Faculty of Technical Sciences, Trg Dositeja Obradovića 6, Novi Sad, Republic of Serbia
[4]Toplička Academy of Applied Studies – Department of Business Studies, Kralja Petra I Karađorđevića 1, Blace, Republic of Serbia

ABSTRACT

This paper examines the impact of artificial intelligence (AI) on the transformation of IT jobs in the financial sector, focusing on the automation of routine tasks and the phenomenon of deskilling. Deskilling refers to changes in work organization that may reduce the skills required to perform particular tasks or limit employees' opportunities to develop and maintain practical knowledge and professional autonomy.

The empirical part is based on a survey of 138 respondents working in IT and financial settings. The questionnaire examined perceptions of AI use, task automation, job security, and changing competency requirements. The findings indicate that respondents recognize the potential of AI to increase productivity and reduce the time required for routine tasks. At the same time, they express concerns about reduced demand for some entry-level IT positions and the risk that excessive reliance on automated systems may weaken opportunities to develop practical skills.

The results highlight the importance of continuous professional development, mentoring, and preserving opportunities for independent problem-solving. Since the study relies on self-reported responses, the findings are interpreted as employees' perceptions of potential consequences rather than direct measurements of changes in their competencies.

Keywords: artificial intelligence, deskilling, IT jobs, financial sector, automation