

ITe@ 2026

XVIII međunarodni naučno-stručni skup
Informacione tehnologije za e-obrazovanje

ZBORNIK RADOVA PROCEEDINGS

25-26. 9. 2026.

Banja Luka



POKROVITELJI KONFERENCIJE
AKADEMIJA NAUKA I UMJETNOSTI REPUBLIKE SRPSKE
Agencija za informaciono-komunikacione tehnologije Republike Srpske

XVIII međunarodni naučno-stručni skup
Informacione tehnologije za e-obrazovanje

ITeO

ZBORNİK RADOVA PROCEEDINGS

UREDNICI

DALIBOR P. Drljača

DRAŽEN Marinković


SINIŠA Tomić

POKROVITELJI KONFERENCIJE:

Akademija nauka i umjetnosti Republike Srpske

Agencija za informaciono-komunikacione tehnologije Republike Srpske

SPONZORI KONFERENCIJE:



25 – 26. 9. 2026.

Banja Luka

XVIII međunarodni naučno-stručni skup Informacione tehnologije za e-obrazovanje

ZBORNİK RADOVA

Urednici:

Prof. dr Dalibor P. Drljača
Prof. dr Dražen Marinković
Prof. dr Siniša Tomić

Izdavač:

Panevropski univerzitet "APEIRON", Banja Luka, godina 2026.

Odgovorno lice izdavača:

DARKO Uremović

Glavni i odgovorni urednik izdavača:

Prof. dr ALEKSANDRA Vidović

Tehnički urednik:

SRETKO Bojić

Štampa:

Onlajn izdanje

EDICIJA:

Informacione tehnologije - **Information technologies**

Knjiga br. 43

ISBN 978-99976-87-76-0

Radove ili dijelove radova objavljene u Zborniku radova nije dozvoljeno prešampavati, bez izričite saglasnosti Uredništva. Stavovi i ocjene iznesene u radovima i dijelovima radova lični su stavovi autora i ne izražavaju uvijek i stavove Uredništva ili Izdavača.

ORGANIZACIONI ODBOR

Prof. dr Dražen Marinković, *Panevropski univerzitet APEIRON Banja Luka, BiH, predsjednik*

Prof. dr Siniša Tomić, *Panevropski univerzitet APEIRON Banja Luka*

Doc. dr Boris A. Kovačić, *Panevropski univerzitet APEIRON Banja Luka, BiH*

Sretko Bojić, *Panevropski univerzitet APEIRON Banja Luka, BiH, tehnički urednik*

Marko Milovanović, *Panevropski univerzitet APEIRON Banja Luka*

Hana Kunić, *Panevropski univerzitet APEIRON Banja Luka, BiH, PR konferencije*

Radovan Vučenović, *Panevropski univerzitet APEIRON Banja Luka, BiH*

Stana Mišić, *Panevropski univerzitet APEIRON Banja Luka, BiH, logistika*

POČASNI ODBOR

Akademik prof. dr Rajko Kuzmanović, *Akademija nauka i umjetnosti Republike Srpske*

Akademik prof. dr Dragoljub Mirjanić, *Akademija nauka i umjetnosti Republike Srpske*

Akademik prof. dr Dušan Starčević, *Akademija inženjerskih nauka Srbije*

Akademik prof. dr Zoran Ž. Avramović, *Akademija inženjerskih nauka Srbije*

Prof. dr Gordana Radić, *Panevropski univerzitet APEIRON Banja Luka*

Darko Uremović, *predsjednik Upravnog odbora Panevropskog univerziteta APEIRON*

Doc. dr Siniša Aleksić, *direktor Panevropskog univerziteta APEIRON*

NAUČNI ODBOR

Prof. dr Dalibor P. Drljača, *Panevropski univerzitet APEIRON Banja Luka, predsjednik*

Prof. dr Negovan Stamenković, *Univerzitet u Prištini, Srbija*

Prof. dr Ouajdi Corbaa, *Univesity of Sousse, Tunisia*

Prof. dr Ahmed Maalel, *Univesity of Sousse, Tunisia*

Prof. dr Branko Latinović, *Panevropski univerzitet APEIRON Banja Luka*

Prof. dr Siniša Tomić, *Panevropski univerzitet APEIRON Banja Luka*

Prof. dr Goran Đukanović, *Panevropski univerzitet APEIRON Banja Luka*

RECEZENTSKI ODBOR

Prof. dr Goran Đukanović, *Panevropski univerzitet APEIRON Banja Luka, predsjednik*

Doc. dr Tijana Talić, *Panevropski univerzitet APEIRON Banja Luka*

Prof. dr Željko Stanković, *Univerzitet UNION Nikola Tesla, Srbija*

SADRŽAJ:

KVANTNA BUDUĆNOST JE BLIŽE NEGO ŠTO MISLIMO	7
Aleš Gros THE QUANTUM FUTURE IS CLOSER THAN WE THINK	
SAJBER SIGURNOST AUTONOMNIH VOZILA: FEDERATIVNO UČENJE, KOMUNIKACIJSKI IZAZOVI I EKSPERIMENTALNA ANALIZA NAPADA	8
Prof.dr Vladimir Mladenović CYBERSECURITY FOR AUTONOMOUS VEHICLES: FEDERATED LEARNING, COMMUNICATION CHALLENGES, AND EXPERIMENTAL ATTACK ANALYSIS	
TARA: MODULARNA TROPROCESORSKA PLATFORMA IZVIĐAČKOG ROVERA ZA PODRŠKU OPERACIJAMA SPASAVANJA.....	10
Prof.dr Željko Stanković CYBERSECURITY FOR AUTONOMOUS VEHICLES: FEDERATED LEARNING, COMMUNICATION CHALLENGES, AND EXPERIMENTAL ATTACK ANALYSIS	
GENERATIVNA VJEŠTAČKA INTELIGENCIJA KAO PODRŠKA SAVREMENOM UX/UI DIZAJNERSKOM PROCESU.....	13
Milana Jović, Olja Krčadinac, Siniša Tomić	
VJEŠTAČKA INTELIGENCIJA I GIS U PREDIKCIJI I RANOJ DETEKCIJI ŠUMSKIH POŽARA.....	21
Saša Ljubojević, Branko Latinović ARTIFICIAL INTELLIGENCE AND GIS IN FOREST FIRE PREDICTION AND EARLY DETECTION	
INTEGRACIJA VJEŠTAČKE INTELIGENCIJE U ERP SISTEME ZA UNAPREĐENJE POSLOVNOG ODLUČIVANJA U BIH.....	27
Nataša Buzadžija INTEGRATION OF AI INTO ERP SYSTEMS FOR ENHANCING BUSINESS DECISION- MAKING IN BOSNIA AND HERZEGOVINA	
RAZVOJ ALGORITMA ZA AUTOMATSKO UPARIVANJE POSLODAVCA SA NAJPOGODNIJIM KANDIDATOM	33
Sandro Gatarić, Goran Đukanović DEVELOPMENT OF AN ALGORITHM FOR AUTOMATIC EMPLOYER-CANDIDATE MATCHING	
PERCEPCIJA I PRIHVATANJE GENERATIVNE VJEŠTAČKE INTELIGENCIJE: TEORIJSKI OKVIR I PRIJEDLOG BUDUĆEG ISTRAŽIVANJA.....	40
Lidija Žunić, Goran Đukanović	
EKONOMSKE POSLJEDICE RANSOMWARE NAPADA: PERSPEKTIVA UPRAVLJANJA RIZICIMA.....	53
Milan Panić, Negovan Stamenković, Aleksa Marčeta, Tijana Talić ECONOMIC CONSEQUENCES OF RANSOMWARE ATTACKS: A RISK MANAGEMENT PERSPECTIVE	
OTKRIVANJE RANJIVOSTI VEB APLIKACIJA PRIMJENOM CEH METODOLOGIJE.....	62
Sara Kukić DETECTION OF WEB APPLICATION VULNERABILITIES USING THE CEH METHODOLOGY	
ZNAČAJ INFORMACIONIH TEHNOLOGIJA U OSAVREMENJAVANJU NASTAVE	68
Slavojka Lazić, Zoran Ž. Avramović, Dražen Marinković	

PRIMJENA VJEŠTAČKE INTELIGENCIJE U PERSONALIZOVANOM UČENJU: KONCEPT I RAZVOJ OBRAZOVNE PLATFORME UČIM.ONLINE	74
Teo Milanković, Katarina Držajić Laketić	
APPLICATION OF ARTIFICIAL INTELLIGENCE IN PERSONALIZED LEARNING: CONCEPT AND DEVELOPMENT OF THE UČIM.ONLINE EDUCATIONAL PLATFORM	
DIGITALIZACIJA PROCESA UPRAVLJANJA STUDENTSKIM ZAVRŠNIM RADOVIMA – ANALIZA POTREBA I RAZVOJ WEB SISTEMA.....	80
Luka Lakobrija, Dražen Marinković	
DIGITALIZATION OF THE STUDENT THESIS MANAGEMENT PROCESS – NEEDS ANALYSIS AND DEVELOPMENT OF A WEB-BASED SYSTEM	
PRIMJENA BIOMETRIJSKOG PREPOZNAVANJA LICA U AUTOMATIZACIJI EVIDENCIJE PRISUSTVA U NASTAVI	92
Danijel Gajić, Tijana Talić	
APPLICATION OF BIOMETRIC FACE RECOGNITION IN AUTOMATING ATTENDANCE RECORDING IN TEACHING	
AUTOMATSKO TESTIRANJE I CI/CD PIPELINE U KONSTRUISANJU SOFTVERA – UTICAJ NA PRODUKTIVNOST I KVALITET	101
Anastasija Vasilčić, Dražen Marinković	
AUTOMATED TESTING AND CI/CD PIPELINE IN SOFTWARE CONSTRUCTION – IMPACT ON PRODUCTIVITY AND QUALITY	
PLATFORM INŽENJERING U ENTERPRISE KOMPANIJAMA: STUDIJA SLUČAJA IAC AUTOMATIZACIJE	107
Mišo Stamenić, Dražen Marinković, Zoran Ž. Avramović	
PLATFORM ENGINEERING IN ENTERPRISE COMPANIES: CASE STUDY OF IAC AUTOMATIZATION	
PROJEKTOVANJE I RAZVOJ SISTEMA ZA UPRAVLJANJE RADIOKOMUNIKACIONOM INFRASTRUKTUROM	112
Daniel Meničanin, Jelena Radanović, Dražen Marinković	
DESIGN AND DEVELOPMENT OF A SYSTEM FOR RADIO COMMUNICATION INFRASTRUCTURE MANAGEMENT	
MREŽNA SEGMENTACIJA I KONTROLA PRISTUPA U ZAŠTITI POSLOVNE MREŽE.....	123
Marko Majstorović	123
NETWORK SEGMENTATION AND ACCESS CONTROL IN BUSINESS NETWORK PROTECTION	
123	
SISTEMI ZA UPRAVLJANJE LABORATORIJSKIM INFORMACIJAMA (LIMS) OTVORENOG KODA.....	130
Igor Grujić, Mira Obradović	
OPEN SOURCE LABORATORY INFORMATION MANAGEMENT SYSTEMS (LIMS)	
DIGITALNE KOMPETENCIJE KAO TEMELJ OBRAZOVNE TRANSFORMACIJE: ANALIZA PRIMJENE DIGCOMP OKVIRA U REPUBLICI SRPSKOJ	138
Jefko Džino, Danijela Injac, Stefan Džino, Milan Dedić	

PLENARNA PREDAVANJA



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



KVANTNA BUDUĆNOST JE BLIŽE NEGO ŠTO MISLIMO

Aleš Gros

Principal Client Engineering Manager, EET at IBM

Sažetak: *Kvantno računarstvo više nije samo tema naučne fantastike, već tehnologija koja već danas menja način rešavanja najzahtevnijih naučnih, industrijskih i poslovnih izazova. Na predavanju će biti predstavljen razvoj IBM Quantum rešenja, najnovija dostignuća u oblasti kvantnih računara, kao i pogled u budućnost u kojoj će kvantni sistemi značajno dopunjavati mogućnosti klasičnog računarstva.*

Dodatno ćemo se osvrnuti i na uticaj kvantnih tehnologija na bezbednost podataka. Današnji sistemi šifrovanja zasnivaju se na matematičkim problemima koje će budući kvantni računari moći da rešavaju znatno brže. Zbog toga se već danas razvijaju novi pristupi post-quantnoj bezbednosti, koji će omogućiti zaštitu podataka i u eri kvantnih računara.

Predavanje će pružiti razumljiv uvid u kvantnu budućnost, njene mogućnosti za nauku i privredu, kao i odgovor na pitanje kako već danas možemo zaštititi podatke i digitalno poverenje od izazova koji nas očekuju u narednim decenijama.

Ključne riječi: *kvantno računarstvo, kvantum sistemi, IBM Quantum, bezbednost podataka*

THE QUANTUM FUTURE IS CLOSER THAN WE THINK

Abstract: *Quantum computing is no longer the realm of science fiction—it is a technology that is already transforming the way we approach some of the most complex scientific, industrial, and business challenges. This keynote will introduce the evolution of IBM Quantum, recent advances in quantum computing, and a vision of a future where quantum systems complement and extend the capabilities of classical computing.*

The presentation will also explore the impact of quantum technologies on data security. Today's encryption methods rely on mathematical problems that future quantum computers may be able to solve much more efficiently. As a result, new post-quantum security approaches are already being developed to ensure that sensitive data remains protected in the quantum era.

Attendees will gain an accessible overview of the quantum future, its opportunities for science and industry, and the key steps organizations can take today to protect data and digital trust against the challenges of the coming decades.

Keywords: *quantum computing, quantum systems, IBM Quantum, data security*



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



SAJBER SIGURNOST AUTONOMNIH VOZILA: FEDERATIVNO UČENJE, KOMUNIKACIJSKI IZAZOVI I EKSPERIMENTALNA ANALIZA NAPADA

Prof.dr Vladimir Mladenović

Fakultet tehničkih nauka u Čačku, Univerzitet u Kragujevcu

Sažetak: Autonomna vozila su složeni kibernetičko-fizički sistemi u kojima su integrisani vještačka inteligencija, senzorske tehnologije, komunikacijske mreže i upravljačke jedinice kako bi se osiguralo sigurno i pouzdano kretanje. Njihova povezanost s drugim vozilima, cestovnom infrastrukturom, rubnim računarstvom (edge computing) i uslugama u oblaku istovremeno proširuje površinu izloženu napadima. Kompromitovanje samo jednog čvora može ugroziti ne samo pojedinačno vozilo, već i pouzdanost cijele flote ili distribuiranog sistema.

Predstavljene su osnovne klase direktnih i indirektnih napada na autonomna i povezana vozila. Razmatrat će se ubacivanje zlonamjernih poruka u CAN mrežu, lažiranje GPS signala, manipulacija podacima LiDAR senzora, kompromitovanje elektronskih upravljačkih jedinica, napadi na V2X infrastrukturu i serverske sisteme, kao i distribuirani napadi uskraćivanja usluge (DDoS). Kroz primjere poznatih sigurnosnih incidenata prikazano je kako ranjivosti u komunikacijskim, upravljačkim ili perceptivnim komponentama mogu uticati na ponašanje vozila i sigurnost učesnika u saobraćaju.

Posebna pažnja posvećena je federativnom učenju kao pristupu koji omogućava više vozila da zajednički unaprijede model vještačke inteligencije bez rutinskog prijenosa sirovih lokalnih podataka. Objašnjeni su osnovni elementi ovog procesa: lokalna obuka, komunikacijski ciklusi, razmjena parametara, agregacija ažuriranja i formiranje globalnog modela. Istovremeno će se naglasiti da federativno učenje samo po sebi ne garantuje sigurnost, jer zlonamjerni ili kompromitovani učesnici mogu slati "otrovana" ažuriranja, ponavljati prethodno presretnute poruke ili narušiti dostupnost usluge.

U eksperimentalnom dijelu demonstrirano je kontrolisano okruženje za distribuirano federativno učenje i testirano šest scenarija: redovna zajednička obuka, trovanje modela, analiza mrežnog saobraćaja, uticaj kašnjenja i komunikacijskog opterećenja, napadi ponovnim slanjem (replay attacks) i DDoS napadi. Rezultati demonstracija omogućuju razmatranje razlika između laboratorijskog sistema i stvarnog okruženja autonomnih vozila, uključujući mobilnost čvorova, nestabilnu komunikaciju, heterogene lokalne podatke i kompromitovane upravljačke jedinice. Zaključujemo da pouzdana primjena distribuirane vještačke inteligencije u autonomnim vozilima zahtijeva objedinjavanje robusne agregacije, personalizovanog i hijerarhijskog federativnog učenja, kriptografske zaštite komunikacije, verifikacije identiteta i integriteta uređaja, kao i mehanizama prilagođenih stvarnim uslovima V2X mreža.

Ključne riječi: autonomna vozila, sajber sigurnost, federativno učenje, V2X komunikacije, trovanje modela, napad ponovnim slanjem (replay attack), DDoS napad.

CYBERSECURITY FOR AUTONOMOUS VEHICLES: FEDERATED LEARNING, COMMUNICATION CHALLENGES, AND EXPERIMENTAL ATTACK ANALYSIS

Abstract: Autonomous vehicles are complex cyber-physical systems in which artificial intelligence, sensor technologies, communication networks, and control units are integrated to ensure safe and reliable movement. Their connectivity with other vehicles, road infrastructure, edge computing, and cloud services simultaneously expands the attack surface. Compromising a single node can jeopardize not only an individual vehicle but also the reliability of the entire fleet or distributed system.

In this lecture, the basic classes of direct and indirect attacks on autonomous and connected vehicles will be presented. The injection of malicious messages into the CAN network, spoofing of GPS signals, manipulation of LiDAR sensor data, compromise of electronic control units, attacks on V2X infrastructure and server systems, as well as distributed denial of service attacks will be discussed. Using examples of well-known security incidents, it will be shown how vulnerabilities in the communication, control or perceptual components can affect the behavior of the vehicle and the safety of road users.

Special attention will be paid to federated learning as an approach that allows multiple vehicles to jointly improve an artificial intelligence model without routinely transmitting raw local data. The basic elements of this process will be explained: local training, communication rounds, parameter exchange, update aggregation and global model formation. At the same time, it will be emphasized that federated learning does not ensure security by itself, because malicious or compromised participants can send poisoned updates, repeat previously intercepted messages or disrupt service availability.

In the experimental part, a controlled environment for distributed federated learning will be demonstrated and six scenarios will be tested: regular joint training, model poisoning, network traffic analysis, impact of delay and communication load, replay attacks and DDoS attacks. The results of the demonstrations will serve to consider the differences between the laboratory system and the real environment of autonomous vehicles, including node mobility, unstable communication, heterogeneous local data and compromised control units.

The lecture concludes that the reliable application of distributed artificial intelligence in autonomous vehicles requires the unification of robust aggregation, personalized and hierarchical federated learning, cryptographic protection of communication, verification of the identity and integrity of devices, as well as mechanisms adapted to the real conditions of V2X networks.

Keywords: autonomous vehicles, cyber security, federated learning, V2X communications, model poisoning, replay attack, DDoS attack



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



TARA: MODULARNA TROPROCESORSKA PLATFORMA IZVIĐAČKOG ROVERA ZA PODRŠKU OPERACIJAMA SPASAVANJA

Prof.dr Željko Stanković

Fakultet za informatiku i računarstvo, Univerzitet UNION Nikola Tesla, Beograd

Sažetak: Operacije potrage i spašavanja (SAR) u vrlo ograničenim, podzemnim ili zadimljenim okruženjima katastrofa predstavljaju ozbiljne operativne izazove za autonomno i teleoperabilno robotsko raspoređivanje. Iako se zračni multirotorski dronovi široko koriste za brzo mapiranje na velikim visinama, njihov operativni opseg je drastično ograničen unutar urušenih struktura zbog ozbiljnog slabljenja višestrukog signala, potpunog nedostatka GPS-a, ograničene autonomije baterije i aerodinamičke turbulencije uzrokovane efektom tla koja inherentno neusklađuje i razrjeđuje očitavanja senzora plina u blizini tla. Predstavljamo sistem TARA, jeftinu, visoko otpornu, gusjeničnu izviđačku rover platformu koju pokreće asinhrona hardverska arhitektura s dva procesora (uključujući ESP32-WROVER sloj za koprocesiranje s integriranim PSRAM-om i neovisni AI-Thinker optički čvor) dizajnirana s determinističkom tolerancijom hardverskih i softverskih grešaka kao svojim osnovnim principom. TARA integriše robusnu matricu fuzije više senzora, uključujući 24 GHz FMCW radar za detekciju ljudskog disanja kroz prepreku, daleko infracrveno termalno snimanje, digitalne MEMS senzore gasa i FHSS LoRa telemetrijsku vezu protiv ometanja. Radeći pod strogom ugrađenom paradigmom "nedostaje ne znači sudar" (okvir MARKIZ 57), platforma garantuje neprekidno izvršavanje kritičnih kontrola motora i funkcija evidentiranja podataka čak i tokom katastrofalnih kvarova komunikacije senzora. Opsežna terenska validacija unutar simuliranih koridora za spašavanje pokazuje da rover uspješno postiže produženo mapiranje okoline na malim visinama, hardverski ubrzano AES-256-CBC telemetrijsko evidentiranje crne kutije i automatizovanu rekonstrukciju putanje tokom potpunih prekida radio veze. Rezultati dokazuju da se pouzdana, visoko otporna SAR robotika može uspješno postići korištenjem modularnih, pristupačnih hardverskih komponenti u kombinaciji sa slojevitim, nelinearnim ugrađenim topologijama upravljanja greškama.

Ključne riječi: robotika za potragu i spašavanje, tolerancija grešaka, arhitektura dvostrukog procesora, fuzija senzora

CYBERSECURITY FOR AUTONOMOUS VEHICLES: FEDERATED LEARNING, COMMUNICATION CHALLENGES, AND EXPERIMENTAL ATTACK ANALYSIS

Abstract: Search-and-rescue (SAR) operations in highly confined, subterranean, or smoke-filled disaster environments present severe operational challenges for autonomous and teleoperated robotic deployment. Although aerial multirotor drones are widely utilized for rapid high-altitude mapping, their operational envelope is drastically constrained within collapsed structures due to severe multi-path signal attenuation, total GPS deprivation, restricted battery autonomy, and aerodynamic ground-effect turbulence that inherently misaligns and dilutes gas sensor readings near the floor. This paper introduces TARA, a low-cost, highly resilient, tracked reconnaissance rover platform driven by an asynchronous dual-processor hardware architecture (including an ESP32-WROVER co-processing layer with integrated PSRAM and an

independent AI-Thinker optical node) designed with deterministic hardware and software fault tolerance as its core foundational principle. TARA integrates a robust multi-sensor fusion matrix including a 24 GHz FMCW radar for through-obstacle human respiration detection, far-infrared thermal imaging, digital MEMS gas sensors, and an anti-jamming FHSS LoRa telemetry link. Operating under the strict "missing does not equal crash" embedded paradigm (MARKIZ 57 framework), the platform guarantees uninterrupted execution of critical motor controls and data logging functions even during catastrophic sensor communication failures. Extensive field validation within simulated rescue corridors demonstrates that the rover successfully achieves prolonged low-altitude environmental mapping, hardware-accelerated AES-256-CBC black-box telemetry logging, and automated path reconstruction during complete radio blackouts. The results prove that dependable, highly resilient SAR robotics can be successfully achieved using modular, accessible hardware components combined with layered, non-linear embedded fault-management topologies.

Keywords: search-and-rescue robotics, fault tolerance, dual-processor architecture, sensor fusion

PRIHVAĆENI RADOVI



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



GENERATIVNA VJEŠTAČKA INTELIGENCIJA KAO PODRŠKA SAVREMENOM UX/UI DIZAJNERSKOM PROCESU

Milana Jović¹, Olja Krčadinac², Siniša Tomic³

¹Pan-European University APEIRON Banja Luka, milana.etfbl@gmail.com

²University Union Nikola Tesla, okrcadinac@unionnikolatesla.edu.rs, ORCID ID: 0000-0002-6299-371X

³Pan-European University APEIRON Banja Luka, sinisa.m.tomic@apeiron-edu.eu, ORCID ID: 0009-0007-6489-2692

Sažetak: Brz razvoj generativne vještačke inteligencije mijenja način na koji se realizuju pojedine aktivnosti u procesu projektovanja korisničkog interfejsa i korisničkog iskustva. Savremeni generativni modeli omogućavaju automatizaciju dijela poslova vezanih za razvoj početnih koncepata, generisanje varijanti korisničkog interfejsa, izradu wireframe modela i prototipova te obradu podataka prikupljenih tokom istraživanja korisnika. Cilj ovog rada je analizirati ulogu generativne vještačke inteligencije kao podrške savremenom UX/UI dizajnerskom procesu i utvrditi aktivnosti u kojima njena primjena donosi najveće prednosti. Posebna pažnja posvećena je raspodjeli zadataka između dizajnera i inteligentnih sistema. Analiza relevantne literature pokazuje da generativna AI može značajno ubrzati iterativni razvoj i povećati broj dizajnerskih alternativa, ali da kvalitet konačnog rješenja i dalje zavisi od razumijevanja korisničkih potreba, konteksta primjene i stručne evaluacije dizajnera. Zaključuje se da najefikasniji pristup nije potpuna automatizacija UX/UI procesa, već integracija generativne AI u radni tok u kojem tehnologija podržava kreativne i analitičke sposobnosti dizajnera.

Ključne riječi: Generativna vještačka inteligencija, UX, UI, korisničko iskustvo, korisnički interfejs, human-AI collaboration, AI-potpomognuti dizajn.

1. UVOD

Kvalitet korisničkog iskustva predstavlja jedan od važnih faktora uspjehnosti savremenih digitalnih proizvoda. Razvoj interaktivnih sistema zbog toga nije ograničen na implementaciju funkcionalnih zahtjeva, već uključuje razumijevanje potreba korisnika, projektovanje odgovarajućih obrazaca interakcije i kontinuiranu evaluaciju upotrebljivosti proizvoda. Principi dizajna usmjerenog prema korisniku podrazumijevaju aktivno uključivanje korisnika i iterativno unapređenje rješenja tokom različitih faza razvoja [1], [2].

Razvoj generativne vještačke inteligencije donosi nove mogućnosti za realizaciju takvog procesa. Veliki jezički i multimodalni modeli sposobni su da na osnovu tekstualnih instrukcija generišu sadržaj, programski kod i različite vizuelne prijedloge, čime njihova uloga prevazilazi tradicionalnu primjenu vještačke inteligencije zasnovanu prvenstveno na analizi i klasifikaciji podataka [3]. Integracija ovih tehnologija u dizajnerske i razvojne alate omogućava da se dio aktivnosti koje su ranije zahtijevale značajan manuelni rad izvršava automatski ili uz neposrednu podršku AI sistema.

U UX/UI dizajnu takve mogućnosti posebno dolaze do izražaja tokom razvoja početnih koncepata, wireframe modela, vizuelnih varijanti i interaktivnih prototipova. Generativni sistemi omogućavaju da dizajner u relativno kratkom vremenu dobije više mogućih rješenja istog problema, što mijenja tradicionalni proces u kojem se ograničen broj koncepata postepeno

razvija i unapređuje. Dosadašnja istraživanja ukazuju da AI može imati značajnu ulogu u podršci različitim kreativnim i dizajnerskim aktivnostima, ali istovremeno naglašavaju potrebu za očuvanjem ljudske kontrole nad procesom odlučivanja [4], [5]. Zbog toga pitanje primjene generativne AI u UX/UI dizajnu nije potrebno posmatrati isključivo kroz stepen automatizacije pojedinačnih aktivnosti. Značajnije pitanje odnosi se na način raspodjele zadataka između čovjeka i inteligentnog sistema. AI može efikasno generisati veliki broj prijedloga, obrađivati informacije i automatizovati repetitivne aktivnosti, dok razumijevanje potreba korisnika, procjena relevantnosti predloženog rješenja i donošenje strateških odluka zahtijevaju ljudsko stručno znanje. Ovakva komplementarnost predstavlja osnovu koncepta saradnje čovjeka i vještačke inteligencije, koji se sve češće razmatra kao odgovarajući okvir za integraciju AI sistema u profesionalne procese [6].

Cilj ovog rada je analizirati mogućnosti primjene generativne vještačke inteligencije kao podrške savremenom UX/UI dizajnerskom procesu, sa posebnim osvrtom na aktivnosti u kojima AI može povećati efikasnost rada i aktivnosti u kojima je neophodno zadržati dominantnu ulogu dizajnera. Rad se zasniva na analizi odabrane naučne literature iz oblasti interakcije čovjeka i računara, dizajna usmjerenog prema korisniku i saradnje čovjeka i AI sistema. Fokus je usmjeren na praktičnu raspodjelu uloga između dizajnera i generativnog AI sistema unutar dizajnerskog radnog toka.

U skladu sa navedenim ciljem, razmatraju se dva istraživačka pitanja: RQ1: U kojim aktivnostima savremenog UX/UI procesa generativna vještačka inteligencija može pružiti najveću podršku dizajneru? RQ2: Koje aktivnosti i odluke u AI-potpomognutom UX/UI procesu treba da ostanu dominantno u domenu ljudskog stručnjaka?

2. GENERATIVNA AI U SAVREMENOM UX/UI PROCESU

Generativna vještačka inteligencija u UX/UI dizajnu ne predstavlja potpuno novu metodologiju projektovanja, već prije svega novi skup mogućnosti unutar postojećeg dizajnerskog procesa. Za razliku od tradicionalnih softverskih alata, kod kojih dizajner neposredno oblikuje gotovo svaki element interfejsa, generativni sistemi mogu na osnovu tekstualnog opisa ponuditi strukturu sadržaja, korisnički tok, vizuelno rješenje ili čak dio funkcionalnog prototipa. Razvoj multimodalnih modela dodatno je proširio ove mogućnosti jer isti sistem može obrađivati i generisati različite vrste sadržaja [3]. Ipak, mogućnosti primjene nisu jednake u svim fazama UX/UI procesa. U istraživanju korisnika AI se uglavnom koristi kao pomoć pri obradi već prikupljenih podataka. Veliki jezički modeli mogu sažeti odgovore iz intervjua i anketa, grupisati slične komentare i pomoći u prepoznavanju tema koje se ponavljaju. To može znatno ubrzati početnu analizu, naročito kada je količina prikupljenih podataka velika. Problem nastaje kada rezultate treba interpretirati. Isti komentar korisnika može imati različito značenje u zavisnosti od okolnosti u kojima je proizvod korišten, prethodnog iskustva korisnika ili njegovih očekivanja. Takav kontekst nije uvijek sadržan u podacima koje AI analizira. Zbog toga razumijevanje potreba i ponašanja korisnika ostaje odgovornost istraživača i dizajnera, što je u skladu sa osnovnim principima dizajna usmjerenog prema čovjeku [1], [6].

Drugačija situacija postoji u fazi ideacije. Kada su problem i osnovni zahtjevi već definisani, generativni sistem može veoma brzo ponuditi različite načine organizovanja sadržaja, navigacije ili korisničkog toka. Njegova vrijednost ovdje nije prvenstveno u pronalaženju „najboljeg“ rješenja. Mnogo je značajnije to što dizajneru omogućava da za kratko vrijeme razmotri više mogućnosti nego što bi ih mogao razviti tradicionalnim postupkom. Ova prednost još je

izraženija pri izradi wireframe modela i početnih vizuelnih rješenja. Dizajner često izrađuje više varijanti istog ekrana, mijenja raspored elemenata ili ispituje različite načine predstavljanja sadržaja. Generativna AI može preuzeti dio tog operativnog posla i ponuditi nekoliko početnih varijanti koje se zatim mogu porediti, kombinovati i dalje razvijati [4], [5]. Time se ne uklanja kreativna uloga dizajnera. Naprotiv, njegov rad se djelimično pomjera sa same izrade prema izboru, procjeni i doradi ponuđenih rješenja. Sličan efekat vidljiv je i tokom prototipisanja. Generativni sistemi koji mogu kreirati programski kod omogućavaju da se početni vizuelni koncept brže pretvori u funkcionalni prototip. Vrijeme između ideje i prvog testiranja tako se skraćuje, što je posebno korisno u iterativnom razvoju. Umjesto dugog čekanja na prvu funkcionalnu verziju, razvojni tim može ranije provjeriti određene pretpostavke i na osnovu rezultata izvršiti korekcije. Brže prototipisanje, međutim, samo po sebi ne garantuje kvalitetnije korisničko iskustvo. Interfejs može biti tehnički funkcionalan i vizuelno uvjerljiv, a da ipak ne odgovara načinu na koji ga stvarni korisnici očekuju koristiti. AI-generisani prototip zato treba posmatrati kao prijedlog koji je potrebno provjeriti, a ne kao završeno rješenje. Ljudska kontrola i stručna evaluacija ostaju neophodan dio procesa [6].

Generativna AI može biti korisna i nakon testiranja proizvoda. Ako je prikupljen veliki broj korisničkih komentara, sistem može pomoći u njihovom razvrstavanju, sažimanju i pronalaženju problema koji se često ponavljaju. Dizajner tako brže dolazi do informacija potrebnih za narednu iteraciju. Ipak, odluka o tome koji problem treba riješiti prvi i koliko je on važan za cjelokupno korisničko iskustvo zahtijeva šire razumijevanje proizvoda i njegovih korisnika. Posmatrano u cjelini, generativna AI najviše koristi donosi u aktivnostima u kojima treba brzo proizvesti, obraditi ili varirati veći broj sadržaja i prijedloga. Njene mogućnosti su znatno ograničenije kada odluka zavisi od razumijevanja konteksta, prioriteta korisnika ili posljedica određenog dizajnerskog izbora. Zbog toga je primjerenije govoriti o AI-potpomognutom UX/UI dizajnu nego o automatizovanom dizajnu. Generativni sistem može ubrzati pojedine korake i proširiti broj mogućih rješenja, ali dizajner ostaje odgovoran za njihovu procjenu i konačan izbor. Upravo način na koji se te odgovornosti raspoređuju između čovjeka i AI predstavlja jedno od ključnih pitanja savremenog UX/UI procesa.

3. SARADNJA ČOVJEKA I AI U DIZAJNERSKOM PROCESU

Uvođenje generativne vještačke inteligencije u UX/UI dizajn mijenja odnos između dizajnera i alata koje koristi. Kod klasičnih dizajnerskih programa alat izvršava konkretnu naredbu, dok odluku o tome šta treba napraviti i na koji način donosi dizajner. Generativni sistemi uvode drugačiji način rada. Na osnovu zadatih zahtjeva oni mogu predložiti rješenje, ponuditi više varijanti ili razviti početni koncept koji dizajner zatim procjenjuje i mijenja. Zbog toga odnos između čovjeka i softvera sve više poprima karakter saradnje [5], [6]. Takva saradnja, međutim, ne podrazumijeva jednaku raspodjelu odgovornosti. AI je posebno efikasna u zadacima koji se mogu jasno opisati i koji zahtijevaju obradu velike količine informacija ili brzo generisanje većeg broja prijedloga. Dizajner može, na primjer, definisati osnovne zahtjeve interfejsa, a zatim koristiti generativni sistem za razvoj nekoliko početnih rješenja. Umjesto da vrijeme troši na izradu svake varijante, može se usmjeriti na njihovo poređenje i izbor elemenata koji najbolje odgovaraju konkretnom projektu. Upravo mogućnost brzog generisanja alternativa predstavlja jednu od važnijih promjena u načinu rada. Tradicionalni proces često je ograničen raspoloživim vremenom, pa se detaljnije razvija relativno mali broj ideja. Uz generativnu AI moguće je istražiti širi skup prijedloga prije donošenja odluke. To ne znači da će veći broj automatski proizvesti bolje rješenje, ali dizajneru pruža širi prostor za razmatranje različitih pristupa [4], [5].

S druge strane, određene aktivnosti teško je prenijeti na inteligentni sistem. Definisanje stvarnog problema koji proizvod treba da riješi jedan je od takvih primjera. Za to nije dovoljno poznavati formalne zahtjeve. Potrebno je razumjeti korisnike, njihove navike, očekivanja i okruženje u kojem koriste proizvod. Poslovni ciljevi organizacije takođe mogu biti u međusobnom konfliktu sa pojedinim zahtjevima korisnika, pa konačno rješenje često predstavlja kompromis koji zahtijeva stručno prosuđivanje.

Zbog toga ljudska uloga postaje posebno važna u trenucima kada treba procijeniti AI-generisani rezultat. Vizuelno kvalitetan interfejs nije nužno i dobar interfejs. Rješenje može izgledati savremeno, a istovremeno imati nejasnu navigaciju, nepotrebno komplikovan korisnički tok ili elemente koji nisu prilagođeni ciljnoj grupi. Dizajner mora biti sposoban da prepozna takve probleme i da ne prihvati prijedlog samo zato što je generisan brzo ili izgleda uvjerljivo. Ovakav način rada mijenja i dio kompetencija potrebnih UX/UI dizajneru. Poznavanje principa interakcije, vizuelnog dizajna i istraživanja korisnika ostaje osnov profesije, ali se tome pridružuje sposobnost efikasnog rada sa generativnim sistemima. Formulisanje jasnih instrukcija može značajno uticati na kvalitet rezultata, posebno kada se od modela zahtijeva da poštuje konkretna ograničenja ili razvije više varijanti istog koncepta. Ipak, kvalitetna instrukcija nije dovoljna. Još važnija postaje sposobnost procjene dobijenog rezultata. Dizajner koji dobro koristi AI nije samo osoba koja zna napisati odgovarajući prompt, već stručnjak koji može prepoznati šta je u generisanom rješenju korisno, šta treba izmijeniti, a šta odbaciti. U tom smislu AI pismenost podrazumijeva i razumijevanje ograničenja generativnih modela, a ne samo poznavanje načina njihovog korištenja [6]. Takva raspodjela uloga odgovara širem konceptu human-AI saradnje, prema kojem inteligentni sistem treba da dopunjuje ljudske sposobnosti umjesto da pokušava u potpunosti preuzeti proces odlučivanja [6]. U UX/UI dizajnu ova razlika je posebno značajna jer posljedice dizajnerskih odluka neposredno utiču na način na koji korisnik komunicira sa proizvodom. Praktično posmatrano, AI može imati dominantniju ulogu u generisanju prijedloga, varijacija i početnih artefakata, dok dizajner treba da zadrži kontrolu nad definisanjem problema, interpretacijom korisničkih potreba, izborom rješenja i njegovom konačnom evaluacijom. Granica između ovih aktivnosti nije potpuno fiksna i zavisi od vrste proizvoda, ciljne grupe i složenosti projekta. Zato razvoj generativne AI vjerovatno neće ukloniti potrebu za UX/UI dizajnerom, već će promijeniti dio njegovih svakodnevnih aktivnosti. Manje vremena može biti potrebno za rutinsku izradu pojedinačnih varijanti, dok veći značaj dobijaju analiza, procjena i donošenje odluka. U takvom procesu generativna AI ima ulogu inteligentnog pomoćnika, dok odgovornost za kvalitet konačnog korisničkog iskustva ostaje na čovjeku.

4. PREDNOSTI, OGRANIČENJA I IZAZOVI AI-POTPOMOGNUTOG UX/UI DIZAJNA

Primjena generativne vještačke inteligencije donosi niz prednosti koje mogu uticati na brzinu i organizaciju UX/UI procesa. Najvidljivija je mogućnost da se određene aktivnosti izvedu za znatno kraće vrijeme. Generisanje početnih koncepata, varijanti interfejsa ili dijelova prototipa više ne mora zahtijevati da dizajner svako rješenje izrađuje od početka. Time se više vremena može usmjeriti na analizu problema i procjenu ponuđenih rješenja [3], [5]. Brzina je posebno značajna u iterativnom razvoju. Kada je izmjene moguće realizovati brzo, razvojni tim može češće provjeravati različite ideje i ranije odbaciti one koje ne daju očekivane rezultate. Na taj način vrijednost generativne AI nije samo u skraćivanju vremena potrebnog za pojedinačan zadatak, već i u mogućnosti da se u okviru istog projekta ispita veći broj alternativa. To,

međutim, otvara i pitanje kvaliteta. Veći broj generisanih prijedloga ne znači da će među njima nužno biti rješenje koje odgovara stvarnim potrebama korisnika. Generativni model kreira rezultat na osnovu obrazaca naučenih iz podataka, dok informacije o konkretnom proizvodu, ciljnoj grupi ili poslovnom okruženju dobija prvenstveno kroz ulazne instrukcije. Ako su zahtjevi nepotpuni ili neprecizni, rezultat može biti vizuelno uvjerljiv, ali funkcionalno neodgovarajući. Jedno od ograničenja je i mogućnost pojave sličnih dizajnerskih obrazaca. Ako se razvoj interfejsa previše oslanja na automatski generisane prijedloge, postoji rizik da različiti proizvodi počnu koristiti sličnu organizaciju sadržaja, vizuelne elemente ili obrasce interakcije. U tom slučaju efikasnost generisanja može biti ostvarena na račun originalnosti i identiteta proizvoda. Ljudska kreativna intervencija zato ostaje važna ne samo zbog estetskog kvaliteta, nego i zbog prilagođavanja rješenja specifičnom kontekstu [4], [5].

Poseban problem predstavlja povjerenje u rezultate koje AI generiše. Korisnik sistema može pretpostaviti da je ponuđeno rješenje ispravno samo zato što djeluje detaljno i uvjerljivo. Takvo nekritičko prihvatanje posebno je problematično kada AI predlaže strukturu korisničkog toka, sadržaj interfejsa ili programski kod. Smjernice za interakciju čovjeka i AI sistema zbog toga naglašavaju potrebu da korisnik razumije mogućnosti sistema i zadrži kontrolu nad njegovim rezultatima [6]. Ograničenja nisu samo tehničke prirode. Upotreba generativne AI otvara pitanja privatnosti i načina na koji se podaci korisnika dostavljaju sistemima trećih strana. UX istraživanja mogu sadržavati intervjue, komentare i druge podatke koji nisu namijenjeni nekontrolisanoj obradi. Njihovo unošenje u generativni sistem zahtijeva procjenu načina čuvanja i obrade podataka, posebno kada je riječ o osjetljivim informacijama.

Pored privatnosti, značajna su pitanja algoritamske pristrasnosti i autorskih prava. Generisani sadržaj može odražavati obrasce i pristrasnosti prisutne u podacima na kojima je model razvijen, što se može prenijeti i na dizajnersko rješenje. Istovremeno, porijeklo pojedinih generisanih vizuelnih elemenata nije uvijek moguće jednostavno utvrditi. Zbog toga korištenje AI sadržaja u komercijalnim proizvodima zahtijeva više pažnje nego korištenje materijala čije je autorstvo i pravo upotrebe jasno definisano [4]. Pristupačnost predstavlja još jedno područje u kojem automatizacija zahtijeva kontrolu. Generativni sistem može kreirati vizuelno privlačan interfejs, a da pri tome ne uzme dovoljno u obzir čitljivost, logiku navigacije ili potrebe osoba sa različitim sposobnostima. Poštovanje principa human-centered dizajna zato se ne može pretpostaviti samo na osnovu činjenice da je model dobio zahtjev da generiše „dobar“ korisnički interfejs [1]. Na organizacionom nivou javlja se i pitanje načina uvođenja AI alata u postojeće radne procese. Njihova upotreba ima smisla kada uklanja nepotreban operativni rad ili olakšava istraživanje različitih mogućnosti. Ako se, međutim, AI uvodi samo sa ciljem maksimalnog smanjenja ljudskog angažmana, postoji opasnost da se automatizuju i aktivnosti kod kojih stručna procjena predstavlja važan dio kvaliteta procesa.

Zbog toga produktivnost ne bi trebalo da bude jedini kriterijum uspješnosti AI-potpomognutog dizajna. Brže izrađen interfejs nije nužno bolji interfejs, kao što ni veći broj generisanih varijanti sam po sebi ne predstavlja kvalitetniji dizajnerski proces. Relevantniji pokazatelj je odnos između ostvarene vremenske uštede i kvaliteta korisničkog iskustva koje je na kraju postignuto. Prednosti i ograničenja generativne AI zbog toga su međusobno povezani. Ista sposobnost koja omogućava brzo generisanje velikog broja rješenja može dovesti do nekritičkog prihvatanja prijedloga ili prevelikog oslanjanja na postojeće obrasce. Efikasna primjena zahtijeva da dizajner zna ne samo kada treba koristiti AI, već i kada njen rezultat treba provjeriti, izmijeniti ili potpuno odbaciti.

5. DISKUSIJA

Analiza pokazuje da se značaj generativne vještačke inteligencije u UX/UI dizajnu ne može svesti samo na automatizaciju pojedinačnih zadataka. Iako su ušteda vremena i brže generisanje sadržaja među njenim najočiglednijim prednostima, važnija promjena odnosi se na sam način organizovanja dizajnerskog procesa. Dizajner više ne mora razvijati svaku početnu ideju od nule, već može koristiti AI za stvaranje polaznih rješenja koja zatim procjenjuje, kombinuje i prilagođava. Takav pristup mijenja i način na koji se posmatra produktivnost. U tradicionalnom procesu vrijeme potrebno za izradu dodatne varijante često ograničava broj rješenja koja je moguće detaljnije razmotriti. Generativna AI smanjuje taj trošak i omogućava šire istraživanje mogućih pravaca razvoja. Njena vrijednost zato nije samo u tome što određeni zadatak može biti završen brže, već i u tome što se prije donošenja odluke može razmotriti više opcija [4], [5].

Ipak, rezultati razmatrane literature ne opravdavaju zaključak da veći stepen automatizacije nužno vodi kvalitetnijem korisničkom iskustvu. Upravo suprotno, aktivnosti koje imaju najveći uticaj na razumijevanje korisnika i određivanje ciljeva proizvoda pokazuju najmanji potencijal za potpuno prepuštanje generativnom sistemu. AI može analizirati prikupljene komentare ili predložiti moguću strukturu interfejsa, ali konačna procjena zavisi od konteksta koji nije uvijek moguće precizno izraziti kroz podatke i tekstualne instrukcije [1], [6]. Ovo je posebno važno kada se razmatra prvo istraživačko pitanje. Najveća praktična korist generativne AI može se očekivati kod razvoja početne ideje, izrade početnih wireframe modela, razvoja vizuelnih varijanti, prototipisanja i obrade već prikupljenih informacija. Zajednička karakteristika ovih aktivnosti jeste da rezultat predstavlja osnovu za narednu fazu rada, a ne konačnu odluku. Dizajner može brzo dobiti materijal za razmatranje, ali ga prije primjene mora procijeniti u odnosu na potrebe konkretnog proizvoda.

Odgovor na drugo istraživačko pitanje ukazuje na drugačiju grupu aktivnosti. Definisanje problema, razumijevanje korisnika, određivanje prioriteta, procjena kvaliteta predloženih rješenja i donošenje konačnih odluka trebalo bi da ostanu dominantno u domenu ljudskog stručnjaka. Razlog nije samo trenutno tehničko ograničenje generativnih modela. Ove aktivnosti uključuju odgovornost, razumijevanje šireg konteksta i prosuđivanje posljedica dizajnerskih odluka, što ih čini suštinski drugačijim od generisanja pojedinačnih artefakata. Na toj razlici zasniva se i model saradnje čovjeka i AI sistema. Umjesto nastojanja da se što veći dio procesa automatizuje, efikasniji pristup je odrediti u kojim aktivnostima tehnologija donosi stvarnu korist. AI tada preuzima dio operativnog opterećenja, dok dizajner zadržava kontrolu nad smjerom razvoja proizvoda. Takva raspodjela uloga odgovara principima prema kojima AI sistem treba da podržava ljudsko odlučivanje i omogućći korisniku odgovarajući nivo kontrole [6].

Promjena ima posljedice i na samu profesiju. Ako se dio vremena potrebnog za izradu početnih varijanti i prototipova smanji, veći značaj dobijaju sposobnosti koje je teže automatizovati: razumijevanje problema, komunikacija sa korisnicima, kritička analiza i procjena kvaliteta rješenja. Poznavanje generativnih sistema postaje dodatna kompetencija, ali ne može zamijeniti osnovna znanja iz UX/UI dizajna. Istovremeno, postojeća istraživanja još ne daju dovoljno osnova za precizno određivanje dugoročnih posljedica ovakvog načina rada. Posebno nedostaju rezultati koji bi pokazali da li povećanje produktivnosti tokom projektovanja dovodi i do mjerljivo boljeg korisničkog iskustva nakon implementacije proizvoda. Potrebna su istraživanja u kojima bi se tradicionalni i AI-potpomognuti proces upoređivali prema istim kriterijumima, uključujući vrijeme razvoja, upotrebljivost, zadovoljstvo korisnika i kvalitet konačnog rješenja.

Zbog toga bi buduća istraživanja trebalo manje usmjeravati na pitanje može li AI generisati određeni dizajnerski artefakt, a više na pitanje kakav je stvarni doprinos tog artefakta kvalitetu proizvoda. Takav pristup omogućio bi realnije sagledavanje mjesta generativne vještačke inteligencije u UX/UI procesu i jasnije razdvajanje tehnoloških mogućnosti od njihove praktične vrijednosti.

6. ZAKLJUČAK

Generativna vještačka inteligencija postaje sve značajniji dio savremenog UX/UI procesa, ali njenu ulogu nije opravdano posmatrati kao zamjenu za dizajnera. Rezultati ovog rada ukazuju da se njena najveća vrijednost ostvaruje kada se koristi za podršku aktivnostima koje zahtijevaju brzo generisanje sadržaja, obradu većih količina informacija i razvoj više alternativnih rješenja.

U odnosu na prvo istraživačko pitanje (RQ1), analiza pokazuje da generativna AI može pružiti najveću podršku tokom ideacije, razvoja wireframe modela, kreiranja vizuelnih varijanti i prototipisanja. Korisna je i pri obradi podataka prikupljenih istraživanjem i evaluacijom korisničkog iskustva. U svim ovim slučajevima osnovna prednost proizlazi iz smanjenja vremena potrebnog za operativne aktivnosti i mogućnosti da se u istom vremenskom periodu razmotri veći broj rješenja [3]–[5].

Takva ušteda vremena ne znači da se kvalitet korisničkog iskustva može automatizovati. Odgovor na drugo istraživačko pitanje (RQ2) pokazuje da definisanje problema, razumijevanje potreba korisnika, određivanje prioriteta i konačna procjena dizajnerskog rješenja treba da ostanu prvenstveno odgovornost čovjeka. Ove aktivnosti zavise od razumijevanja konteksta i stručnog prosuđivanja koje generativni sistem ne može pouzdano zamijeniti [1], [6].

Između potpune automatizacije i tradicionalnog manuelnog procesa zato se izdvaja AI-potpomognuti dizajn kao realniji model budućeg razvoja. U takvom pristupu generativna AI preuzima dio operativnih aktivnosti i proširuje broj mogućnosti koje dizajner može razmotriti, dok čovjek određuje ciljeve, kontroliše proces i donosi konačne odluke. Na taj način odnos između dizajnera i AI sistema postaje komplementaran.

Istovremeno, primjena generativnih sistema zahtijeva određeni oprez. Brzina generisanja ne garantuje kvalitet rezultata, a pretjerano oslanjanje na automatske prijedloge može dovesti do uniformnosti rješenja, zanemarivanja specifičnih potreba korisnika ili prihvatanja sadržaja koji nije dovoljno provjeren. Pitanja privatnosti, algoritamske pristrasnosti, pristupačnosti i autorskih prava dodatno potvrđuju potrebu da čovjek zadrži kontrolu nad procesom [4], [6].

Dalja istraživanja trebalo bi usmjeriti na empirijsko poređenje tradicionalnih i AI-potpomognutih UX/UI procesa. Posebno je važno utvrditi da li povećanje produktivnosti koje omogućava generativna AI dovodi i do mjerljivog poboljšanja upotrebljivosti i zadovoljstva krajnjih korisnika. Time bi se njena vrijednost mogla procjenjivati na osnovu kvaliteta ostvarenog korisničkog iskustva, a ne samo na osnovu količine generisanog sadržaja ili vremena potrebnog za njegovu izradu.

Može se zaključiti da budućnost generativne AI u UX/UI dizajnu prvenstveno zavisi od sposobnosti da se uspostavi odgovarajuća podjela zadataka između čovjeka i inteligentnog sistema. Generativna AI može učiniti dizajnerski proces bržim i fleksibilnijim, ali ljudsko razumijevanje korisnika, kritičko razmišljanje i odgovornost ostaju ključni za kvalitet konačnog proizvoda.

LITERATURA

- [1.] ISO, ISO 9241-210:2019 Ergonomics of Human-System Interaction—Part 210: Human-Centred Design for Interactive Systems. Geneva, Switzerland: International Organization for Standardization, 2019.
- [2.] D. A. Norman, The Design of Everyday Things, Revised and Expanded Edition. New York, NY, USA: Basic Books, 2013.
- [3.] OpenAI, “GPT-4 Technical Report,” arXiv preprint arXiv:2303.08774, 2023.
- [4.] H. H. Jiang et al., “AI Art and Its Impact on Artists,” in Proc. AAAI/ACM Conf. AI, Ethics, and Society (AIES), 2023.
- [5.] M. Muller et al., “Generative AI and Creative Work: Human–AI Collaboration in Design,” in Proc. ACM CHI Conf. Human Factors in Computing Systems, 2024.
- [6.] S. Amershi et al., “Guidelines for Human-AI Interaction,” in Proc. ACM CHI Conf. Human Factors in Computing Systems, 2019.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITEO 2026

Banja Luka, 25 - 26. 9. 2026. godine



VJEŠTAČKA INTELIGENCIJA I GIS U PREDIKCIJI I RANOJ DETEKCIJI ŠUMSKIH POŽARA

Saša Ljubojević¹, Branko Latinović²

¹JPŠ „Šume Republike Srpske“ a.d. Sokolac, sasa.ljubojevic@sumers.org

²Panevropski univerzitet APEIRON Banja Luka, branko.b.latinovic@apeiron-edu.eu

Apstrakt: Šumski požari, sve češći i intenzivniji usljed klimatskih promjena, među najozbiljnijim su prijetnjama šumama u regionu. U radu je dat pregled metoda vještačke inteligencije i geografskih informacionih sistema (GIS) u dvjema ključnim fazama zaštite: predikciji opasnosti od požara i ranoj detekciji. Analizirani su modeli zasnovani na znanju (AHP) i na podacima (Random Forest, gradijentni boosting, duboke neuronske mreže), kao i sistemi detekcije na satelitskom nivou, nivou kamera sa automatskim prepoznavanjem dima i nivou bespilotnih letjelica i senzora. Predložen je koncept integrisanog, slojevitog sistema za podršku odlučivanju za JPŠ „Šume Republike Srpske“, u kojem GIS objedinjuje karte opasnosti, alarme i operativne resurse. Najveći potencijal ima povezivanje prediktivne i detekcione komponente u jedinstven sistem.

Ključne riječi: šumski požari, vještačka inteligencija, GIS, rana detekcija

ARTIFICIAL INTELLIGENCE AND GIS IN FOREST FIRE PREDICTION AND EARLY DETECTION

Abstract: Forest fires, increasingly frequent and intense due to climate change, are one of the most serious threats to forests in the region. This paper reviews artificial intelligence (AI) and geographic information system (GIS) methods in two key phases of fire protection: fire danger prediction and early detection. Knowledge-driven (AHP) and data-driven models (Random Forest, gradient boosting, deep neural networks) are analysed, together with detection systems at the satellite level, the level of cameras with automatic smoke recognition, and the level of drones and sensors. A concept of an integrated, layered decision support system for the forestry enterprise “Šume Republike Srpske” is proposed, in which GIS combines danger maps, alarms and operational resources. The greatest potential lies in linking the predictive and detection components into a single system.

Key words: forest fires, artificial intelligence, GIS, early detection

1. UVOD

Klimatske promjene, koje karakterišu duži sušni periodi, toplotni talasi i smanjena vlažnost gorivog materijala, značajno povećavaju učestalost i intenzitet šumskih požara. Prema podacima Evropskog informacionog sistema za šumske požare (EFFIS), sezona 2025. bila je najrazornija od početka evidencije 2006. godine: u Evropskoj uniji izgorjelo je 1.079.538 ha, gotovo dvostruko više od prosjeka perioda 2006–2024 [1].

U Republici Srpskoj su požari tokom 2025. godine zahvatili 5.748 ha šuma [2], a i 2026. godina donijela je velike požare. Obim štete najviše zavisi od vremena koje protekne od nastanka

požara do početka gašenja: što je taj period duži, požar se širi na veću površinu, a šteta i troškovi gašenja brzo rastu.

Klasični sistem zaštite (osmatračnice, patrole, dojave građana) u suštini je reaktivan. Daljinska detekcija i mašinsko učenje (engl. machine learning – ML) omogućavaju proaktivan pristup, u kojem se opasnost procjenjuje unaprijed, a požar otkriva u početnoj fazi [3]. Geografski informacijski sistemi (GIS) pritom imaju ulogu zajedničke prostorne osnove koja povezuje podatke, modele i operativne službe [4]. Cilj rada je pregled rješenja zasnovanih na vještačkoj inteligenciji i GIS-u u predikciji i ranoj detekciji požara i prijedlog koncepta integrisanog sistema za JPŠ „Šume Republike Srpske“.

2. GIS KAO OSNOVA ZA PROCJENU OPASNOSTI OD POŽARA

Opasnost od požara je prostorno i vremenski promjenljiva veličina koja zavisi od statičkih faktora (reljef, vrsta vegetacije, blizina infrastrukture) i dinamičkih faktora (temperatura, vlažnost vazduha i goriva, vjetar). GIS omogućava da se ovi faktori predstavljaju kao rasterski slojevi jedinstvene rezolucije i kombinuju u integralni indeks rizika [5]. Najpoznatiji meteorološki indeks je kanadski indeks opasnosti od požara (engl. Fire Weather Index – FWI) [6], koji EFFIS koristi za izradu dnevnih prognoza opasnosti za cijelu Evropu [7].

Za procjenu dugoročnog (strukturnog) rizika često se koriste metode višekriterijumske analize, prije svega analitički hijerarhijski proces (AHP) [8], u kojem se težine faktora određuju ekspertskim poređenjem u parovima, uz provjeru konzistentnosti. U okviru istraživanja autora, koje se nastavlja na raniju GIS analizu CORINE Land Cover podataka o šumama Republike Srpske [9] i mapiranje rizika po važećoj metodologiji [10], izrađena je karta rizika od šumskih požara za teritoriju Bosne i Hercegovine primjenom AHP metode sa sedam faktora (tabela 1), među kojima je i udaljenost od puteva kao značajan antropogeni faktor; kartografski prikaz dobijenih klasa rizika objavljen je u [11]. Ta karta klasa rizika služi kao polazni sloj za planiranje preventivnih mjera. Nedostaci ovog pristupa – subjektivnost ekspertskih procjena i statičnost rezultata – mogu se ublažiti modelima vještačke inteligencije.

Tabela 1. Faktori i težine AHP modela rizika od šumskih požara za BiH

Faktor	Grupa faktora	Težina
Istorijski požari	istorijski	0,28
Nagib terena	topografski	0,22
Vegetacija (CORINE Land Cover)	vegetacijski	0,18
Temperatura	klimatski	0,14
Udaljenost od puteva	antropogeni	0,09
Udaljenost od naselja	antropogeni	0,05
Udaljenost od vodotoka	hidrografski	0,04

3. PREDIKCIJA POŽARA PRIMJENOM VJEŠTAČKE INTELIGENCIJE

Modeli zasnovani na podacima uče vezu između faktora i pojave požara iz istorijskih evidencija, a predikcija opasnosti je jedna od najzastupljenijih oblasti primjene mašinskog učenja u nauci o požarima [3]. Najčešće korišćeni algoritmi su ansambl stabala odlučivanja – Random Forest [12] i gradijentni boosting (XGBoost, LightGBM) – koji daju i mjeru važnosti ulaznih promjenljivih. Studije za mediteranski dio Evrope pokazale su da Random Forest nadmašuje klasičnu regresiju u modelovanju prostornog rasporeda požara [13]. Kondylatos i saradnici [14] primjenom dubokih mreža LSTM i ConvLSTM predviđeli su opasnost od požara za naredni dan na području Grčke i pokazali da modeli dubokog učenja postižu bolje rezultate od klasičnih pristupa.

Za operativnu primjenu preporučuje se hibridni pristup, koji povećava i objašnjivost modela: karta strukturnog rizika dobijena AHP metodom [11] koristi se kao ulazni sloj i referenca za model mašinskog učenja, a dinamička komponenta (meteorološka prognoza, vlažnost vegetacije procijenjena satelitskim indeksima NDVI i NDMI) daje dnevnu prognozu opasnosti. Glavno ograničenje u regionu predstavljaju istorijski podaci: evidencije o požarima često nisu georeferencirane ili su vezane samo za odjeljenje [15], pa se kao dopunski izvor koriste satelitski proizvodi o aktivnim požarima i opožarenim površinama [16, 17].

4. RANA DETEKCIJA POŽARA

Cilj rane detekcije je da skрати vrijeme od nastanka požara do alarma. Savremeni sistemi rade na tri nivoa koji se međusobno dopunjuju [18] (tabela 2).

4.1. Satelitski nivo

Senzori MODIS i VIIRS detektuju termalne anomalije u srednjem infracrvenom dijelu spektra, sa rezolucijom od 1 km, odnosno 375 m [16, 19], a podaci su javno dostupni gotovo u realnom vremenu kroz sistem FIRMS. Ograničenja su mali broj preleta dnevno i nemogućnost otkrivanja malih požara, što rješava nova generacija konstelacija: OroraTech šalje alarm tri minuta nakon preleta, zahvaljujući obradi snimaka na samom satelitu [20], a konstelacija FireSat (Earth Fire Alliance, Muon Space, Google Research) detektuje žarišta veličine 5×5 m, uz cilj da sa oko 50 satelita postigne interval ponovnog snimanja od 20 minuta [21]. U regionu je značajan sistem NIMOS Instituta za nizijsko šumarstvo i životnu sredinu, koji pomoću satelitskih snimaka i alata vještačke inteligencije prati stanje šuma [22].

4.2. Terestrički nivo, bespilotne letjelice i senzori

Kamere sa algoritmima za automatsko prepoznavanje dima i plamena danas su najzrelija tehnologija rane detekcije. Konvolucione neuronske mreže (CNN) postižu visoku tačnost u klasifikaciji prizora sa požarom [23], a detektori objekata (npr. YOLO) omogućavaju lokalizaciju dima u realnom vremenu. Presijecanjem azimuta dvije ili više kamera i digitalnog modela terena GIS automatski određuje lokaciju požara. Primjer iz neposrednog okruženja je hrvatski sistem OIV Fire Detect AI, razvijen u saradnji sa FESB-om iz Splita, koji obuhvata 282 kamere na 143 lokacije [24]. Bespilotne letjelice sa termalnim kamerama služe za potvrdu alarma. Bežične senzorske mreže (temperatura, vlažnost, gasovi) uz modele mašinskog učenja


otkrivaju požar i bez optičke vidljivosti [25], ali pokrivaju male površine i pogodne su za zaštitu vrijednih lokacija.

Tabela 2. Upporedni prikaz nivoa rane detekcije (orijentacione vrijednosti)

Nivo	Pokrivenost / rezolucija	Kašnjenje alarma	Glavna ograničenja
Sateliti MODIS / VIIRS	globalna; 1 km / 375 m	sati	rijetki preleti, oblaci, mali požari
Nove satelitske konstelacije	globalna; žarište od 5x5 m	minuti	cijena, faza uvođenja
Kamere sa vještačkom inteligencijom	regionalna; desetine km ² po lokaciji	minuti	linija vidljivosti, lažni alarmi
Bespilotne letjelice	lokalna	na zahtjev	autonomija leta, propisi
Senzorske mreže	vrlo lokalna	minuti	gustina mreže, napajanje, veza

5. PREDLOŽENI KONCEPT INTEGRISANOG SISTEMA

Tehnologije daju puni efekat tek kada su povezane u jedinstven tok podataka (slika 1). Sloj podataka objedinjuje statičke GIS slojeve (digitalni model terena, sastojinske karte, putevi, naselja, istorijski požari), otvorene satelitske podatke (Copernicus, FIRMS), meteorološke prognoze i tokove sa kamera i senzora. U analitičkom sloju prediktivni modul na osnovu hibridnog AHP/ML modela svakodnevno generiše kartu opasnosti za naredna 1–3 dana po gazdinstvima i odjeljenjima, a detekcioni modul u realnom vremenu analizira termalne anomalije i snimke kamera. Karta opasnosti usmjerava detekciju: u zonama visoke opasnosti snižava se prag za alarm, a patrolne i letjelice raspoređuju se prioritarno.



Slika 1. Slojeviti koncept sistema za predikciju i ranu detekciju šumskih požara

Web GIS platforma sve ove informacije prikazuje korisnicima na jednoj karti. Povratna sprega – potvrda ili odbacivanje alarma i georeferencirana evidencija svakog požara – vraća se u sloj podataka i koristi za ponovno treniranje modela.

Uvođenje je realno sprovesti u fazama: (1) georeferenciranje evidencije požara i povezivanje sa servisima EFFIS i FIRMS; (2) dnevna karta opasnosti na osnovu postojeće AHP karte i meteoroloških prognoza; (3) pilot mreža kamera sa vještačkom inteligencijom u gazdinstvima najviše klase rizika; (4) ML modeli i integracija sa civilnom zaštitom.

6. IZAZOVI I PREPORUKE

Glavni izazovi su nedostatak georeferenciranih istorijskih podataka, lažni alarmi (magla, prašina, dim od spaljivanja), slaba telekomunikaciona pokrivenost planinskih područja, troškovi, te potreba za obukom kadrova i jasnim procedurama postupanja po alarmu. Budući da požari ne poznaju granice, preduslov efikasne primjene je razmjena podataka među institucijama i regionalno povezivanje sistema.

7. ZAKLJUČAK

Vještačka inteligencija i GIS mijenjaju zaštitu šuma od požara iz reaktivne u proaktivnu djelatnost. Prediktivni modeli omogućavaju da se resursi rasporede prije nego što požar nastane, a sistemi rane detekcije značajno skraćuju vrijeme od nastanka požara do njegovog otkrivanja i prijavljivanja. Sateliti obezbjeđuju široku prostornu pokrivenost, kamere brzo uočavanje dima i vatre, a GIS objedinjuje prostorne, meteorološke i operativne podatke i pretvara ih u informacije pogodne za donošenje odluka.

Primjena ovakvog sistema u JPŠ „Šume Republike Srpske“ a.d. Sokolac mogla bi doprinijeti preciznijem određivanju područja povećanog rizika, efikasnijem raspoređivanju ljudstva i opreme, bržem reagovanju i smanjenju štete na šumskim ekosistemima. Tehnologija pritom ne može zamijeniti stručno znanje i iskustvo zaposlenih, već treba da služi kao podrška u odlučivanju, a uspjehnost sistema zavisiće i od obučenosti korisnika, redovnog ažuriranja podataka i institucionalne saradnje. Dalja istraživanja autora usmjerena su na validaciju hibridnog AHP – Random Forest modela na istorijskim podacima o požarima i pilot-primjenu dnevne karte opasnosti na odabranom području.

REFERENCE

- [1] European Commission, JRC, 2025 was EU's most destructive wildfire season on record, 2026, <https://joint-research-centre.ec.europa.eu> (pristupljeno 11.9.2026.)
- [2] Šumarstvo na prekretnici: suše i požari ruše planove, ZOS media, 24.8.2026., <https://www.zosmedia.ba> (pristupljeno 11.9.2026.)
- [3] P. Jain et al., A review of machine learning applications in wildfire science and management, *Environmental Reviews*, 28(4), 478–505, 2020.
- [4] S. Ljubojević, Ž. Stanković, Upotreba geografskih informacionih sistema za zaštitu od šumskih požara, *Zbornik radova ITeO 2021*, Panevropski univerzitet APEIRON, Banja Luka, 248–253, 2021.
- [5] E. Chuvieco et al., Development of a framework for fire risk assessment using remote sensing and geographic information system technologies, *Ecological Modelling*, 221(1), 46–58, 2010.
- [6] C. E. Van Wagner, Development and structure of the Canadian Forest Fire Weather Index System, *Forestry Technical Report 35*, Canadian Forestry Service, Ottawa, 1987.
- [7] J. San-Miguel-Ayaz et al., Comprehensive monitoring of wildfires in Europe: the European Forest Fire Information System (EFFIS), in: *Approaches to Managing Disaster*, InTech, Rijeka, 87–108, 2012.
- [8] T. L. Saaty, *The Analytic Hierarchy Process*, McGraw-Hill, New York, 1980.
- [9] S. Ljubojević, B. Latinović, Analiza podataka o šumama prikupljenih daljinskom detekcijom na teritoriji Republike Srpske, *Zbornik radova ITeO 2022*, Panevropski univerzitet APEIRON, Banja Luka, 312–316, 2022.

- [10] S. Ljubojević, B. Latinović, Mapiranje rizika od šumskih požara na teritoriji Republike Srpske prikazano pomoću GIS-a, Zbornik radova XII konferencije STED, Univerzitet PIM, Trebinje, 376–381, 2023, doi: 10.7251/PIMZ2301376L.
- [11] O. Krčadinac, S. Ljubojević, B. Latinović, Analysing road proximity to forest areas as a wildfire risk factor in Bosnia and Herzegovina, Proc. of the 5th Int. Conf. on Sustainable Environment and Technologies, Union – Nikola Tesla University, Belgrade, 126–133, 2025.
- [12] L. Breiman, Random Forests, Machine Learning, 45(1), 5–32, 2001.
- [13] S. Oliveira et al., Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest, Forest Ecology and Management, 275, 117–129, 2012.
- [14] S. Kondylatos et al., Wildfire danger prediction and understanding with deep learning, Geophysical Research Letters, 49(17), e2022GL099368, 2022.
- [15] S. Ljubojević, Z. Ž. Avramović, Architecture of GIS solutions for detection and development of wildfire database, JITA – Journal of Information Technology and Applications, 11(2), 123–130, 2021, doi: 10.7251/JIT2102123L.
- [16] L. Giglio et al., The collection 6 MODIS active fire detection algorithm and fire products, Remote Sensing of Environment, 178, 31–41, 2016.
- [17] S. Ljubojević, B. Latinović, Prikaz pojave šumskih požara evidentiranih pomoću MODIS-a na teritoriji Republike Srpske i prikazanih u GIS-u, Zbornik radova XI konferencije STED, Univerzitet PIM, Trebinje, 96–101, 2022.
- [18] P. Barmpoutis et al., A review on early forest fire detection systems using optical remote sensing, Sensors, 20(22), 6442, 2020.
- [19] NASA, Fire Information for Resource Management System (FIRMS), <https://firms.modaps.eosdis.nasa.gov> (pristupljeno 11.9.2026.)
- [20] OroraTech, Three-minute on-orbit fire detection with satellite constellation, 2023, <https://ororatech.com> (pristupljeno 11.9.2026.)
- [21] eoPortal, FireSat constellation, <https://www.eoportal.org> (pristupljeno 11.9.2026.)
- [22] Srbija uvodi pametni monitoring šuma – projekat NIMOS, Politika, 2026, <https://www.politika.rs> (pristupljeno 11.9.2026.)
- [23] K. Muhammad et al., Early fire detection using convolutional neural networks during surveillance for effective disaster management, Neurocomputing, 288, 30–42, 2018.
- [24] Zaštita od požara sa 282 AI kamere na 143 lokacije, Bug.hr, 2026, <https://www.bug.hr> (pristupljeno 11.9.2026.)
- [25] U. Dampage et al., Forest fire detection system using wireless sensor networks and machine learning, Scientific Reports, 12, 46, 2022.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



INTEGRACIJA VJEŠTAČKE INTELIGENCIJE U ERP SISTEME ZA UNAPREĐENJE POSLOVNOG ODLUČIVANJA U BIH

Nataša Buzadžija

JS Logistic Services, Banja Luka, BiH, natasa.buzadzija@gmail.com

Sažetak: Savremeno poslovanje karakteriše intenzivna digitalna transformacija i rastuća primjena naprednih informacionih tehnologija, među kojima vještačka inteligencija zauzima značajno mjesto. ERP sistemi predstavljaju ključnu infrastrukturu za integraciju poslovnih procesa, ali tradicionalni ERP sistemi često imaju ograničenja u pogledu prediktivne analitike, automatizacije odlučivanja i adaptivnosti na promjene u poslovnom okruženju. Integracija vještačke inteligencije u sisteme za planiranje resursa preduzeća predstavlja trenutno jedan od najznačajnijih pravaca u digitalnoj transformaciji poslovanja. U fokusu rada biće sama tranzicija sa reaktivnih sistema, koji bilježe šta se desilo na proaktivne sisteme, koji predviđaju šta će se desiti. Problem koji ovaj rad opisuje je niska stopa iskorištenosti nestrukturiranih podataka u standardnim ERP modulima i nedostatak agilnosti u reaktivnim poslovnim modelima.

Osnovni cilj rada je definisanje teorijskog i praktičnog modela integracije vještačke inteligencije u ERP arhitekturu. Rad istražuje sinergiju mašinskog učenja (ML), obrade prirodnog jezika (NLP) i robotske automatizacije procesa (RPA) unutar ključnih modula kao što su finansije, lanac snabdijevanja i upravljanje ljudskim resursima.

Istraživanje ukazuje na to da integracija vještačke inteligencije u ERP sisteme predstavlja značajan korak ka razvoju inteligentnih poslovnih sistema koji omogućavaju adaptivno i proaktivno upravljanje poslovnim procesima. Naučni doprinos rada ogleda se u definisanju modela integracije vještačke inteligencije u ERP sisteme i identifikaciji ključnih faktora uspješne implementacije, dok praktični doprinos obuhvata smjernice za organizacije koje planiraju unapređenje postojećih ERP sistema primjenom tehnologija vještačke inteligencije.

Ključne riječi: Vještačka inteligencija, ERP, Mašinsko učenje, Digitalna transformacija

INTEGRATION OF AI INTO ERP SYSTEMS FOR ENHANCING BUSINESS DECISION-MAKING IN BOSNIA AND HERZEGOVINA

Abstract: Modern business is characterized by intensive digital transformation and the increasing use of advanced information technologies, among which artificial intelligence occupies a significant role. Enterprise Resource Planning (ERP) systems represent a key infrastructure for the integration of business processes; however, traditional ERP systems often face limitations in predictive analytics, automated decision-making, and adaptability to changes in the business environment. The integration of artificial intelligence into enterprise resource planning systems currently represents one of the most significant directions in business digital transformation. This paper focuses on the transition from reactive systems, which record what has already happened, to proactive systems capable of predicting future events. The problem addressed in this paper is the low utilization rate of unstructured data within standard ERP modules and the lack of agility in reactive business models.

The primary objective of this paper is to define a theoretical and practical model for integrating artificial intelligence into ERP architecture. The research explores the synergy of Machine Learning (ML), Natural

Language Processing (NLP), and Robotic Process Automation (RPA) within key modules such as finance, supply chain, and human resource management.

The research indicates that the integration of artificial intelligence into ERP systems represents a significant step toward the development of intelligent business systems that enable adaptive and proactive management of business processes. The scientific contribution of the paper is reflected in defining a model for integrating artificial intelligence into ERP systems and identifying key factors for successful implementation, while the practical contribution includes guidelines for organizations planning to enhance existing ERP systems through the application of artificial intelligence technologies.

Key words: Artificial Intelligence, ERP, Machine Learning, Digital Transformation

1. UVOD

Digitalna transformacija postala je neizostavan element savremenog poslovanja, omogućavajući optimizaciju operacija, smanjenje troškova i povećanje agilnosti [6]. Za mala i srednja preduzeća (MSP), digitalizacija donosi visoku operativnu efikasnost, ali i izazove poput resursnih ograničenja, nedostatka vještina i neadekvatne infrastrukture [9]. Paralelno sa razvojem informacionih sistema, vještačka inteligencija (AI) se nametnula kao jedna od nosivih tehnologija četvrte industrijske revolucije [11].

Tradicionalni ERP sistemi primarno su projektovani za prikupljanje, obradu i skladištenje strukturiranih podataka, pri čemu donošenje poslovnih odluka i dalje zavisi od ljudske interpretacije izvještaja [2], [8]. Međutim, u uslovima masovnog priliva nestrukturiranih podataka, klasični ERP sistemi pokazuju ograničenja u pravovremenom prepoznavanju poslovnih trendova. Integracija AI tehnologija – poput mašinskog učenja (ML), dubokog učenja i obrade prirodnog jezika (NLP) – pretvara pasivne ERP sisteme u proaktivne platforme koje nude prediktivnu analitiku i automatizaciju odlučivanja [5], [12].

Predmet ovog rada jeste istraživanje mogućnosti integracije vještačke inteligencije u ERP sisteme radi unapređenja procesa donošenja poslovnih odluka, sa posebnim osvrtnom na specifičnosti poslovnog okruženja u Bosni i Hercegovini. Naučni doprinos rada ogleda se u definisanju konceptualnog modela AI-ERP integracije, dok praktični doprinos obuhvata smjernice za faznu implementaciju ovih rješenja u sektoru malih i srednjih preduzeća.

2. TEORIJSKI OKVIR

Sistemi za planiranje resursa preduzeća (ERP) čine osnovu digitalne infrastrukture savremenih organizacija. Oni objedinjuju poslovne funkcije u jedinstvenu cjelinu, povećavajući transparentnost i smanjujući operativne troškove [1], [8]. Iako su istorijski bili rezervisani za velika preduzeća, razvoj cloud tehnologija omogućio je masovniju primjenu ERP sistema i među malim i srednjim preduzećima [1].

Mala i srednja preduzeća predstavljaju okosnicu privrede Bosne i Hercegovine. Primjena ERP-a u ovim preduzećima donosi brže odlučivanje, bolju kontrolu troškova i optimizaciju zaliha [10]. Međutim, stepen digitalne zrelosti domaćih preduzeća i dalje zaostaje za prosjekom Evropske unije [7]. Glavne prepreke obuhvataju visoke troškove, otpor zaposlenih prema promjenama, niske digitalne kompetencije i neadekvatan kvalitet podataka [7], [9]. Inicijative poput EU4DigitalSME i EBRD programa pružaju podršku digitalizaciji [3], [4], ali mnogi ERP

sistemi u Bosni i Hercegovini i dalje funkcionišu isključivo kao reaktivni sistemi za evidenciju [7].

U okviru ERP sistema posebno su značajne tehnologije mašinskog učenja, prediktivne analitike i obrade prirodnog jezika [5]. Mašinsko učenje omogućava prepoznavanje obrazaca u poslovnim podacima i predviđanje budućih događaja, prediktivna analitika podržava planiranje prodaje, zaliha i finansijskih tokova, dok NLP omogućava automatizovanu obradu tekstualnih dokumenata i komunikaciju korisnika sa sistemom [5], [12]. Njihovom integracijom ERP sistemi mogu pružiti kvalitetnije i pravovremenije informacije za poslovno odlučivanje [12].

Integracija AI u ERP sisteme (stvaranje tzn. inteligentnih ERP ili iERP sistema) omogućava prelazak sa istorijske analitike na prediktivno i autonomno poslovanje. AI rješenja nalaze primjenu u ključnim modulima [5], [12]:

Finansije: detekcija anomalija, automatizacija izvještaja i predviđanje novčanih tokova.

Lanac snabdijevanja: predviđanje potražnje i optimizacija zaliha.

Ljudski resursi (HR): analiza performansi i automatizacija selekcije kadrova.

Prodaja i CRM: personalizacija ponuda i analiza ponašanja kupaca.

3. METODOLOGIJA ISTRAŽIVANJA

Istraživanje se zasniva na teorijskom pristupu i sistematskoj analizi relevantne naučne i stručne literature iz oblasti vještačke inteligencije (AI) i ERP sistema. Istraživački proces sproveden je u tri faze.

Prva faza istraživanja obuhvata identifikaciju i analizu teorijskih osnova vještačke inteligencije i ERP sistema, sa posebnim fokusom na njihovu evoluciju, funkcionalnosti i ulogu u digitalnoj transformaciji poslovanja [1], [6], [8]. Druga faza istraživanja usmjerena je na pregled savremene literature koja razmatra mogućnosti integracije tehnologija vještačke inteligencije, uključujući mašinsko učenje (Machine Learning – ML), obradu prirodnog jezika (Natural Language Processing – NLP), prediktivnu analitiku i robotsku automatizaciju procesa (Robotic Process Automation – RPA), u ERP okruženja [5], [12]. Treća faza obuhvata komparativnu analizu postojećih modela i pristupa integracije vještačke inteligencije u ERP sisteme, s ciljem identifikacije zajedničkih karakteristika, prednosti, ograničenja i faktora uspješne implementacije [10].

4. PREDLOŽENI MODEL INTEGRACIJE VJEŠTAČKE INTELIGENCIJE U ERP SISTEME

Predloženi model integracije osmišljen je kao višeslojni konceptualni okvir prilagođen specifičnostima domaćih preduzeća, sa ciljem transformacije ERP sistema iz pasivnog skladišta podataka u inteligentni sistem za podršku odlučivanju.


Model obuhvata četiri osnovna sloja:

1. Sloj podataka (Data Layer): Zadužen za prikupljanje, čišćenje i integraciju strukturiranih i nestrukturiranih podataka iz ERP baza, CRM-a, IoT uređaja i eksternih izvora.

2. Sloj vještačke inteligencije (AI Layer): Centralni dio arhitekture u kome se primjenjuju ML, NLP i prediktivni algoritmi za prepoznavanje obrazaca i generisanje predikcija u realnom vremenu.

3. Aplikativni ERP sloj (ERP Application Layer): Obuhvata standardne module (finansije, logistika, HR, proizvodnja) unaprijeđene AI funkcionalnostima.

4. Sloj poslovnog odlučivanja (Decision-Making Layer): Predstavlja interfejs prema menadžmentu, omogućavajući vizuelni prikaz KPI indikatora, prediktivne scenarije i automatske preporuke.



Slika 1. Predloženi AI-ERP model integracije

Izvor: Autor

Tok podataka odvija se u zatvorenom ciklusu: od prikupljanja iz internih i eksternih izvora, preko obrade u AI sloju, do generisanja preporuka koje se vraćaju u operativne ERP module. Skalabilnost modela omogućava njegovu primjenu kako u MSP sektoru kroz cloud arhitekturu, tako i u većim poslovnim sistemima.

5. DISKUSIJA

Rezultati analize ukazuju da uspješna AI-ERP integracija zavisi od prethodno uspostavljene kvalitetne podatkovne infrastrukture i odgovarajućeg nivoa digitalne zrelosti organizacije [7], [10]. Predloženi model omogućava postepenu implementaciju AI funkcionalnosti, čime se smanjuje rizik i početni trošak, što je posebno značajno za mala i srednja preduzeća u Bosni i Hercegovini [9]. Najveći potencijal primjene identifikovan je u prediktivnom upravljanju zalihama, finansijskom planiranju, analizi prodaje i automatizaciji dokumentacionih procesa.

Za uspješnu primjenu predloženog modela u praksi ne preporučuje se radikalna i jednokratna implementacija, već postupni, fazni pristup:

Faza 1 – Digitalna konsolidacija: Standardizacija poslovnih procesa, uspostavljanje jedinstvene baze podataka i podizanje nivoa kvaliteta ulaznih podataka.

Faza 2 – Implementacija prediktivne analitike: Uvođenje modela za predviđanje prodaje, sezonskih oscilacija i planiranje zaliha.

Faza 3 – Automatizacija procesa: Uvođenje inteligentne obrade faktura, automatskog kreiranja radnih naloga i korisničkih asistenata.

Faza 4 – Inteligentno poslovno odlučivanje: Potpuna podrška menadžmentu kroz simulaciju scenarija, procjenu rizika i preporuke u realnom vremenu.

Tabela 1. Pregled rezultata po fazama implementacije

Faza implementacije	Osnovni fokus	Ključni ishod za preduzeće
Faza 1	Konsolidacija podataka i procesa	Konsolidovana baza i standardizovan unos
Faza 2	Prediktivna analitika	Tačnije planiranje prodaje i zaliha
Faza 3	Automatizacija rutinskih zadataka	Smanjenje operativnih troškova i grešaka
Faza 4	Proaktivno podržano odlučivanje	Strateško upravljanje zasnovano na AI preporukama

Najveći izazovi u realizaciji ovog modela u domaćem okruženju ostaju neadekvatan kvalitet istorijskih podataka, nedostatak stručnog kadra (IT i data science profila), finansijska ograničenja i otpor zaposlenih prema automatizaciji [7], [9].

6. ZAKLJUČAK

Digitalizacija poslovnih procesa nameće potrebu za transformacijom tradicionalnih ERP sistema iz reaktivnih u proaktivne, inteligentne platforme [5], [6]. Integracija vještačke inteligencije omogućava bolju iskorištenost poslovnih podataka, automatizaciju rutinskih procesa i značajno unapređenje kvaliteta i brzine donošenja odluka.

Rad je ponudio konceptualni četvoroslojni model AI-ERP integracije prilagođen specifičnostima i nivou digitalne zrelosti preduzeća u Bosni i Hercegovini. Implementacija predloženog modela kroz fazni pristup omogućava preduzećima postepeni prelazak na inteligentno poslovanje uz optimizaciju ulaganja i resursa.

Ograničenje rada ogleda se u izostanku empirijske provjere modela u realnom poslovnom okruženju. Buduća istraživanja treba usmjeriti ka empirijskoj validaciji modela kroz studije

slučaja u domaćim kompanijama, kao i na istraživanje mogućnosti primjene generativne AI i AI agenata u naprednim ERP arhitekturama.

REFERENCE

- [1] Bradford, M., *Modern ERP: Select, Implement, and Use Today's Advanced Business Systems*, Lulu Press, 2020.
- [2] Davenport, T. H., "Putting the enterprise into the enterprise system", *Harvard Business Review*, vol. 76, no. 4, pp. 121–131, 1998.
- [3] EBRD, "Digital transformation initiatives in the Western Balkans", European Bank for Reconstruction and Development, 2025.
- [4] EU4DigitalSME, "Innovation and digitization of SMEs in Bosnia and Herzegovina", 2024.
- [5] Hurbean, L., Necula, S. C., Fotache, D., & Stepan, I. M., "Unveiling AI-powered ERP systems: A systematic review of trends and future directions", *Information Systems and e-Business Management*, 2026.
- [6] Laudon, K. C., & Laudon, J. P., *Management Information Systems: Managing the Digital Firm*, 17th ed., Pearson, 2022.
- [7] Mekić, E., Maksić, A., & Hadžimusić, B., "Digital literacy and ERP technology adoption in Bosnia and Herzegovina", *Economic Review*, vol. 18, no. 2, 2020.
- [8] Monk, E., & Wagner, B., *Concepts in Enterprise Resource Planning*, 4th ed., Cengage Learning, 2013.
- [9] Rubanović, A., & Abazović, F., "Digital transformation of small and medium enterprises in Bosnia and Herzegovina", *Zbornik radova Internacionalnog univerziteta Travnik*, 2025.
- [10] Ruivo, P., Oliveira, T., & Neto, M., "Examining ERP post-implementation stages of use and value: Empirical evidence from Portuguese SMEs", *International Journal of Accounting Information Systems*, vol. 33, p. 100419, 2020.
- [11] Russell, S., & Norvig, P., *Artificial Intelligence: A Modern Approach*, 4th ed., Pearson, 2021.
- [12] Sharma, M., "AI integration in ERP systems", *arXiv preprint*, 2025.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



RAZVOJ ALGORITMA ZA AUTOMATSKO UPARIVANJE POSLODAVCA SA NAJPOGODNIJIM KANDIDATOM

Sandro Gatarić, Goran Đukanović

*Panevropski univerzitet „APEIRON“, Banja Luka, Republika Srpska, Bosna i Hercegovina
sandro.yt29us@gmail.com, goran.z.djukanovic@apeiron-edu.eu*

Sažetak: U radu je predstavljen algoritam za automatsko uparivanje poslodavca sa najpogodnijim kandidatom, implementiran u okviru web aplikacije InterHUB. Za razliku od postojećih platformi za zapošljavanje, kod kojih se procjena podudarnosti kandidata sa oglasom u potpunosti prepušta poslodavcu nakon pregleda biografije, predloženi pristup zasniva se na strukturisanoj samoprocjeni kandidata. Poslodavac prilikom kreiranja oglasa definiše najmanje tri pitanja vezana za tražena znanja i vještine, a kandidat prilikom prijave svako pitanje ocjenjuje na skali od 1 do 10. Algoritam pojedinačne ocjene svodi na jedinstven procenat podudarnosti i automatski rangira sve prijavljene kandidate opadajuće. Izračun je realizovan dinamički, unutar SQL upita, čime rezultat uvijek odražava trenutno stanje podataka. Aplikacija je razvijena u Next.js i React okruženju, uz MySQL bazu podataka i Server Actions funkcije. Funkcionalnim testiranjem potvrđena je tačnost algoritma poređenjem automatski izračunatih procenata sa ručnim proračunom.

Ključne riječi: algoritam za uparivanje, rangiranje kandidata, Next.js, SQL

DEVELOPMENT OF AN ALGORITHM FOR AUTOMATIC EMPLOYER– CANDIDATE MATCHING

Abstract: This paper presents an algorithm for automatic matching of an employer with the most suitable candidate, implemented within the InterHUB web application. Unlike existing recruitment platforms, where the assessment of how well a candidate fits a job advertisement is left entirely to the employer after reviewing a curriculum vitae, the proposed approach is based on structured candidate self-assessment. When creating an advertisement, the employer defines at least three questions related to the required knowledge and skills, and the candidate rates each question on a scale from 1 to 10 when applying. The algorithm reduces the individual ratings to a single matching percentage and automatically ranks all applicants in descending order. The calculation is performed dynamically inside an SQL query, so the result always reflects the current state of the data. The application was developed using Next.js and React, with a MySQL database and Server Actions. Functional testing confirmed the accuracy of the algorithm by comparing the automatically calculated percentages with manual computation.

Key Words: matching algorithm, candidate ranking, Next.js, SQL

1. UVOD

Današnje tržište rada suočava se sa problemom usklađivanja ponude i potražnje radne snage. Poslodavci često imaju poteškoće da pronađu kandidate koji posjeduju znanja i vještine potrebne za određeno radno mjesto, dok se kandidati nerijetko prijavljuju na oglase na osnovu formalnih kvalifikacija, bez dovoljno praktičnog znanja za obavljanje traženih poslova. Klasične

platforme za zapošljavanje, poput LinkedIna ili Indeed-a, uglavnom se zasnivaju na objavljivanju oglasa i dostavljanju biografija, što poslodavcima ne pruža dovoljno informacija o stvarnim kompetencijama kandidata. Zbog toga proces selekcije često traje dugo i u velikoj mjeri zavisi od subjektivne procjene poslodavca.

Razvoj web tehnologija omogućio je kreiranje sistema koji mogu automatizovati određene dijelove procesa zapošljavanja i pomoći poslodavcima pri donošenju odluka. U okviru ovog rada predložen je pristup u kojem se podudarnost izračunava na osnovu konkretnih odgovora kandidata na pitanja vezana za poziciju, umjesto na osnovu slobodnog teksta biografije. Predmet rada jeste razvoj algoritma za automatsko rangiranje kandidata prema stepenu podudarnosti sa zahtjevima oglasa, u okviru web aplikacije namijenjene povezivanju poslodavaca i kandidata.

Rad polazi od pretpostavke da se samoprocjena kandidata, izražena kroz jednostavan numerički sistem ocjenjivanja u rasponu od 1 do 10, može iskoristiti kao pouzdana osnova za automatsko rangiranje, te da ovakav pristup poslodavcu pruža brži i pregledniji uvid u kandidate u odnosu na klasičan pregled biografija. U drugom poglavlju opisane su korištene tehnologije i model podataka, treće poglavlje prikazuje algoritam i njegovu implementaciju, četvrto rezultate testiranja, a u zaključku su sumirani doprinosi, ograničenja i pravci daljeg razvoja.

2. TEHNOLOGIJE I MODEL PODATAKA

2.1. Izbor razvojnog okvira

Kod klasičnih klijentskih aplikacija primjenjuje se renderovanje na strani klijenta, pri čemu pregledač preuzima minimalnu HTML datoteku i kompletan sadržaj generiše izvršavanjem JavaScript koda [1]. Takav pristup produžava vrijeme do prvog prikaza sadržaja i otežava indeksiranje stranica od strane pretraživača. Renderovanje na strani servera rješava oba problema tako što se HTML generiše prije slanja klijentu [2], [3], pa se kod aplikacija sa mješovitim sadržajem u praksi preporučuje hibridni pristup, u kojem se za svaku stranicu bira način renderovanja koji joj najviše odgovara [4].

Zbog toga je za izradu aplikacije InterHUB odabran Next.js framework, koji podrazumijevano razdvaja serverske od klijentskih komponenti i omogućava da se komponenta izvršava na serveru sve dok joj eksplicitno ne bude potrebna interaktivnost u pregledaču [5], [6]. Preduslov za rad framework-a jeste Node.js izvršno okruženje, koje omogućava izvršavanje JavaScript koda izvan pregledača [7], [8], a inicijalna struktura projekta generisana je zvaničnim alatom create-next-app [9], [10]. Korisnički interfejs izrađen je pomoću React biblioteke uz Tailwind CSS za stilizovanje.

Komunikacija između klijentskog i serverskog dijela sistema realizovana je putem Server Actions funkcija, umjesto klasičnih API ruta. Takvim pristupom kod koji pristupa bazi podataka nikada se ne isporučuje pregledaču, čime se smanjuje rizik od nenamjernog izlaganja osjetljivih podataka na klijentskoj strani.

2.2. Baza podataka i razvojno okruženje

Za skladištenje podataka korištena je MySQL relaciona baza podataka, koja podatke organizuje u tabele povezane relacijama uz podršku za SQL upitni jezik [11]. Aplikacija bazi pristupa preko mysql2 drajvera sa podrškom za asinhrono upite i parametrizovane naredbe, čime se istovremeno sprječava SQL injection [12]. Tokom razvoja baza je pokretana u Docker

kontejneru, čime je razvojno okruženje odvojeno od operativnog sistema i lako ponovljivo na drugom računaru [13].

Model podataka sastoji se od pet međusobno povezanih tabela. Tabela users čuva podatke o svim korisnicima, pri čemu kolona role tipa ENUM sa vrijednostima „osoba“ i „firma“ razlikuje kandidata od poslodavca unutar iste tabele. Tabela oglas sadrži oglase za posao i preko stranog ključa user_id povezana je sa poslodavcem koji ih je kreirao. Tabela oglas_pitanje čuva pitanja definisana za pojedinačni oglas, tabela prijave povezuje kandidata sa oglasom na koji se prijavio, a tabela prijava_odgovor čuva pojedinačne ocjene koje je kandidat unio za svako pitanje. Ključna projektna odluka jeste da se u bazi čuvaju isključivo sirove ocjene po pitanju, dok se konačan procenat podudarnosti ne upisuje u bazu, čime se izbjegava mogućnost da sačuvani rezultat postane neusklađen sa podacima na osnovu kojih je izračunat.

2.3. Autentifikacija korisnika

Lozinke se ne čuvaju u izvornom obliku, već se hashuju bcrypt algoritmom, koji ugrađenim usporavanjem otežava napade grubom silom [14]. Za održavanje prijavljenog stanja korišteni su sesijski kolačići [15], [16], odabrani umjesto tokena koji se čuvaju u pregledaču zato što se sesijski kolačić uz odgovarajuće atribute ne može pročitati iz JavaScript koda, a njegovo opozivanje na serveru je trenutno [17], [18]. Provjera identiteta i uloge korisnika izvršava se isključivo na serverskoj strani, prije svake operacije nad podacima [19].

3. ALGORITAM ZA AUTOMATSKO UPARIVANJE

Osnovni cilj prilikom razvoja algoritma bio je definisati jednostavan, transparentan i lako provjerljiv način izračunavanja stepena podudarnosti između samoocjena kandidata i pitanja koja poslodavac definiše za konkretan oglas. Poslodavac prilikom kreiranja oglasa definiše najmanje tri pitanja koja se odnose na tražena znanja, vještine ili uslove za poziciju. Kandidat prilikom prijave svako pitanje ocjenjuje na skali od 1 do 10, kako je prikazano na Slici 1. Za svaku prijavu zatim se izračunava aritmetička sredina unesenih ocjena, koja se svodi na procenat podudarnosti, a svi kandidati prijavljeni na isti oglas rangiraju se opadajuće prema dobijenom procentu. U slučaju identičnog rezultata kao dodatni kriterijum koristi se datum prijave.



The image shows a web form for candidate self-evaluation. It contains three questions, each followed by a horizontal input field with a dropdown menu. The first question is 'Koliko iskustva imate sa JavaScript?' with a value of 9. The second question is 'Koliko dobro poznajete React?' with a value of 9. The third question is 'Koliko dugo poznajete Tailwindcss?' with a value of 9.

Question	Answer
Koliko iskustva imate sa JavaScript?	9
Koliko dobro poznajete React?	9
Koliko dugo poznajete Tailwindcss?	9

Slika 1. Forma za samoocjenjivanje kandidata prilikom prijave na oglas

3.1. Matematička osnova

Procenat podudarnosti kandidata R, za oglas sa n definisanih pitanja, računa se prema formuli:

$$R = ((o_1 + o_2 + \dots + o_n) / n) / 10 \times 100 \text{ [\%]} \quad (1)$$

gdje je o_i ocjena koju je kandidat unio za i-to pitanje ($1 \leq o_i \leq 10$), n je ukupan broj pitanja definisanih za konkretan oglas, a R je konačan procenat podudarnosti, zaokružen na dvije decimale. Uz skraćivanje, formula se može zapisati i u pojednostavljenom obliku $R = (10/n) \times \sum o_i$. Odabran je aritmetički model zasnovan na prosjeku unesenih ocjena zato što je potpuno transparentan i objašnjiv i poslodavcu i kandidatu, deterministički, pa ga je lako testirati i provjeriti, jednostavan za implementaciju i dalje proširenje, te dovoljno pouzdan s obzirom na svrhu aplikacije, a to je brza preliminarna selekcija, a ne konačna odluka o zapošljavanju.

3.2. Pseudokod algoritma

ALGORITAM AutomatskoRangiranje

Ulaz: Lista prijava L

Izlaz: Rangirana lista kandidata

1. Za svaku prijavu p iz liste L uradi:
 - suma ← 0
2. Za svaki odgovor o kandidata:
 - suma ← suma + o.vrijednost
3. prosjek ← suma / broj odgovora
4. rezultat ← (prosjek / 10) * 100
5. Dodijeli rezultat prijavi p.
6. Sortiraj listu L prema rezultatu (opadajuće),
a zatim prema datumu prijave (opadajuće).
7. Vрати sortiranu listu.

KRAJ ALGORITMA

3.3. Implementacija

Algoritam nije implementiran kao zasebna izolovana funkcija, već se sastoji iz dvije logički povezane cjeline: prikupljanja i čuvanja odgovora, realizovanog Server Action funkcijom applyToJob, i izračuna i sortiranja rezultata, realizovanog na strani baze podataka. Funkcija applyToJob prvo provjerava da li je korisnik prijavljen i da li ima ulogu kandidata, a zatim sprječava duple prijave na isti oglas. Nakon toga dohvata sva pitanja vezana za oglas i za svako pitanje iz forme izdvaja unesenu ocjenu, koja se validira: vrijednost mora biti broj u rasponu od 1 do 10, u suprotnom se izvršavanje prekida uz odgovarajuću grešku. Tek nakon uspješne validacije kreira se zapis u tabeli prijave, a svaki pojedinačni odgovor upisuje se u tabelu prijava_odgovor.

Izračun rezultata realizovan je direktno unutar SQL upita, umjesto u JavaScript kodu:

```
SELECT users.id, users.ime, users.email,  
       prijave.datum_prijave,  
       COALESCE(scores.score, 0) AS score  
FROM prijave  
JOIN users ON prijave.user_id = users.id  
LEFT JOIN (  
    SELECT prijava_id,  
           ROUND(AVG(vrijednost) / 10 * 100, 2) AS score  
    FROM prijava_odgovor  
    GROUP BY prijava_id  
) AS scores ON scores.prijava_id = prijave.id  
WHERE prijave.oglas_id = ?  
ORDER BY score DESC, prijave.datum_prijave DESC
```

Podupit scores grupiše sve odgovore po identifikatoru prijave, izračunava prosječnu vrijednost unesenih ocjena funkcijom AVG, dijeli je sa 10 i množi sa 100 kako bi se dobio procenat, te zaokružuje rezultat na dvije decimale. Podupit se zatim spaja sa glavnom tabelom prijave, uz upotrebu funkcije COALESCE, koja osigurava da kandidat bez izračunatog rezultata dobije podrazumijevanu vrijednost 0 umjesto da izostane iz liste. Sortiranje je dvostruko, čime se osigurava deterministički i predvidljiv redoslijed prikaza kandidata poslodavcu.

4. TESTIRANJE I REZULTATI

Ispravnost algoritma provjerena je funkcionalnim testiranjem u razvojnom okruženju. Kreiran je nalog sa ulogom poslodavca i dva naloga sa ulogom kandidata. Poslodavac je objavio oglas za poziciju programera i definisao tri pitanja koja se odnose na poznavanje JavaScript-a, React-a i Tailwind CSS-a. Oba kandidata su se zatim prijavila na isti oglas sa različitim kombinacijama samoocjena, kako bi se dobila dva različita rezultata podudarnosti. Rezultati testiranja prikazani su u Tabeli 1.

Tabela 1. Poređenje ručnog proračuna i rezultata aplikacije

Kandidat	Ocjene	Ručni proračun	Rezultat aplikacije
Marko	9, 9, 9	90,00 %	90,00 %
Sandro	7, 8, 10	83,33 %	83,33 %

Za kandidata Marka prosjek ocjena iznosi 9,00, što podijeljeno sa 10 i pomnoženo sa 100 daje 90,00 %. Za kandidata Sandra prosjek iznosi 8,33, odnosno 83,33 %. Procenti koje je aplikacija

automatski izračunala u potpunosti se poklapaju sa ručnim proračunom, čime je potvrđena ispravnost matematičkog modela na kojem se algoritam zasniva.

Na Slici 2 prikazana je tabela prijavljenih kandidata u panelu poslodavca. Potvrđeno je da je lista sortirana opadajuće prema procentu podudarnosti, odnosno da je kandidat Marko, sa rezultatom od 90,00 %, prikazan iznad kandidata Sandra sa rezultatom od 83,33 %. Testirani su i granični slučajevi unosa, odnosno unos vrijednosti izvan raspona od 1 do 10 i pokušaj ponovne prijave na isti oglas, koji su u oba slučaja ispravno odbijeni uz odgovarajuću poruku o grešci.



Prijavljeni kandidati

Ime	Email	Telefon	Rezultat (%)	Datum prijave	Akcije
Marko	marko.markovic@gmail.com	Nema	90.00%	13. 7. 2026.	<button>Profil</button>
Sandro	sandro.gataric@gmail.com	Nema	83.33%	13. 7. 2026.	<button>Profil</button>

Slika 2. Automatski rangirana lista prijavljenih kandidata u panelu poslodavca

5. ZAKLJUČAK

U radu je predstavljen algoritam za automatsko uparivanje poslodavca sa najpogodnijim kandidatom, implementiran u okviru web aplikacije InterHUB. Procenat podudarnosti izračunava se kao prosjek unesenih samoocjena, sveden na skalu od 0 do 100, čime se dobija jedinstvena, uporediva vrijednost za svakog kandidata. Izračunavanje je realizovano dinamički, unutar SQL upita prilikom svakog prikaza liste prijavljenih kandidata, čime se osigurava da rezultat uvijek odražava trenutno stanje podataka. Sprovedenim testiranjem potvrđena je ispravnost algoritma i funkcije rangiranja, čime se može zaključiti da je postavljeni cilj rada ostvaren.

Potrebno je istaći i određena ograničenja. Model se zasniva na samoocjenjivanju, što unosi element subjektivnosti, jer procjena sopstvenog znanja ne mora odgovarati stvarnom nivou vještina. Sva pitanja nose jednaku važnost, pa algoritam ne razlikuje ključna pitanja od onih manje bitnih. Takođe ne uzima u obzir meke vještine ni motivaciju kandidata, a testiranje je sprovedeno ručno, bez automatizovanih testova.

Buduća istraživanja mogla bi ići u tri pravca. Prvi je uvođenje pondera, odnosno mogućnosti da poslodavac svakom pitanju dodijeli različitu težinu, što bi zahtijevalo dodavanje kolone u tabeli oglasa, pitanje i prilagođavanje formule. Drugi je uvođenje mehanizama za objektivnu provjeru vještina, poput kratkih testova znanja ili automatizovanog ocjenjivanja koda, čime bi se rezultat zasnivao na demonstriranom znanju. Treći je automatska analiza biografije kandidata primjenom tehnika obrade prirodnog jezika, kao dodatnog izvora podataka koji bi upotpunio samoprocjenu.

LITERATURA

- [1] Vercel Inc. (2025, Jun.). Rendering: Client-side Rendering (CSR) [Online]. Dostupno na: <https://nextjs.org/docs/pages/building-your-application/rendering/client-side-rendering>, [pristupljeno 11.07.2026.].

- [2] Kevin. (2026, Mar.). Unlocking Next.js Server-Side Rendering: A Deep Dive from Principles to Practice. Medium [Online]. Dostupno na: <https://tianyashool.medium.com/unlocking-next-js-server-side-rendering-a-deep-dive-from-principles-to-practice-15e32f1e4661>, [pristupljeno 11.07.2026.].
- [3] L. Jorge. (2023, Jun.). Server-Side Rendering vs. Client-Side Rendering: Exploring the Benefits of NextJS. Medium [Online]. Dostupno na: <https://medium.com/@livajorge7/server-side-rendering-vs-client-side-rendering-exploring-the-benefits-of-nextjs-4d6d66fed560>, [pristupljeno 11.07.2026.].
- [4] Educative Inc. (2026). Client-Side vs Server-Side Rendering in Next.js apps [Online]. Dostupno na: <https://www.educative.io/courses/next-js-build-react-apps/client-side-rendering-vs-server-side-rendering>, [pristupljeno 11.07.2026.].
- [5] Vercel Inc. (2026, Jul.). Getting Started: Server and Client Components [Online]. Dostupno na: <https://nextjs.org/docs/app/getting-started/server-and-client-components>, [pristupljeno 11.07.2026.].
- [6] Vercel Inc. (2026). Next.js Docs [Online]. Dostupno na: <https://nextjs.org/docs>, [pristupljeno 11.07.2026.].
- [7] OpenJS Foundation. (2026). Node.js — Run JavaScript Everywhere [Online]. Dostupno na: <https://nodejs.org/en>, [pristupljeno 11.07.2026.].
- [8] GeeksforGeeks. (2026). How to Download and Install Node.js and NPM [Online]. Dostupno na: <https://www.geeksforgeeks.org/node-js/how-to-download-and-install-node-js-and-npm/>, [pristupljeno 11.07.2026.].
- [9] Vercel Inc. (2026, Mar.). Getting Started: Installation [Online]. Dostupno na: <https://nextjs.org/docs/app/getting-started/installation>, [pristupljeno 11.07.2026.].
- [10] Vercel Inc. (2026, Mar.). CLI: create-next-app [Online]. Dostupno na: <https://nextjs.org/docs/app/api-reference/cli/create-next-app>, [pristupljeno 11.07.2026.].
- [11] Oracle Corporation. (2026). MySQL 8.4 Reference Manual [Online]. Dostupno na: <https://dev.mysql.com/doc/>, [pristupljeno 14.07.2026.].
- [12] sidorares. (2026). MySQL2 Promise Wrapper [Online]. Dostupno na: <https://sidorares.github.io/node-mysql2/docs/documentation/promise-wrapper>, [pristupljeno 14.07.2026.].
- [13] Docker Inc. (2026). Docker overview [Online]. Dostupno na: <https://docs.docker.com/get-started/docker-overview/>, [pristupljeno 14.07.2026.].
- [14] npm, Inc. (2026). bcrypt [Online]. Dostupno na: <https://www.npmjs.com/package/bcrypt>, [pristupljeno 14.07.2026.].
- [15] Mozilla Foundation. (2026). Using HTTP cookies [Online]. Dostupno na: <https://developer.mozilla.org/en-US/docs/Web/HTTP/Guides/Cookies>, [pristupljeno 14.07.2026.].
- [16] Mozilla Foundation. (2026). Session management [Online]. Dostupno na: https://developer.mozilla.org/en-US/docs/Web/Security/Authentication/Session_management, [pristupljeno 14.07.2026.].
- [17] S. Sootar. (2026, May). Sessions vs JWT vs Cookies: Understanding Authentication Approaches. dev.to [Online]. Dostupno na: <https://dev.to/satyasootar/sessions-vs-jwt-vs-cookies-understanding-authentication-approaches-1ojo>, [pristupljeno 14.07.2026.].
- [18] OWASP Foundation. (2026). Authentication Cheat Sheet [Online]. Dostupno na: https://cheatsheetseries.owasp.org/cheatsheets/Authentication_Cheat_Sheet.html, [pristupljeno 14.07.2026.].
- [19] Vercel Inc. (2026). Data Security [Online]. Dostupno na: <https://nextjs.org/docs/app/guides/data-security>, [pristupljeno 14.07.2026.].



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITEO 2026

Banja Luka, 25 - 26. 9. 2026. godine



PERCEPCIJA I PRIHVATANJE GENERATIVNE VJEŠTAČKE INTELIGENCIJE: TEORIJSKI OKVIR I PRIJEDLOG BUDUĆEG ISTRAŽIVANJA

Lidija Žunić¹, Goran Đukanović²

¹Panevropski univerzitet "Apeiron" Banja Luka, lidija.zunic@apeiron-edu.eu

²Panevropski univerzitet "Apeiron" Banja Luka, goran.z.djukanovic@apeiron-edu.eu

Abstrakt: Širenje alata zasnovanih na velikim jezičkim modelima otvorilo je pitanje u kojoj mjeri se generativna vještačka inteligencija koristi i na čemu korisnici zasnivaju povjerenje u takve sisteme. Korisnici mogu smatrati određeni alat korisnim, a istovremeno sumnjati u tačnost i vjerodostojnost sadržaja koji generiše. Shodno tome, prihvatanje generativne vještačke inteligencije je potrebno posmatrati iz šire perspektive, uzimajući u obzir koliko korisnici smatraju ove alate korisnim, koliko im vjeruju, da li namjeravaju da ih koriste i koje rizike uočavaju. Cilj rada je analizirati ključne faktore koji mogu uticati na percepciju i prihvatanje generativne vještačke inteligencije i na osnovu teorijskih saznanja definisati okvir za buduće empirijsko istraživanje.

Ključne riječi: generativna vještačka inteligencija, prihvatanje tehnologije, povjerenje, percipirana korisnost, veliki jezički modeli

1. UVOD

Široka dostupnost alata generativne vještačke inteligencije otvorila je pitanje njihovog prihvatanja među korisnicima. Veliki jezički modeli mogu proizvesti jasno i uvjerljivo formulisan odgovor čak i kada on sadrži netačne ili izmišljene informacije. Međutim, sama upotreba generativne vještačke inteligencije nije dovoljan pokazatelj njenog prihvatanja. Korisnik može često koristiti neki od alata vještačke inteligencije radi uštede vremena, a da njihove odgovore ipak ne smatra dovoljno pouzdanim za donošenje odluka ili izvršavanje stručnih zadataka. Zbog toga se u ovom radu dosadašnja upotreba posmatra kao pokazatelj prethodnog iskustva, dok se prihvatanje razmatra kroz namjeru budućeg korištenja.

Model prihvatanja tehnologije i UTAUT (engl. *Unified Theory of Acceptance and Use of Technology*) pružaju teorijsku osnovu za razmatranje percipirane korisnosti, jednostavnosti korištenja i namjere korištenja. Međutim, primjena ovih modela na generativnu vještačku inteligenciju zahtijeva uključivanje povjerenja u generisani sadržaj, percipirane tačnosti i rizika povezanih s netačnim informacijama, privatnošću i odgovornošću za korištenje rezultata. Dodatno pitanje predstavlja odnos između stvarnog porijekla sadržaja i načina na koji ga korisnici procjenjuju, posebno kada ne znaju da li je sadržaj proizveo čovjek ili sistem vještačke inteligencije.

Cilj rada je analizirati faktore povezane s percepcijom i prihvatanjem generativne vještačke inteligencije i na osnovu teorijskih modela i rezultata prethodnih istraživanja predložiti okvir

budućeg empirijskog istraživanja. Rad je teorijskog karaktera i zasniva se na analizi literature o generativnoj vještačkoj inteligenciji, velikim jezičkim modelima, prihvatanju tehnologije i povjerenju korisnika. Predloženi okvir obuhvata percipiranu korisnost i jednostavnost korištenja, percipiranu tačnost, povjerenje, rizike, prethodno iskustvo i namjeru budućeg korištenja, uz dodatno poređenje procjena ljudskog teksta i onog koji je generisala vještačka inteligencija.

2. GENERATIVNA VJEŠTAČKA INTELIGENCIJA

Generativna vještačka inteligencija obuhvata modele koji na osnovu korisničkog zahtjeva mogu stvarati različite oblike sadržaja [1]. Za razliku od sistema koji prvenstveno analiziraju ili prepoznaju postojeće podatke, generativni sistemi koriste modele i algoritme kako bi na osnovu dobijenih uputa stvarali novi sadržaj [2]. U kontekstu ovog rada posebno je značajno to što korisnik generativnu vještačku inteligenciju upoznaje kroz sadržaj koji sistem proizvodi kao odgovor na njegov zahtjev.

Razvoj vještačke inteligencije nije tekao kontinuirano, nego su se periodi intenzivnog napretka smjenjivali s periodima smanjenog interesovanja i finansiranja. Ponovno intenziviranje razvoja krajem dvadesetog i početkom dvadeset prvog vijeka Kager povezuje s naprednijim računarskim resursima, novim algoritmima i povećanom dostupnošću podataka [2]. Savremeni napredak generativne vještačke inteligencije takođe se povezuje s razvojem mašinskog učenja, velikim skupovima podataka i povećanjem raspoložive računarske snage [1].

Važnu prekretnicu predstavlja Transformer arhitektura, predstavljena 2017. godine. Za razliku od tada dominantnih rekurentnih i konvolucijskih pristupa, Transformer je zasnovan na mehanizmu pažnje, što je omogućilo veću paralelizaciju obrade i kraće vrijeme treniranja modela [3]. Ova arhitektura omogućila je efikasnije obuhvatanje odnosa između međusobno udaljenih dijelova teksta i podstakla razvoj jezičkih modela s većim brojem parametara, treniranih na sve obimnijim skupovima podataka [1].

Značaj savremene generativne vještačke inteligencije ne proizlazi samo iz razvoja modela. Tehnologija je iz istraživačkog okruženja prešla u lako dostupne proizvode i usluge namijenjene širem krugu korisnika [1]. Takav razvoj mijenja i predmet istraživanja, te pored tehničkih mogućnosti modela, važno postaje i pitanje kako korisnici procjenjuju korisnost, pouzdanost i rizike sistema s kojima neposredno komuniciraju.

2.1. Veliki jezički modeli i njihove osnovne karakteristike

Veliki jezički modeli zauzimaju ključno mjesto u savremenoj upotrebi generativne vještačke inteligencije, prvenstveno zbog značaja jezika u svakodnevnim zadacima obrade informacija. Njihov osnovni princip rada podrazumijeva određivanje vjerovatnoće naredne riječi ili tokena na osnovu prethodno zadatog konteksta. Ponavljanjem tog postupka model postepeno formira rečenice i duže tekstualne cjeline [1].

Generisanje odgovora nije u potpunosti determinisano, zbog čega isti upit pri ponovljenom korištenju može proizvesti različite odgovore. Na rezultat utiče i način na koji je početni upit formulisan, a pažljivije oblikovan upit može poboljšati kvalitet i upotrebljivost generisanog teksta [1].

Veliki jezički modeli treniraju se na obimnim količinama tekstualnih podataka prikupljenih iz knjiga, članaka, mrežnih stranica i drugih pisanih izvora. Mogu se koristiti za rad chatbotova i virtuelnih asistenata, prevođenje, stvaranje tekstualnog sadržaja, analizu sentimenta i

odgovaranje na pitanja na osnovu tekstualnih podataka [2]. Dodatnu prilagodljivost omogućava učenje iz konteksta, pri kojem se modelu u okviru samog upita daju primjeri zadatka bez mijenjanja njegovih parametara [1].

Jezička uvjerljivost odgovora, međutim, nije potvrda njegove činjenične tačnosti. Veliki jezički modeli mogu proizvesti netačne, nepostojeće ili izmišljene informacije koje djeluju uvjerljivo i vjerodostojno, što se označava pojmom halucinacije. Ovaj problem posebno dolazi do izražaja u područjima u kojima se zahtijeva visok nivo tačnosti i pouzdanosti, kao što su pravno savjetovanje, medicinska dijagnostika i naučno istraživanje. Zbog toga je generisane informacije potrebno provjeravati korištenjem pouzdanih izvora, a rezultate u stručnim područjima podvrgnuti dodatnoj provjeri stručnjaka [2].

Navedena ograničenja neposredno su povezana s povjerenjem korisnika. Sadržaj koji je jasno i uvjerljivo formulisan može ostaviti utisak pouzdanosti, dok uočavanje netačnih ili izmišljenih informacija može smanjiti spremnost korisnika da se osloni na sistem i da ga nastavi koristiti.

2.2. Savremeni alati i područja primjene

Radi terminološke jasnoće, u ovom radu razlikuju se generativni model i generativni alat. Model predstavlja tehnološku osnovu za obradu i generisanje sadržaja, dok se pod alatom podrazumijeva aplikacija putem koje korisnik pristupa mogućnostima jednog ili više modela.

Komercijalna primjena generativnih modela obuhvata alate za stvaranje vizuelnog sadržaja i podršku pri programiranju, među kojima Singh navodi Adobeove proizvode i GitHub Copilot [1]. Među alatima i modelima za generisanje slika Baker navodi DALL-E 2, Stable Diffusion, Adobe Firefly i Midjourney, dok u području generisanja teksta i programskog kôda izdvaja ChatGPT i OpenAI Codex [4]. Razvoj multimodalnih sistema omogućava da isti alat prihvata ili proizvodi više vrsta sadržaja, što Baker pokazuje na primjerima sistema Microsoft Copilot i ChatGPT 4o [4].

Primjene generativne vještačke inteligencije obuhvataju korisničku podršku, grafički dizajn, digitalne medije, zabavnu industriju, razvoj softvera i pisanje, ali i specijalizovana područja kao što su zdravstvo, farmaceutska industrija, proizvodnja i finansije [4]. Kao primjer alata za pronalaženje i organizovanje informacija može se izdvojiti Perplexity, koji generiše sažete odgovore na osnovu više izvora i uz njih prikazuje korištene reference. Pored pretraživanja, ovaj alat omogućava i generisanje teksta i programskog kôda [2].

U obrazovnom kontekstu Kager navodi mogućnosti korištenja generativnih alata za vježbanje jezika, stvaranje kratkih priča, pretraživanje informacija, analizu sentimenta, razvijanje strukture eseja te pisanje i analizu programskog kôda [2]. U priručniku se istovremeno naglašava da uključivanje alata vještačke inteligencije u obrazovanje treba biti zasnovano na njihovoj sigurnoj, etičnoj i korisnoj primjeni [2].

Dostupnost različitih generativnih alata sama po sebi ne podrazumijeva njihovo prihvatanje. Korisnik procjenjuje u kojoj mjeri mu alat olakšava izvršavanje zadataka, koliko može vjerovati generisanom sadržaju i da li potreba za njegovom dodatnom provjerom umanjuje ostvarenu korist. Zbog toga tehničke karakteristike generativne vještačke inteligencije predstavljaju polazište za razmatranje percipirane korisnosti, povjerenja, uočenih rizika i namjere budućeg korištenja.

3. PERCEPCIJA I PRIHVATANJE GENERATIVNE VJEŠTAČKE INTELIGENCIJE

3.1. Teorijske osnove prihvatanja tehnologije

Prihvatanje tehnologije ne može se posmatrati samo kroz činjenicu da je određeni alat dostupan ili da ga je korisnik nekada upotrijebio. Povremeno korištenje, namjera budućeg korištenja, povjerenje u rezultate i opšta procjena tehnologije predstavljaju povezane, ali različite pojave. Korisnik može, na primjer, koristiti generativnu vještačku inteligenciju zato što mu ubrzava određeni zadatak, a da istovremeno ima izražene sumnje u tačnost dobijenih odgovora.

Jedan od najčešće korištenih teorijskih pristupa za objašnjavanje prihvatanja informacionih tehnologija jeste Model prihvatanja tehnologije, TAM (engl. *Technology Acceptance Model*). Davis u okviru ovog modela izdvaja percipiranu korisnost i percipiranu jednostavnost korištenja kao dva osnovna uvjerenja povezana s prihvatanjem tehnologije. Percipirana korisnost označava stepen u kojem osoba vjeruje da će upotreba određenog sistema poboljšati njeno izvršavanje zadataka, dok se percipirana jednostavnost korištenja odnosi na uvjerenje da korištenje sistema neće zahtijevati veliki napor [5].

Kasnije razvijeni UTAUT model objedinio je elemente osam ranijih modela prihvatanja tehnologije [6]. U njemu se izdvajaju očekivani učinak, očekivani napor, društveni uticaj i olakšavajući uslovi, dok se starost, pol, iskustvo i dobrovoljnost korištenja razmatraju kao faktori koji mogu mijenjati odnose između navedenih konstrukata, namjere korištenja i stvarne upotrebe [6].

TAM i UTAUT pružaju korisnu osnovu za proučavanje generativne vještačke inteligencije, ali ne obuhvataju u potpunosti specifičnost ove tehnologije. Kod generativnih sistema korisnik ne procjenjuje samo funkcionalnost alata nego i sadržaj koji alat proizvodi. Zbog toga je teorijski okvir potrebno proširiti pitanjima povjerenja u generisane rezultate, njihove tačnosti i autentičnosti, kao i rizika koje korisnik povezuje s upotrebom generativne vještačke inteligencije.

3.2. Percipirana korisnost i namjera korištenja

Percipirana korisnost generativne vještačke inteligencije odnosi se na procjenu korisnika da mu određeni alat omogućava brže, kvalitetnije ili jednostavnije izvršavanje zadataka. Korist se može ogledati u uštedi vremena, lakšem pronalaženju i organizovanju informacija, razvijanju ideja, pisanju, učenju ili podršci pri rješavanju problema. U TAM modelu percipirana korisnost pokazala je snažnu povezanost sa samoprijavljenim korištenjem sistema i procjenom njegove buduće upotrebe [5].

Jednostavnost korištenja predstavlja drugi važan element procjene. Alat generativne vještačke inteligencije može imati napredne funkcije, ali će njegova praktična vrijednost za korisnika biti ograničena ako su način postavljanja upita, razumijevanje odgovora ili provjera rezultata suviše zahtjevni. Percipirana jednostavnost može uticati i na procjenu korisnosti, jer će korisnik lakše prepoznati korist sistema koji može upotrijebiti bez velikog dodatnog napora [5].

Novije istraživanje Konti i Kotsisa obuhvatilo je 460 odraslih ispitanika prikupljenih online prigodnim uzorkovanjem. Prihvatanje generativne vještačke inteligencije mjereno je GAIAS skalom, zasnovanom na dimenzijama UTAUT modela: očekivanom učinku, očekivanom naporu, olakšavajućim uslovima i društvenom uticaju [7]. Ukupno prihvatanje bilo je umjereno

do visoko. Najviša prosječna vrijednost zabilježena je za očekivani napor, tj. dimenziju koja u ovom istraživanju odražava percipiranu lakoću korištenja. Slijedili su očekivani učinak i olakšavajući uslovi, dok je društveni uticaj imao najnižu prosječnu ocjenu [7].

Nakon korekcije zbog višestrukih poređenja, razlike u ukupnom prihvatanju, očekivanom učinku i očekivanom naporu zadržale su statističku značajnost u odnosu na starost i nivo obrazovanja. Autori, međutim, upozoravaju da korišteni dizajn ne omogućava zaključivanje da starost ili obrazovanje samostalno uzrokuju razlike u prihvatanju. Istraživanje takođe nije neposredno mjerilo namjeru korištenja, dugoročnu primjenu ni stvarno ponašanje korisnika, zbog čega njegove rezultate ne treba tumačiti kao dokaz da jednostavnost korištenja uzrokuje usvajanje generativne vještačke inteligencije [7].

Za buduće istraživanje zato je opravdano odvojeno mjeriti percipiranu korisnost, jednostavnost korištenja, namjeru budućeg korištenja i učestalost dosadašnje upotrebe. Na taj način može se ispitati da li korisnici koji generativnu vještačku inteligenciju smatraju korisnom zaista namjeravaju nastaviti njeno korištenje i da li se iskazana namjera podudara s njihovim prethodnim iskustvom.

3.3. Povjerenje u sadržaj generisan pomoću vještačke inteligencije

Povjerenje u generativnu vještačku inteligenciju podrazumijeva spremnost korisnika da se u određenoj mjeri osloni na sistem i njegove rezultate. Takvo povjerenje ne bi trebalo posmatrati kao jedinstvenu i nepromjenjivu osobinu. Korisnik može vjerovati da je alat sposoban sažeti tekst ili predložiti ideje, ali mu istovremeno ne mora vjerovati pri navođenju činjenica, izvora ili stručnih preporuka.

Zhang, Tian i Deng istraživali su povjerenje u ChatGPT putem polustrukturisanih intervjua sa 29 korisnika. Izdvojili su pet grupa faktora povezanih s povjerenjem: osobine korisnika, kvalitet i izvor informacija, kvalitet i etičnost tehnologije, karakteristike organizacije koja stoji iza sistema te društveno, mrežno i regulatorno okruženje. Ovakav pristup pokazuje da se povjerenje ne formira samo na osnovu jednog odgovora sistema. Prema tome, na povjerenje mogu uticati stav korisnika prema tehnologiji i njegova percepcija rizika, kvalitet informacija, procijenjeni kvalitet i etičnost sistema, reputacija organizacije te šire društveno i regulatorno okruženje [8].

Posebno pitanje predstavlja uticaj informacije o autorstvu na procjenu sadržaja. Sears i Weisberg su u prvom eksperimentu, provedenom na 1.682 odrasla ispitanika, odvojeno mijenjali stvarno porijeklo priče i informaciju koju su ispitanici dobili o njenom autoru. Priče generisane pomoću ChatGPT-a ocijenjene su kao kvalitetnije i u većoj mjeri su zaokupljale pažnju ispitanika nego priče koje su napisali ljudi. Istovremeno, obje vrste priča dobijale su više ocjene kada je ispitanicima rečeno da ih je napisao čovjek [9]. Rezultat pokazuje da procjena sadržaja ne zavisi isključivo od njegovih stvarnih osobina nego i od uvjerenja korisnika o tome ko ga je proizveo.

U naredna dva eksperimenta, u kojima je ukupno učestvovalo 905 ispitanika, učesnici nisu pouzdano razlikovali ljudske od priča generisanih pomoću vještačke inteligencije. U jednom eksperimentu tačnost prepoznavanja iznosila je 39,39%, odnosno bila je statistički ispod nivoa slučajnog pogađanja [9]. Veće samoprocijenjeno iskustvo s alatima vještačke inteligencije bilo je povezano s uspješnijim prepoznavanjem porijekla priče, dok iskustvo s književnim tekstovima nije imalo isti efekat [9].

Ovi rezultati pokazuju da sposobnost prepoznavanja sadržaja vještačke inteligencije nije isto što i procjena njegovog kvaliteta ili povjerenje u taj sadržaj. Korisnik može pozitivno ocijeniti tekst

koji je generisala vještačka inteligencija, ali promijeniti procjenu kada sazna njegovo porijeklo. Zbog toga je u budućem istraživanju potrebno odvojeno mjeriti procijenjeni kvalitet teksta, povjerenje u njegovu tačnost, pretpostavljeno autorstvo, autentičnost i spremnost na korištenje.

3.4. Rizici i prepreke prihvatanju

Prihvatanje generativne vještačke inteligencije može biti ograničeno rizicima koji se odnose na kvalitet sadržaja, zaštitu podataka, nedovoljnu transparentnost sistema, pristrasnost rezultata i mogućnost neodgovorne upotrebe. Poseban problem predstavljaju halucinacije, odnosno situacije u kojima veliki jezički model proizvodi netačne ili izmišljene informacije koje djeluju uvjerljivo. Ovakvi odgovori zahtijevaju provjeru pomoću pouzdanih izvora, naročito kada se generativna vještačka inteligencija koristi u stručnom ili obrazovnom kontekstu [2].

Kasneci i saradnici razmatraju mogućnosti i ograničenja primjene velikih jezičkih modela u obrazovanju. Među izdvojenim problemima navode nedovoljnu interpretabilnost, pristrasnost rezultata, mogućnost zloupotrebe i potrebu za kontinuiranim ljudskim nadzorom. Budući da modeli mogu prenijeti ili pojačati pristrasnosti sadržane u podacima korištenim za njihovu obuku, autori naglašavaju značaj praćenja rezultata, transparentnosti i stručne provjere [10].

Dodatnu prepreku predstavlja nedostatak znanja potrebnog za razumijevanje mogućnosti i ograničenja sistema. Efikasna i odgovorna primjena zahtijeva digitalnu pismenost, odgovarajuću obuku i jasne institucionalne smjernice. Troškovi pristupa, održavanja i potrebne infrastrukture takođe mogu stvoriti razlike između korisnika i institucija koje imaju različite finansijske i tehničke mogućnosti [10].

Korištenje velikih jezičkih modela otvara i pitanja privatnosti i sigurnosti podataka, posebno kada korisnik u sistem unosi lične, poslovne ili druge osjetljive informacije. Potencijalni problemi obuhvataju neovlašten pristup, povredu povjerljivosti i upotrebu podataka u svrhe za koje korisnik nije dao saglasnost [10]. Nedovoljno jasna pravila o prikupljanju i obradi podataka mogu zbog toga smanjiti spremnost korisnika da se osloni na alate generativne vještačke inteligencije.

Dosadašnja istraživanja zajedno pokazuju da prihvatanje generativne vještačke inteligencije nije moguće objasniti samo jednim faktorom. Istraživanje Konti i Kotsisa ukazuje na istaknutu ulogu percipirane jednostavnosti i korisnosti, ali ne potvrđuje da one neposredno uzrokuju stvarnu upotrebu [7]. Zhang, Tian i Deng pokazuju da povjerenje zavisi od osobina korisnika, sadržaja, sistema, organizacije i šireg okruženja [8]. Sears i Weisberg pokazuju da sama informacija o autorstvu može uticati na procjenu sadržaja, nezavisno od njegovog stvarnog porijekla [9].

Na osnovu navedenog može se zaključiti da buduće istraživanje treba obuhvatiti percipiranu korisnost i jednostavnost korištenja, povjerenje u tačnost generisanog sadržaja, namjeru korištenja, prethodno iskustvo, percepciju rizika i osnovne demografske karakteristike. Te varijable treba posmatrati odvojeno, ali i ispitati njihove međusobne odnose, jer učestalo korištenje ne mora nužno značiti visoko povjerenje niti prihvatanje generativne vještačke inteligencije bez rezerve.

4. PRIJEDLOG KONCEPTUALNOG OKVIRA BUDUĆEG EMPIRIJSKOG ISTRAŽIVANJA

Na osnovu teorijskih razmatranja i rezultata prethodnih istraživanja predstavljenih u ranijim dijelovima rada, predlaže se konceptualni okvir budućeg empirijskog istraživanja percepcije i

prihvatanja generativne vještačke inteligencije. Predloženi okvir predstavlja osnovu za istraživanje koje bi se naknadno moglo realizovati putem strukturisanog online upitnika.

Buduće istraživanje bilo bi usmjereno na ispitivanje načina na koji korisnici procjenjuju sisteme generativne vještačke inteligencije, poput ChatGPT-a, Gemini-ja, Copilota i drugih sličnih alata. Posebna pažnja bila bi posvećena percipiranoj korisnosti i jednostavnosti korištenja, povjerenju u sadržaj generisan pomoću vještačke inteligencije, percepciji njegove tačnosti, zabrinutosti u vezi sa privatnošću i etičkim pitanjima, kao i namjeri budućeg korištenja ovih sistema.

U ovom istraživanju prihvatanje generativne vještačke inteligencije posmatralo bi se prvenstveno kroz namjeru budućeg korištenja. Učestalost dosadašnjeg korištenja predstavljala bi pokazatelj prethodnog iskustva ispitanika, a namjera korištenja bi pokazivala njihovu spremnost da alate generativne vještačke inteligencije koriste i u budućnosti. Na taj način pravi se razlika između postojećeg ponašanja korisnika i njihove buduće namjere.

Pored ispitivanja opštih stavova korisnika, buduće istraživanje uključivalo bi i poređenje više parova tekstova, pri čemu bi svaki par sadržavao tekst generisan pomoću vještačke inteligencije i tekst koji je napisao čovjek. Ispitanici bi pročitali tekstove iz svakog para, bez prethodne informacije o njihovom porijeklu, a zatim bi procijenili njihov kvalitet, jasnoću, prirodnost, uvjerljivost i pouzdanost. Na kraju bi naveli koji im se tekst više dopada i pokušali prepoznati koji je tekst generisan pomoću vještačke inteligencije. Na taj način mogla bi se uporediti opšta percepcija generativne vještačke inteligencije sa konkretnom procjenom sadržaja koji ona proizvodi.

4.1. Izbor varijabli istraživanja

Konceptualni okvir obuhvata više varijabli koje bi mogle biti povezane sa prihvatanjem generativne vještačke inteligencije.

Percipirana korisnost se odnosi na stepen u kojem ispitanik smatra da generativna vještačka inteligencija može unaprijediti obavljanje određenih zadataka. Ona može obuhvatiti procjenu da alati vještačke inteligencije štede vrijeme, olakšavaju pronalaženje informacija, povećavaju produktivnost, pomažu pri učenju ili radu i omogućavaju brže stvaranje različitih vrsta sadržaja.

Percipirana jednostavnost korištenja predstavlja procjenu korisnika o tome koliko je korištenje sistema generativne vještačke inteligencije jasno, razumljivo i jednostavno. Pretpostavlja se da će korisnici koji alate vještačke inteligencije smatraju lakim za korištenje lakše prepoznati njihovu praktičnu vrijednost i biti spremniji da ih nastave koristiti.

Percipirana tačnost sadržaja generisanog pomoću vještačke inteligencije odnosi se na procjenu korisnika da su odgovori i informacije koje generišu sistemi vještačke inteligencije tačni, dosljedni i pouzdani. Ova varijabla ne pokazuje stvarnu ili objektivno utvrđenu tačnost sadržaja, nego ličnu procjenu ispitanika. To je važno naglasiti jer se putem ankete mogu ispitati stavovi korisnika, ali se ne može neposredno utvrditi stvarna tačnost odgovora sistema generativne vještačke inteligencije.

Povjerenje u sadržaj generisanog pomoću vještačke inteligencije predstavlja spremnost korisnika da se u određenoj mjeri osloni na informacije, preporuke ili sadržaj koji generiše vještačka inteligencija. Povjerenje ne mora podrazumijevati nekritičko prihvatanje svakog odgovora, nego može uključivati i spremnost korisnika da koristi sadržaj generisan pomoću vještačke inteligencije uz dodatnu provjeru važnih informacija.

Percipirani rizici i prepreke obuhvataju zabrinutost korisnika u vezi sa mogućim negativnim posljedicama upotrebe generativne vještačke inteligencije. U okviru ove varijable mogu se ispitati:

- zabrinutost za privatnost i način korištenja unesenih podataka,
- mogućnost dobijanja netačnih ili izmišljenih informacija,
- etičke dileme povezane sa autorstvom i odgovornošću,
- mogućnost zloupotrebe generisanog sadržaja,
- pretjerano oslanjanje korisnika na sisteme vještačke inteligencije i
- strah od smanjenja značaja ljudskog rada ili zamjene određenih poslova.

Navedene vrste zabrinutosti mogu se posmatrati kao dimenzije šireg pojma percipiranog rizika, ali njihovo objedinjavanje u jednu varijablu trebalo bi izvršiti tek nakon provjere da li odgovarajuće tvrdnje u upitniku zaista mjere zajednički konstrukt. Ukoliko se pokaže da predstavljaju različite dimenzije, privatnost, tačnost, etička pitanja i strah od zamjene ljudskog rada mogu se analizirati odvojeno.

Prethodno iskustvo i učestalost korištenja odnose se na to da li je ispitanik ranije koristio alate generativne vještačke inteligencije, koliko dugo ih koristi i koliko često ih upotrebljava. Ova varijabla omogućava poređenje osoba koje alate vještačke inteligencije koriste svakodnevno ili povremeno sa osobama koje ih koriste rijetko ili ih do sada nisu koristile.

Namjera budućeg korištenja predstavlja osnovnu zavisnu varijablu predloženog istraživanja. Ona obuhvata spremnost ispitanika da u budućnosti koristi alate generativne vještačke inteligencije, da poveća učestalost njihove upotrebe ili da ih primijeni u većem broju aktivnosti.

Procjena tekstova generisanih pomoću vještačke inteligencije i tekstova koje je napisao čovjek predstavljala bi poseban dio istraživanja. Porijeklo teksta, odnosno činjenica da li ga je generisala vještačka inteligencija ili napisao čovjek, predstavljalo bi nezavisnu varijablu. Procjene kvaliteta, jasnoće, prirodnosti, uvjerljivosti, pouzdanosti i korisnosti teksta predstavljale bi zavisne varijable. Dodatno bi se ispitalo koji tekst ispitanici preferiraju i da li mogu pravilno prepoznati njegovo porijeklo.

Demografske karakteristike, kao što su pol, starosna dob, nivo obrazovanja i radni status, mogle bi se uključiti kao dodatne kontrolne varijable. Njihova uloga bila bi da se ispita postoje li razlike između pojedinih grupa ispitanika, ali one ne bi činile centralni dio konceptualnog modela.

4.2. Predloženi odnosi između varijabli

Predloženi konceptualni model polazi od pretpostavke da namjera korištenja generativne vještačke inteligencije ne zavisi od jednog faktora, nego od kombinacije percipirane korisnosti, jednostavnosti korištenja, povjerenja, percipirane tačnosti i mogućih rizika.

Očekuje se da će korisnici koji generativnu vještačku inteligenciju smatraju korisnom pokazivati veću spremnost da je koriste u budućnosti. Jednostavnost korištenja mogla bi doprinijeti boljoj percepciji korisnosti, jer korisnik lakše prepoznaje praktičnu vrijednost sistema kojim može upravljati bez većih poteškoća.


Percipirana tačnost sadržaja posmatra se kao jedan od mogućih preduslova povjerenja. Ako korisnik vjeruje da sistem vještačke inteligencije uglavnom pruža tačne, dosljedne i

odgovarajuće informacije, vjerovatnije je da će razviti veći nivo povjerenja u njegove rezultate. Veće povjerenje zatim može biti povezano sa izraženijom namjerom budućeg korištenja.

Suprotno tome, zabrinutost u pogledu privatnosti, etičkih pitanja, netačnih informacija i mogućih zloupotreba može smanjiti povjerenje i spremnost korisnika da se osloni na sisteme generativne vještačke inteligencije. Prethodno iskustvo takođe može biti značajno, jer osobe koje češće koriste alate generativne vještačke inteligencije imaju više neposrednih saznanja o njihovim mogućnostima i ograničenjima.

Pored odnosa između stavova, povjerenja, rizika i namjere korištenja, buduće istraživanje obuhvatilo bi i komparativnu procjenu više parova tekstova različitog porijekla. Ovaj dio istraživanja omogućio bi ispitivanje razlika u procjenama tekstova generisanih pomoću vještačke inteligencije i tekstova koje su napisali ljudi. Takođe bi se moglo ispitati da li su prethodno iskustvo s generativnom vještačkom inteligencijom i povjerenje u njen sadržaj povezani s ocjenama i izborom tekstova generisanih pomoću vještačke inteligencije.

Predloženi odnosi mogu se prikazati sljedećim konceptualnim modelom:



Slika 1 Predloženi konceptualni model budućeg empirijskog istraživanja

U predloženom modelu namjera budućeg korištenja predstavlja glavni pokazatelj prihvatanja generativne vještačke inteligencije. Percipirana korisnost, povjerenje, percipirani rizici i prethodno iskustvo predstavljaju neposredne prediktore namjere korištenja. Percipirana jednostavnost korištenja povezuje se sa percipiranom korisnošću, dok se percipirana tačnost sadržaja povezuje sa povjerenjem korisnika.

4.3. Istraživačka pitanja

Na osnovu predloženog konceptualnog okvira definišu se sljedeća istraživačka pitanja:

IP1: Kako ispitanici procjenjuju korisnost i jednostavnost korištenja alata generativne vještačke inteligencije?

IP2: Koliki nivo povjerenja ispitanici imaju u sadržaj generisan pomoću generativne vještačke inteligencije?

IP3: Kako ispitanici procjenjuju tačnost i pouzdanost sadržaja generisanog pomoću generativne vještačke inteligencije?

IP4: U kojoj mjeri su ispitanici zabrinuti zbog privatnosti podataka, mogućnosti dobijanja netačnih informacija, etičkih problema, zloupotrebe generativne vještačke inteligencije i mogućeg smanjenja značaja ljudskog rada?

IP5: Postoje li razlike u procjenama kvaliteta, jasnoće, prirodnosti, uvjerljivosti i pouzdanosti tekstova generisanih pomoću vještačke inteligencije i tekstova koje su napisali ljudi?

IP6: Koje tekstove ispitanici češće biraju kao kvalitetnije unutar predstavljenih parova?

IP7: U kojoj mjeri ispitanici mogu pravilno prepoznati porijeklo tekstova predstavljenih u komparativnom zadatku?

Istraživačka pitanja IP1–IP4 deskriptivnog su karaktera, dok se IP5–IP7 odnose na poređenje procjena tekstova, preferencije ispitanika i sposobnost prepoznavanja njihovog porijekla.

4.4. Prijedlog hipoteza

U skladu sa predloženim odnosima između varijabli, definišu se sljedeće hipoteze:

H1: Percipirana korisnost generativne vještačke inteligencije pozitivno je povezana sa namjerom njenog budućeg korištenja.

H2: Percipirana jednostavnost korištenja sistema generativne vještačke inteligencije pozitivno je povezana sa percipiranom korisnošću tih sistema.

H3: Viši nivo percipirane tačnosti sadržaja generisanog pomoću vještačke inteligencije pozitivno je povezan sa povjerenjem korisnika u taj sadržaj.

H4: Viši nivo povjerenja u sadržaj generisan pomoću vještačke inteligencije pozitivno je povezan sa namjerom budućeg korištenja generativne vještačke inteligencije.

H5: Veća zabrinutost u vezi sa privatnošću, tačnošću, etičkim pitanjima i mogućim zloupotrebama negativno je povezana sa povjerenjem u sisteme generativne vještačke inteligencije.

H6: Veća zabrinutost zbog mogućih rizika generativne vještačke inteligencije negativno je povezana sa namjerom njenog budućeg korištenja.

H7: Viši nivo prethodnog iskustva i veća učestalost korištenja alata generativne vještačke inteligencije pozitivno su povezani sa namjerom njihovog budućeg korištenja.

H8: Prosječne procjene tekstova generisanih pomoću vještačke inteligencije statistički se značajno razlikuju od prosječnih procjena tekstova koje su napisali ljudi.

H9: Viši nivo povjerenja u sadržaj generisan pomoću vještačke inteligencije pozitivno je povezan s povoljnijim procjenama tekstova generisanih pomoću vještačke inteligencije.

H10: Procjene tekstova generisanih pomoću vještačke inteligencije razlikuju se u zavisnosti od učestalosti korištenja alata generativne vještačke inteligencije.

Formulacija „povezana je sa“ prikladnija je od tvrdnje da određena varijabla direktno „utiče“ na drugu varijablu. Predloženo istraživanje bilo bi sprovedeno u jednom vremenskom periodu putem ankete, zbog čega bi moglo pokazati statističku povezanost između varijabli, ali ne bi bilo dovoljno za potpuno dokazivanje uzročno-posljedičnih odnosa.

4.5. Prijedlog metodologije budućeg empirijskog istraživanja

Buduće istraživanje bilo bi zasnovano na kvantitativnom presječnom anketnom pristupu, uz komparativni zadatak procjene tekstova različitog porijekla. Podaci bi se prikupljali jednokratno, putem strukturisanog online upitnika. Ciljnu populaciju činile bi punoljetne osobe koje alate generativne vještačke inteligencije koriste često, povremeno ili rijetko, kao i osobe koje su upoznate sa takvim alatima, ali ih trenutno ne koriste.

Uzorak bi se mogao formirati kombinovanjem prigodnog uzorkovanja i metode „snježne grudve“, odnosno dijeljenjem upitnika putem društvenih mreža, elektronske pošte, studentskih grupa i drugih dostupnih komunikacionih kanala. Budući da ovakav način izbora ispitanika ne predstavlja slučajni uzorak stanovništva, dobijeni rezultati ne bi se mogli bez ograničenja generalizovati na cjelokupnu populaciju. Navedeno ograničenje trebalo bi jasno navesti prilikom interpretacije rezultata.

Veličina uzorka biće određena na osnovu planiranih statističkih analiza, broja prediktora i prethodno definisane statističke snage testa.

Za mjerenje glavnih varijabli koristile bi se tvrdnje sa petostepenom Likertovom skalom, pri čemu bi vrijednost 1 označavala odgovor „u potpunosti se ne slažem“, a vrijednost 5 odgovor „u potpunosti se slažem“. Svaku složeniju varijablu trebalo bi mjeriti pomoću više međusobno povezanih tvrdnji, a ne samo jednim pitanjem. Na primjer, percipirana korisnost mogla bi se ispitivati tvrdnjama koje se odnose na uštedu vremena, povećanje produktivnosti i olakšavanje obavljanja zadataka.

Učestalost korištenja mogla bi se mjeriti kategorijama: „nikada“, „rjeđe od jednom mjesečno“, „nekoliko puta mjesečno“, „nekoliko puta sedmično“ i „svakodnevno“. Ispitanicima koji nikada nisu koristili alate generativne vještačke inteligencije najprije bi se pružilo kratko i neutralno objašnjenje njihove namjene. Njima se ne bi postavljala pitanja koja zahtijevaju neposredno iskustvo, nego bi odgovarali na pitanja o opštoj percepciji, zabrinutostima i namjeri budućeg korištenja.

Poseban dio upitnika sadržao bi komparativni zadatak sastavljen od više parova tekstova. Svaki par odnosio bi se na istu temu i sadržao bi jedan tekst generisan pomoću odabranog sistema generativne vještačke inteligencije i jedan tekst koji je napisala osoba bez korištenja generativnih alata. Tekstovi unutar svakog para bili bi približno jednake dužine i složenosti te zasnovani na istim osnovnim informacijama.

Prije procjene ispitanicima ne bi bilo navedeno porijeklo tekstova. Redoslijed tekstova unutar svakog para trebalo bi nasumično određivati kako položaj teksta ne bi uticao na ocjene ispitanika. Tekstovi bi bili označeni neutralnim oznakama, poput „Tekst A“ i „Tekst B“.

Nakon čitanja svakog teksta ispitanici bi na petostepenoj Likertovoj skali procijenili njegov kvalitet, jasnoću, prirodnost, uvjerljivost, pouzdanost i korisnost. Zatim bi odgovorili koji im se tekst više dopada i za koji tekst smatraju da je generisan pomoću vještačke inteligencije.

Informacija o stvarnom porijeklu tekstova mogla bi im biti prikazana tek nakon završetka procjene kako prethodno saznanje ne bi uticalo na njihove odgovore.

Dobijene ocjene omogućile bi poređenje prosječnih procjena tekstova prema njihovom stvarnom porijeklu. Odgovori o izboru kvalitetnijeg teksta i pretpostavljenom autorstvu omogućili bi ispitivanje preferencija i sposobnosti prepoznavanja sadržaja generisanog pomoću vještačke inteligencije.

Učešće u istraživanju bilo bi dobrovoljno i anonimno. Na početku upitnika ispitanici bi bili upoznati sa ciljem istraživanja, načinom korištenja podataka i pravom da odustanu od popunjavanja upitnika. Ne bi se prikupljali podaci koji nisu potrebni za ostvarivanje ciljeva istraživanja niti podaci na osnovu kojih bi se mogao neposredno utvrditi identitet ispitanika.

Predložena metodologija omogućila bi da se teorijske pretpostavke iz ovog rada naknadno provjere na empirijskim podacima. Rezultati budućeg istraživanja mogli bi pokazati koji faktori su najviše povezani sa povjerenjem i spremnošću korisnika da prihvate generativnu vještačku inteligenciju.

5. ZAKLJUČAK

Prihvatanje generativne vještačke inteligencije ne može se objasniti samo dostupnošću alata ili učestalošću njihove upotrebe. Analizirana literatura pokazuje da je potrebno razlikovati percipiranu korisnost, jednostavnost korištenja, povjerenje, procjenu tačnosti, percipirane rizike i namjeru budućeg korištenja. Korisnik može redovno koristiti generativnu vještačku inteligenciju zbog praktične koristi, a istovremeno zadržati nepovjerenje prema tačnosti i pouzdanosti generisanog sadržaja.

TAM i UTAUT pružaju osnovu za objašnjavanje korisnosti, jednostavnosti korištenja i namjere korištenja, ali ne obuhvataju u potpunosti specifičnosti generativnih sistema. Rezultati razmatranih istraživanja ukazuju na višedimenzionalnu prirodu povjerenja i na mogućnost da procjena sadržaja zavisi od informacije o njegovom autorstvu. Zbog toga sposobnost prepoznavanja teksta generisanog pomoću vještačke inteligencije, procjena njegovog kvaliteta i povjerenje u njegovu tačnost predstavljaju povezane, ali odvojene pojave.

Na osnovu ovih saznanja predložen je konceptualni okvir u kojem namjera budućeg korištenja predstavlja glavni pokazatelj prihvatanja. Percipirana korisnost, povjerenje, rizici i prethodno iskustvo posmatraju se kao mogući prediktori namjere korištenja, dok se percipirana jednostavnost povezuje s korisnošću, a percipirana tačnost s povjerenjem. Predloženo poređenje više parova tekstova generisanih pomoću vještačke inteligencije i tekstova koje su napisali ljudi omogućilo bi da se opšti stavovi ispitanika uporede s njihovom neposrednom procjenom konkretnog sadržaja. Buduće empirijsko istraživanje potrebno je za provjeru predloženih odnosa, pri čemu bi se dobijeni rezultati mogli tumačiti kao pokazatelji povezanosti, ali ne i kao dokaz uzročno-posljedičnih odnosa.

REFERENCE

- [1] K. Singh, Principles of Generative AI: A Technical Introduction. Carnegie Mellon University, 2023.
- [2] D. Kager, Umjetna inteligencija – početak, razvoj i budući izazovi: prvo izdanje CARNET-ovog priručnika. Zagreb: Hrvatska akademska i istraživačka mreža – CARNET, 2024.
- [3] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser i I. Polosukhin, „Attention Is All You Need“, Advances in Neural Information Processing Systems, vol. 30, str. 5998–6008, 2017.
- [4] [P. Baker, Generative AI For Dummies. Hoboken, NJ: John Wiley & Sons, 2025.

- [5] F. D. Davis, „Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology“, *MIS Quarterly*, vol. 13, br. 3, str. 319–340, 1989.
- [6] V. Venkatesh, M. G. Morris, G. B. Davis i F. D. Davis, „User Acceptance of Information Technology: Toward a Unified View“, *MIS Quarterly*, vol. 27, br. 3, str. 425–478, 2003.
- [7] E. Konti i K. T. Kotsis, „Acceptance of Generative Artificial Intelligence Among Adults: A Cross-Sectional Study of UTAUT-Based Dimensions and Group Differences“, *International Journal of Changes in Education*, vol. 4, br. 1, em110, 2027; objavljeno online 20. avgusta 2026.
- [8] Y. Zhang, J. Tian i F. Deng, „In Generative AI We Trust: An Exploratory Study on Dimensionality and Structure of User Trust in ChatGPT“, *Interacting with Computers*, vol. 38, br. 1, str. 58–76, 2026.
- [9] S. Sears i D. S. Weisberg, „Bot or Not: Can People Tell the Difference Between Stories Written by a Human or by an AI System?“, *Judgment and Decision Making*, vol. 21, e21, str. 1–20, 2026.
- [10] E. Kasneci i sar., „ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education“, *Learning and Individual Differences*, vol. 103, 102274, 2023.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



EKONOMSKE POSLJEDICE RANSOMWARE NAPADA: PERSPEKTIVA UPRAVLJANJA RIZICIMA

Milan Panić, Negovan Stamenković, Aleksa Marčeta, Tijana Talić

Panevropski univerzitet „APEIRON“, Banja Luka, Republika Srpska, Bosna i Hercegovina,
milan.v.panic@apeiron-edu.eu; negovan.m.stamenkovic@apeiron-edu.eu; aleksa.v.marčeta@apeiron-edu.eu;
tijana.z.talic@apeiron-edu.eu

Sažetak: Ransomware je jedan od najštetnijih oblika savremenog sajber kriminala jer u istom incidentu povezuje tehnički prekid rada, finansijsku ucjenu, pravnu izloženost i reputacioni pritisak. Rad primjenjuje narativni pregled relevantnih institucionalnih, industrijskih i naučnih izvora kao i komparativnu analizu šest javno dokumentovanih incidenata iz različitih sektora. Na toj osnovi predlaže se okvir ukupnog ekonomskog troška (TEC), koji obuhvata otkupninu, odgovor na incident, prekid poslovanja, pravne i regulatorne obaveze, oporavak sistema i reputacioni uticaj. Model se proširuje razlikovanjem bruto i neto troška, kao i očekivanog godišnjeg gubitka zasnovanog na vjerovatnoći incidenta. Analiza pokazuje da troškovi zastoja, obnove i odgovora mogu višestruko premašiti iznos otkupnine. Predloženi okvir nije univerzalni prediktivni model, već praktičan instrument za strukturisanje procjene, vođenje registra rizika i opravdavanje ulaganja u kontinuitet poslovanja i preventivne kontrole.

Ključne riječi: ransomware, sajber bezbjednost, ekonomski uticaj, upravljanje rizicima, kontinuitet poslovanja

ECONOMIC CONSEQUENCES OF RANSOMWARE ATTACKS: A RISK MANAGEMENT PERSPECTIVE

Abstract: Ransomware is one of the most damaging forms of modern cybercrime because it combines technical disruption, financial extortion, legal exposure and reputational pressure within a single incident. This paper applies a narrative review of relevant institutional, industry and academic sources with a comparative analysis of six publicly documented incidents across different sectors. Based on this evidence, the paper proposes a Total Economic Cost (TEC) framework covering ransom payments, incident response, business interruption, legal and regulatory obligations, system recovery and reputational impact. The framework distinguishes gross from net loss and links incident impact to an expected annual loss based on incident probability. The reviewed cases indicate that downtime, recovery and response costs can substantially exceed the ransom itself. The proposed framework is not a universal predictive model; it is a practical instrument for structuring assessments, maintaining risk registers and supporting investment decisions related to business continuity and preventive controls.

Keywords: ransomware, cybersecurity, economic impact, risk management, business continuity

1. UVOD I METODOLOGIJA

Digitalna transformacija povećala je zavisnost organizacija od informacionih sistema, usluga u oblaku, elektronske komunikacije, digitalnih plaćanja i međusobno povezanih poslovnih procesa. Takva zavisnost doprinosi efikasnosti i konkurentnosti, ali istovremeno povećava

izloženost sajber prijetnjama. Među njima se ransomware izdvojio kao jedan od najvidljivijih i ekonomski najštetnijih oblika sajber kriminala, jer može istovremeno zaustaviti poslovanje, ugroziti podatke i izazvati snažan pritisak na rukovodstvo organizacije [1], [2].

Osnovna logika ransomware napada zasniva se na kompromitovanju informacionog sistema, ograničavanju pristupa podacima ili uslugama i zahtijevanju plaćanja u zamjenu za obnovu pristupa. Savremene kampanje često uključuju dvostruku ili višestruku ucjenu: enkripciju, krađu podataka, prijetnju objavljivanjem i dodatni pritisak na korisnike, dobavljače ili partnere. Zbog toga ransomware više nije samo tehnički problem, nego događaj koji istovremeno aktivira pitanja kontinuiteta poslovanja, likvidnosti, usklađenosti, kriznog komuniciranja i reputacije [3], [4], [5].

Sa ekonomskog stanovišta, otkupnina predstavlja samo jednu i najvidljiviju komponentu gubitka. Organizacije snose troškove zastoja, smanjene produktivnosti, angažovanja eksternih stručnjaka, digitalne forenzike, pravne pomoći, regulatornog izvještavanja, obnove sistema, komunikacije sa zainteresovanim stranama i naknadnih ulaganja u bezbjednost. Dio tih posljedica nastavlja se i nakon tehničkog oporavka [6], [7].

Istraživačko pitanje rada glasi: kako strukturisano identifikovati i procijeniti ukupan ekonomski trošak ransomware incidenta tako da se obuhvate tehničke, poslovne, pravne i reputacione posljedice? Cilj rada je da, na osnovu literature i komparativne analize javno dokumentovanih slučajeva, razvije praktičan okvir koji prevodi sajber incident na jezik upravljanja rizicima i finansijskog odlučivanja. Doprinos rada ogleda se u operacionalizaciji kategorija troška, razlikovanju bruto, neto i očekivanog gubitka, te definisanju pravila koja smanjuju rizik dvostrukog računanja.

1.1. Metodologija istraživanja

Rad je koncipiran kao konceptualni stručni rad sa narativnim pregledom literature i komparativnom analizom više slučajeva. Pregledani su institucionalni izvještaji i smjernice, zvanične objave kompanija i regulatorni dokumenti, industrijski izvještaji i odabrani recenzirani naučni radovi. Težište je na izvorima objavljenim od 2019. do 2026. godine, uz zadržavanje nekoliko ranijih radova koji daju osnovne klasifikacije ransomware prijetnji i mjera zaštite [1], [8], [5], [9], [10], [11].

Slučajevi su odabrani namjernim uzorkovanjem prema tri kriterijuma: postojanje javno dostupnih i provjerljivih podataka, raznovrsnost sektora i mogućnost identifikovanja najmanje jedne ekonomske ili operativne posljedice. Za svaki slučaj posmatrani su sektor, vrsta poremećaja, objavljeni ili procijenjeni finansijski uticaj, status podatka i ključna upravljačka pouka. U analizu su uključeni Colonial Pipeline, Norsk Hydro, Garmin, JBS Foods, MGM Resorts i Change Healthcare.

Javno objavljeni podaci nisu potpuno uporedivi: pojedine organizacije objavljuju plaćenu otkupninu, druge računovodstveni uticaj, troškove odgovora ili procjenu poslovnog poremećaja. Iznosi nisu normalizovani prema inflaciji ni kursnim razlikama, jer je svrha analize identifikovanje strukture gubitka, a ne izrada rang-liste incidenata. Zbog toga rezultati i predloženi model imaju analitičku i upravljačku, a ne statističko-prediktivnu funkciju.

2. RANSOMWARE KAO ORGANIZACIONI I EKONOMSKI RIZIK

Ransomware pripada široj kategoriji zlonamjernog softvera čiji je cilj onemogućavanje pristupa sistemima ili podacima dok organizacija ne plati otkupninu ili ne sprovede oporavak drugim putem. Raniji oblici bili su često usmjereni na pojedinačne korisnike, dok savremene kampanje ciljaju organizacije koje snažno zavise od digitalne infrastrukture. Napadači biraju mete prema platežnoj sposobnosti, osjetljivosti procesa, vrijednosti podataka, stepenu povezanosti sa drugim organizacijama i uočenim slabostima kontrola.

Organizacioni uticaj naročito je ozbiljan kada su nedostupni ERP sistemi, elektronska pošta, baze korisnika, proizvodni kontrolni sistemi, platforme za naplatu ili sistemi za pružanje javnih usluga. Organizacija tada prelazi na ručni rad ili potpuno obustavlja određene procese. Finansijske posljedice zastoja mogu premašiti iznos otkupnine, posebno u zdravstvu, logistici, proizvodnji, hotelijerstvu i kritičnoj infrastrukturi [6], [12], [13].

Profesionalizacija kriminalnih grupa i model ransomware-as-a-service smanjuju prepreke za izvođenje napada, dok kriptovalute, anonimna infrastruktura i prekogranične operacije otežavaju istragu i povrat sredstava [3], [4], [7], [14]. Ransomware zato treba posmatrati kroz upravljanje rizicima preduzeća: incident utiče na povjerljivost, integritet i dostupnost, ali i na prihode, ugovorne obaveze, regulatornu usklađenost i strateški ugled. Efikasan odgovor zahtijeva koordinaciju IT sektora, rukovodstva, pravne službe, finansija, komunikacija i nadležnih organa [8], [5], [15].

2.1. Direktni troškovi

Direktni troškovi su najvidljiviji i najlakše se dokumentuju. Obuhvataju eventualnu otkupninu, transakcione i pregovaračke troškove, odgovor na incident, digitalnu forenziku, pravne i komunikacione usluge, hitnu zamjenu opreme, obnovu iz rezervnih kopija i nabavku dodatnih alata neposredno nakon napada. Plaćanje otkupnine ne garantuje brzu ili potpunu dekripciju, niti garantuje da ukradeni podaci neće biti objavljeni. Ono može otvoriti i pravna pitanja kada je primalac povezan sa sankcionisanim ili kriminalnim subjektima [1], [16], [9].

2.2. Indirektni troškovi

Indirektni troškovi uključuju izgubljene prihode zbog zastoja, pad produktivnosti, kašnjenja u isporuci, ugovorne kazne, dodatni rad korisničke podrške, gubitak korisnika, rast premija osiguranja i propuštene poslovne prilike. Često se nastavljaju nakon povratka sistema u funkciju. U vremenski osjetljivim sektorima i kod centralizovanih pružalaca usluga jedan incident može proizvesti lančane posljedice kod korisnika, dobavljača i partnera [12], [17].

2.3. Nematerijalni i dugoročni troškovi

Nematerijalne posljedice najteže se mjere, ali mogu imati strateški značaj. Narušen ugled može smanjiti povjerenje korisnika i investitora, oslabiti odnose sa partnerima i otežati privlačenje stručnog kadra. Objavljivanje osjetljivih podataka može dovesti do sporova i dugotrajnog regulatornog nadzora. Dugoročni troškovi uključuju i inkrementalna ulaganja u detekciju krajnjih uređaja, upravljanje identitetima, segmentaciju, obuku, rezervne sisteme, eksterne revizije i osiguranje. U procjenu treba uključiti samo dio ulaganja koji je stvarno izazvan incidentom, a ne redovna ulaganja koja bi organizacija svakako sprovela.

3. ODABRANI RANSOMWARE INCIDENTI I EKONOMSKE POUKE

Tabela 1 prikazuje šest slučajeva iz različitih sektora. Podatak je označen kao potvrđen kada potiče iz zvanične objave kompanije, regulatornog dokumenta ili organa vlasti. Formulacija „nije javno objavljeno” zadržana je kada pouzdana novčana procjena nije dostupna, čime se izbjegava predstavljanje medijskih navoda kao potvrđenih činjenica.

Tabela 1. Odabrani ransomware incidenti i ekonomske pouke

Organizacija / slučaj	Sektor	Glavni poremećaj	Prijavljeni ekonomski uticaj i status	Ključna pouka
Colonial Pipeline (2021)	Energetika / kritična infrastruktura	Privremeni prekid rada naftovoda i poremećaj snabdijevanja gorivom.	Plaćeno približno 4,4 miliona USD; DOJ je zaplijenio 63,7 BTC, tada vrijednih oko 2,3 miliona USD. Potvrđeno [16].	Bruto i neto trošak nisu jednaki; kritična infrastruktura zahtijeva unaprijed definisane procedure odlučivanja.
Norsk Hydro (2019)	Proizvodnja	Poremećaj proizvodnje, ručni rad i obnova velikog broja uređaja.	Ukupan trošak procijenjen na oko 800 miliona NOK. Zvanična procjena kompanije [13].	Rezervne kopije, ručne procedure i transparentno komuniciranje smanjuju zavisnost od plaćanja.
Garmin (2020)	Tehnologija / digitalne usluge	Prekid web funkcija, podrške, aplikacija i komunikacionih servisa.	Novčani iznos nije objavljen; kompanija je navela da ne očekuje materijalan uticaj na poslovanje ili finansijske rezultate [18].	Odsustvo javnog iznosa ne znači odsustvo troška; procjene moraju razlikovati potvrđene i nepotvrđene podatke.
JBS Foods (2021)	Proizvodnja hrane	Privremeni poremećaj pogona i transakcija sa kupcima i dobavljačima.	Plaćena otkupnina od 11 miliona USD. Zvanična objava kompanije [17].	Rezervni sistemi mogu ubrzati oporavak, ali uprava i dalje donosi odluke pod neizvjesnošću.
MGM Resorts (2023)	Hotelijerstvo / zabava	Poremećaj rezervacija, mobilnih aplikacija i usluga u objektima.	Oko 100 miliona USD negativnog uticaja na Adjusted Property EBITDAR i manje od 10 miliona USD jednokratnih troškova. SEC prijava [12].	Prekid korisničkih usluga brzo se pretvara u gubitak prihoda i dodatne savjetodavne troškove.
Change Healthcare (2024)	Zdravstvene usluge	Prekid obrade zahtjeva, apotekarskih transakcija i tokova plaćanja.	Tokom 2024. prijavljeno 2,2 milijarde USD direktnih troškova odgovora i 867 miliona USD poslovnog poremećaja. SEC prijava [19].	Incident velikog posrednika može proizvesti sistemske i sektorske posljedice koje višestruko premašuju otkupninu.

Izvor: obrada autora na osnovu zvaničnih izvora [16], [12], [17], [18].

3.1. Zajedničke karakteristike analiziranih slučajeva

Slučajevi potvrđuju da se ransomware gubitak ne može svesti na jedno plaćanje. Colonial Pipeline pokazuje razliku između bruto isplate i kasnije zaplijenjenog dijela sredstava. Norsk Hydro demonstrira značaj ručnih procedura i obnove iz rezervnih kopija. MGM i Change Healthcare pružaju najjasnije primjere kako poslovni poremećaj i troškovi odgovora mogu biti znatno veći od javno vidljive otkupnine. Garmin istovremeno pokazuje važnost opreznog tumačenja: organizacija može potvrditi ozbiljan operativni prekid, a da ne objavi novčani iznos ili ne očekuje materijalan računovodstveni uticaj.

Zajednički obrazac je lančana reakcija: tehnička kompromitacija izaziva operativni prekid; prekid stvara finansijski gubitak; finansijski i podatkovni efekti proizvode pravne i reputacione posljedice. Intenzitet reakcije zavisi od sektora, digitalne zavisnosti, koncentracije usluge, kvaliteta rezervnih kopija, raspoloživosti alternativnih procesa i brzine donošenja odluka.

4. MODEL PROCJENE UKUPNOG EKONOMSKOG TROŠKA

4.1. Struktura i područje primjene

Za potrebe postincidentne analize predlaže se pojednostavljeni okvir ukupnog ekonomskog troška ransomware incidenta:

$$\text{TEC} = \text{RC} + \text{IRC} + \text{BIC} + \text{LRC} + \text{RDC} + \text{RIC}$$

- **TEC** = bruto ukupan ekonomski trošak incidenta;
- **RC** = trošak otkupnine i neposredno povezanih transakcija;
- **IRC** = trošak odgovora na incident, forenzike, tehničke i savjetodavne podrške;
- **BIC** = trošak prekida poslovanja, izgubljenih prihoda i gubitka produktivnosti;
- **LRC** = pravni i regulatorni trošak, uključujući izvještavanje, sporove i kazne;
- **RDC** = trošak oporavka i inkrementalnog razvoja bezbjednosti;
- **RIC** = reputacioni trošak, gubitak korisnika i krizno komuniciranje.

TEC predstavlja ekonomski uticaj realizovanog događaja, odnosno ex-post procjenu posljedice. On sam po sebi nije potpuna mjera rizika, jer ne sadrži vjerovatnoću nastanka. Za finansijsko izvještavanje i poređenje scenarija korisno je odvojiti bruto trošak od osiguranja i povraćenih sredstava:

$$\text{NTEC} = \text{TEC} - \text{IC} - \text{AR}$$

- **NTEC** = neto ekonomski trošak nakon naknada i povrata;
- **IC** = priznata naknada iz sajber ili drugog relevantnog osiguranja;
- **AR** = povraćena sredstva, zaplijenjena imovina ili druge nadoknade.

Za ex-ante planiranje okvir se može povezati sa procjenom vjerovatnoće i koristiti kao pojednostavljena mjera očekivanog godišnjeg gubitka, u skladu sa pristupom koji razdvaja vjerovatnoću i uticaj scenarija [15]:

$$\text{EAL} = \text{P(R)} \times \text{E(NTEC)}$$

- **EAL** = očekivani godišnji gubitak;
- **P(R)** = procijenjena godišnja vjerovatnoća ransomware scenarija;
- **E(NTEC)** = očekivani neto trošak ako se scenario realizuje.

Model je namjerno jednostavan i može se koristiti u registru rizika, internoj reviziji, procjeni osiguranja, postincidentnoj analizi i obrazloženju preventivnih ulaganja. Procjene je preporučljivo voditi kao interval minimalne, najvjerovatnije i maksimalne vrijednosti, a pretpostavke, vremenski horizont i izvor svakog podatka treba dokumentovati.

4.2. Pravila procjene i ilustrativna primjena

Da bi se izbjeglo dvostruko računanje, svaka stavka treba da se evidentira samo u jednoj kategoriji. Izgubljeni prihod i gubitak produktivnosti ne smiju se sabirati kada opisuju isti efekat; pravne usluge se razvrstavaju u IRC ili LRC prema svrsi; krizno komuniciranje se evidentira u IRC ili RIC, ali ne u obje kategorije. U RDC se uključuju samo inkrementalna ulaganja koja ne bi nastala bez incidenta. Osiguranje i povrat sredstava ne umanjuju bruto TEC, već se odvojeno prikazuju pri izračunu NTEC.

Tabela 2 prikazuje hipotetički scenario srednje organizacije sa petodnevnom prekidom ključnih sistema. Iznosi služe isključivo demonstraciji modela i ne predstavljaju tržišne prosjeke niti empirijsku procjenu konkretnog sektora.

Tabela 2. Hipotetički primjer primjene TEC i NTEC okvira

Komponenta	Ilustrativna pretpostavka	Iznos (EUR)
RC	Otkupnina nije plaćena	0
IRC	Forenzika, eksterni tim i krizna podrška	240.000
BIC	Pet dana zastoja, izgubljeni prihodi i produktivnost	1.200.000
LRC	Pravno savjetovanje, obavještanje i ugovorni zahtjevi	110.000
RDC	Obnova sistema i inkrementalna bezbjednosna ulaganja	350.000
RIC	Komunikacija, zadržavanje korisnika i reputacioni oporavak	300.000
TEC	Bruto zbir komponenti	2.200.000
IC + AR	Priznata osiguravajuća naknada; bez drugog povrata	500.000
NTEC	Neto trošak incidenta	1.700.000

Ako bi procijenjena godišnja vjerovatnoća ovog scenarija bila 8%, očekivani godišnji gubitak iznosio bi 136.000 EUR. Takva vrijednost ne predviđa stvarni incident, ali omogućava poređenje troška preventivnih kontrola sa finansijskom izloženošću i podržava određivanje prioriteta ulaganja.

5. IMPLIKACIJE I PREPORUKE ZA UPRAVLJANJE RIZICIMA

5.1. Prevencija i pripremljenost

Prevenciju ransomware napada treba posmatrati kao ulaganje u smanjenje vjerovatnoće i posljedice, a ne kao izolovani IT trošak. Višefaktorska autentifikacija, upravljanje zakrpama i ranjivostima, zaštita krajnjih uređaja, segmentacija, upravljanje privilegovanim pristupom i obuka smanjuju vjerovatnoću uspješne kompromitacije [1], [5], [11]. Nijedna kontrola ne

može potpuno eliminisati rizik, pa se prevencija mora povezati sa sposobnošću detekcije, odgovora i oporavka.

Organizacije treba da održavaju izolovane i nepromjenljive rezervne kopije, redovno testiraju obnovu, definišu uloge, kontaktne tačke i procedure eskalacije. Rezervna kopija koja nije testirana i plan koji nije uvježban mogu zakazati u uslovima pritiska. Tehničke vježbe treba povezati sa poslovnim i upravljačkim scenarijima.

5.2. Kontinuitet poslovanja i donošenje odluka

Rukovodstvo tokom incidenta odlučuje o izolovanju sistema, kontaktiranju organa, obavještanju korisnika, uključivanju osiguravača, pregovorima i načinu obnove. Te odluke imaju tehničke, pravne, finansijske i etičke dimenzije. Unaprijed definisan okvir ovlaštenja i kriterijuma smanjuje kašnjenje, paniku i nekonzistentne odluke.

Planiranje kontinuiteta poslovanja direktno utiče na BIC komponentu. Ako se kritični procesi mogu nastaviti ručno ili preko alternativnih sistema, trošak zastoja se smanjuje. Ciljevi vremena oporavka i prihvatljivog gubitka podataka treba da budu zasnovani na poslovnoj analizi uticaja, a ne samo na tehničkim mogućnostima infrastrukture.

5.3. Ljudski faktor

Phishing, kompromitovani kredencijali, slabe lozinke, pogrešne konfiguracije i zakašnjelo prijavljivanje mogu povećati vjerovatnoću incidenta, dok nejasna ovlaštenja, loša komunikacija i nedovoljno uvježbani timovi povećavaju njegovu cijenu [1], [7], [10]. Obuka zaposlenih zato nije samo bezbjednosna mjera, već komponenta smanjenja ekonomskog rizika. Posebnu pažnju treba posvetiti donosiocima odluka, jer njihova spremnost utiče na trajanje zastoja i izbor odgovora.

5.4. Preporuke za organizacije

- **Uspostaviti registar troškova i rizika:** unaprijed definisati kategorije TEC-a, vlasnike podataka, izvore procjene, vremenski horizont i odgovornost za ažuriranje.
- **Procjenjivati bruto i neto uticaj:** odvojeno prikazivati TEC, osiguravajuće naknade i povraćena sredstva, umjesto da se objavi samo jedna zbirna vrijednost.
- **Koristiti raspone i scenarije:** za svaku komponentu procijeniti minimalnu, najvjerovatniju i maksimalnu vrijednost i dokumentovati pretpostavke.
- **Testirati rezervne kopije i obnovu:** rezervne kopije držati izolovano, redovno provjeravati i uskladiti sa ciljevima oporavka kritičnih procesa.
- **Primijeniti MFA i najmanje privilegije:** ograničiti pristup prema stvarnoj poslovnoj potrebi i posebno zaštititi privilegovane i udaljene pristupe.
- **Pripremiti integrisani plan odgovora:** definisati tehničke, pravne, finansijske, komunikacione i upravljačke odgovornosti, uključujući odnos sa osiguravačem i organima vlasti.
- **Sprovoditi obuku i vježbe:** obuhvatiti phishing, prijavljivanje, krizno odlučivanje, ručne procedure i simulacije prekida poslovanja.
- **Izvršavati rukovodstvo ekonomskim pokazateljima:** uz tehničke metrike prikazivati potencijalni BIC, vrijeme oporavka, NTEC i očekivani godišnji gubitak.

6. OGRANIČENJA ISTRAŽIVANJA

Rad se oslanja na javno dostupne podatke, koji su često nepotpuni, različito definisani i objavljeni u različitim računovodstvenim periodima. Organizacije imaju podsticaj da ograniče objavljivanje pojedinih iznosa, dok medijski izvještaji mogu miješati traženu i plaćenu otkupninu. Studije slučaja nisu statistički reprezentativan uzorak i ne omogućavaju zaključivanje o prosječnom trošku ransomware napada. Hipotetički primjer ilustruje primjenu predloženog modela, ali ne potvrđuje njegovu pouzdanost na osnovu stvarnih podataka. Buduća istraživanja treba da primijene TEC na većem uzorku, normalizuju valute i vremenske horizonte i provjere pouzdanost komponenti po sektorima.

7. ZAKLJUČAK

Ransomware napadi predstavljaju značajnu ekonomsku prijetnju savremenim organizacijama. Njihove posljedice nisu ograničene na plaćanje otkupnine, već obuhvataju direktne, indirektne, pravne, operativne i reputacione gubitke. Analizirani slučajevi pokazuju da prekid poslovanja, odgovor i obnova mogu proizvesti znatno veći finansijski pritisak od javno vidljive otkupnine, a kod centralizovanih pružalaca usluga posljedice se prenose na cijeli sektor. Predloženi TEC okvir strukturira bruto posljedicu realizovanog incidenta, NTEC prikazuje gubitak nakon osiguranja i povrata, dok EAL povezuje očekivani neto uticaj sa vjerovatnoćom scenarija. Time se jasno razdvajaju postincidentni trošak i ex-ante sajber rizik. Vrijednost okvira nije u obećanju univerzalno tačnog broja, nego u dosljednom evidentiranju kategorija, dokumentovanju pretpostavki i sprječavanju dvostrukog računanja.

Ključna upravljačka poruka jeste da je sajber otpornost ekonomski opravdana kada smanjuje trajanje zastoja, ubrzava oporavak i štiti povjerenje zainteresovanih strana. Organizacije koje povezuju tehničke kontrole, kontinuitet poslovanja, odgovor na incident i finansijsko mjerenje mogu kvalitetnije određivati prioritete i donositi odluke prije nego što se incident dogodi.

LITERATURA

- [1] "#StopRansomware Guide," CISA, 2023.
- [2] "Internet Crime Report 2024," Federal Bureau of Investigation, 2025.
- [3] "ENISA Threat Landscape 2024," ENISA, 2024.
- [4] "The State of Ransomware 2025," Sophos Ltd., 2025.
- [5] W. Fisher, M. Souppaya, W. Barker and K. Kent, "Ransomware Risk Management: A Cybersecurity Framework 2.0 Community Profile," NIST, 2026.
- [6] "Cost of a Data Breach Report 2025," IBM Corporation, 2025.
- [7] "2025 Data Breach Investigations Report," Verizon, 2025.
- [8] "The NIST Cybersecurity Framework (CSF) 2.0," NIST, 2024.
- [9] N. Kshetri, "The economics of ransomware and cyber extortion," *Computer*, vol. 56, no. 2, pp. 84-88, 2023.
- [10] R. Brewer, "Ransomware attacks: Detection, prevention and cure," *Network Security*, vol. 2016, no. 9, pp. 5-9, 2016.
- [11] A. Nelson, S. Rekhi, K. Scarfone and M. Souppaya, "Incident Response Recommendations and Considerations for Cybersecurity Risk Management: A CSF 2.0 Community Profile," NIST, 2025.
- [12] "Form 8-K: Cybersecurity Incident," U.S. Securities and Exchange Commission, 2023.
- [13] "Cyber-attack on Hydro," 15 05 2024. [Online]. Available:

- <https://www.hydro.com/en/global/media/on-the-agenda/cyber-attack/>. [Accessed 20 07 2026].
- [14] M. Paquet-Clouston, B. Haslhofer and B. Dupont, "Ransomware payments in the Bitcoin ecosystem," *Journal of Cybersecurity*, vol. 5, no. 1, 2019.
- [15] S. Quinn, N. Ivy, M. Barrett, L. Feldman, R. Gardner and G. Witte, "Identifying and Estimating Cybersecurity Risk for Enterprise Risk Management," NIST, 2025.
- [16] "Department of Justice Seizes \$2.3 Million in Cryptocurrency Paid to the Ransomware Extortionists DarkSide," 07 06 2021. [Online]. Available: <https://www.justice.gov/archives/opa/pr/departement-justice-seizes-23-million-cryptocurrency-paid-ransomware-extortionists-darkside>. [Accessed 20 07 2026].
- [17] "JBS USA Cyberattack Media Statement - June 9," 09 06 2021. [Online]. Available: <https://jbsfoodsgroup.com/articles/jbs-usa-cyberattack-media-statement-june-9>. [Accessed 20 07 2026].
- [18] "Garmin Issues Statement on Recent Outage," 27 07 2020. [Online]. Available: <https://www.garmin.com/en-US/newsroom/press-release/uncategorized/2020-garmin-issues-statement-on-recent-outage/>. [Accessed 20 07 2026].
- [19] "Annual Report on Form 10-K for the Year Ended December 31, 2024," U.S. Securities and Exchange Commission, 2025.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



OTKRIVANJE RANJIVOSTI VEB APLIKACIJA PRIMJENOM CEH METODOLOGIJE

Sara Kukić

Fakultet informacionih tehnologija, Panevropski univerzitet APEIRON, Banja Luka, sara.kukic@apeiron-edu.eu

Apstrakt: Rad prikazuje primjenu CEH metodologije penetracionog testiranja na namjenski izrađenoj veb aplikaciji MyBlogApp (PHP, MySQL, Apache), u izolovanom laboratorijskom okruženju. Testiranje je sprovedeno kroz svih pet faza CEH metodologije, alatima Nmap, Gobuster, ffuf, Nikto, OWASP ZAP i Burp Suite, uz ručnu provjeru svakog automatski dobijenog nalaza. Od ukupno 27 analiziranih nalaza, potvrđeno je 19 stvarnih sigurnosnih propusta: 1 kritičan, 1 visokog, 12 srednjeg i 5 niskog rizika. Preostalih 8 nalaza činilo je 5 lažno pozitivnih i 3 ispravno zaštićene funkcionalnosti. Svaki propust klasifikovan je prema OWASP Top 10 listi i ocijenjen CVSS v3.1 sistemom, u rasponu od kritičnog propusta neograničenog otpremanja datoteka koji omogućava izvršavanje proizvoljnog koda (CVSS 10,0) do propusta srednjeg rizika u upravljanju sesijama. Rezultati potvrđuju da CEH metodologija predstavlja pouzdan okvir za otkrivanje propusta i naglašavaju nezamjenljivu ulogu ručne provjere.

Cljučne riječi: penetraciono testiranje, CEH metodologija, OWASP Top 10, CVSS

DETECTION OF WEB APPLICATION VULNERABILITIES USING THE CEH METHODOLOGY

Abstract: This paper applies the CEH penetration testing methodology to MyBlogApp, a purpose-built web application (PHP, MySQL, Apache), in an isolated laboratory environment. Testing covered all five CEH phases using Nmap, Gobuster, ffuf, Nikto, OWASP ZAP and Burp Suite, with manual verification of every automated finding. Of 27 findings analysed, 19 were confirmed as genuine security flaws: 1 critical, 1 high, 12 medium and 5 low risk; the remaining 8 comprised 5 false positives and 3 correctly protected functionalities. Each flaw was classified by OWASP Top 10 category and scored with CVSS v3.1.

Key Words: penetration testing, CEH methodology, OWASP Top 10, CVSS

1. UVOD

Veb aplikacije postale su kritična tačka u odbrambenom perimetru organizacija. Prema Verizonovom izvještaju Data Breach Investigations Report, one se javljaju kao ključni vektor napada u velikoj većini potvrđenih sigurnosnih incidenata [1]. Isključivo reaktivne mjere stoga su nedovoljne, pa je penetraciono testiranje postalo sistematičan proces za proaktivnu procjenu otpornosti sistema.

Jedna od najrasprostranjenijih metodologija jeste CEH (Certified Ethical Hacker) okvir, koji obezbjeđuje strukturiran pristup kroz pet faza: izviđanje, skeniranje, sticanje pristupa, održavanje pristupa i prikriivanje tragova [2]. Polazna hipoteza rada jeste da CEH metodologija

predstavlja efikasan model za penetraciono testiranje veb aplikacija, čija primjena doprinosi otkrivanju propusta i formulisanju preporuka za sanaciju.

Doprinos rada je trostruk: (a) cjelovita primjena svih pet faza CEH metodologije na aplikaciji koja nije namjerno izrađena da bude ranjiva; (b) povezivanje OWASP Top 10 klasifikacije sa CVSS v3.1 ocjenjivanjem radi prioritizacije sanacije; i (c) kvantifikovanje udjela lažno pozitivnih nalaza.

2. TEORIJSKI OKVIR I SRODNI RADOVI


U centru savremenog pristupa sigurnosti nalazi se CIA trijada (povjerljivost, integritet, dostupnost), koja definiše ciljeve zaštite informacionih sistema [3] i osnovu za procjenu uticaja svake ranjivosti. Penetraciono testiranje definiše se kao ovlašćena i kontrolisana eksploatacija ranjivosti radi procjene sigurnosnog stanja sistema [2], [4]; za razliku od pasivnog skeniranja, ono pruža konkretan dokaz da se ranjivosti mogu iskoristiti. U radu je primijenjen gray-box pristup, u kojem je tester koristio isključivo informacije dostupne autentifikovanom korisniku.

OWASP Top 10 identifikuje najkritičnije rizike za veb aplikacije i služi kao referentni okvir za klasifikaciju nalaza [5]. Altulaihan, Alismail i Frikha [6] zaključuju da nijedan pojedinačni alat ne pokriva sve tipove ranjivosti, što je potvrđeno i u ovom radu. Pored CEH-a postoje i PTES [7] te OWASP WSTG [8]; CEH je odabran zbog pedagoške strukture i cjelovitog pogleda na ciklus napada [9].

3. METODE I MATERIJALI

3.1. Ciljna aplikacija, testno okruženje i obim

Za praktični dio razvijena je veb aplikacija MyBlogApp — platforma za pisanje i dijeljenje blog objava (PHP, MySQL, Apache), bez dodatnih frejmworkova. Aplikacija nije namjerno izrađena da sadrži ranjivosti, već predstavlja tipičan projekat čiji je fokus bila funkcionalna ispravnost, što rezultate čini relevantnim za širi spektar stvarnih sistema. Organizovana je u tri cjeline: modul za upravljanje korisnicima, modul za upravljanje sadržajem (uključujući otpremanje slika) i administrativni modul (Slika 1).



Slika 1. Početna stranica ciljne aplikacije MyBlogApp

Testiranje je sprovedeno u potpuno izolovanom laboratorijskom okruženju: napadačka i ciljna virtualna mašina povezane su isključivo preko host-only mrežnog adaptera, uz ograničenje pristupa zaštitnim zidom UFW (Tabela 1).

Tabela 1. Specifikacija testnog okruženja

Komponenta	Konfiguracija
Platforma	VMware Workstation, host-only mreža, UFW
Napadačka mašina	Kali Linux (kompletan CEH set alata)
Ciljna mašina	Ubuntu Server: Apache 2.4, PHP 8.5, MySQL
Alati za skeniranje	Nmap, Gobuster, ffuf, Nikto
Alati za analizu	OWASP ZAP 2.17, Burp Suite, Hydra
Pristup testiranju	Gray-box, autentifikovani korisnik

Sva testna aktivnost sprovedena je isključivo nad sopstvenom aplikacijom autorke, u akademske svrhe i pod mentorstvom; stvarni korisnički podaci nisu obrađivani. Obim je ograničen na kôd aplikacije i njeno hosting okruženje, u skladu sa praksom prema kojoj svaki angažman mora definisati granice ovlašćenja prije tehničke aktivnosti [4], [7].

3.2. Primjena pet faza CEH metodologije

Faza 1 — Izvidanje. Sprovedeno je pasivno prikupljanje javno dostupnih informacija o ciljnom sistemu (OSINT), bez direktne interakcije koja bi mogla biti detektovana, radi mapiranja površine napada.

Faza 2 — Skeniranje. Nmap-om je izvršeno otkrivanje otvorenih portova, detekcija verzija servisa i skeniranje poznatih ranjivosti, uz enumeraciju direktorijuma (Gobuster, ffuf) i skeniranje servera (Nikto). Otkrivena su tri otvorena porta (FTP, SSH i HTTP), pri čemu je HTTP servis bio primarna meta daljeg testiranja.

Faza 3 — Sticanje pristupa. Demonstrirana su četiri nezavisna vektora napada: potpuna kontrola nad serverom kroz eksploataciju otpremanja slika bez validacije, krađa sesije kombinacijom reflektovanog XSS-a i odsustva zaštite kolačića, preuzimanje naloga usljed odsustva CSRF zaštite te kompromitacija administratorskih kredencijala alatom Hydra. Cilj nije bio samo potvrditi ranjivosti, već ilustrovati obim potencijalne štete.

Faza 4 — Održavanje pristupa. Demonstrirano je kako napadač nakon inicijalne kompromitacije obezbjeđuje trajno prisustvo na serveru postavljanjem povratne ljuske (reverse shell).

Faza 5 — Prikrivanje tragova. Analizirane su tehnike prikrivanja tragova, prije svega brisanje i izmjena zapisa u sistemskim dnevnicima, radi procjene implikacija na praćenje sigurnosnih incidenata.

Svaki potvrđeni nalaz klasifikovan je prema OWASP Top 10 kategoriji i ocijenjen CVSS v3.1 sistemom [10], na osnovu vektora i kompleksnosti napada, potrebnih privilegija te uticaja na CIA trijadu.

4. REZULTATI

Tokom cjelokupnog testiranja analizirano je ukupno 27 nalaza. Nakon ručne provjere, 19 je potvrđeno kao stvarni sigurnosni propusti (1 kritičan, 1 visok, 12 srednjeg i 5 niskog rizika), dok je preostalih 8 otpalo kao 5 lažno pozitivnih nalaza i 3 ispravno zaštićene funkcionalnosti.

Klasifikacija 14 propusta kritičnog, visokog i srednjeg rizika data je u Tabeli 2. Preostalih 5 propusta niskog rizika čine informativna otkrivanja, poput curenja verzije servera i izloženosti kolačića PHPSESSID.

Tabela 2. Klasifikacija 14 propusta kritičnog, visokog i srednjeg rizika prema OWASP Top 10


OWASP kategorija	Br.	Rizik	Šta je pronađeno na MyBlogApp
A03: Injekcija	2	Kritičan	Neograničeno otpremanje datoteka (RCE); reflektovani XSS na search.php
A02: Kriptografske neispravnosti	1	Visok	Sav saobraćaj ide preko HTTP-a, uključujući lozinke i sesijske kolačiće
A01: Slom kontrole pristupa	3	Srednji	Nema CSRF zaštite; pristup /config/ i /includes/; nema ograničenja pokušaja prijave
A04: Nesiguran dizajn	1	Srednji	Odsustvo validacije unosa na serverskoj strani
A05: Pogrešna konfiguracija	3	Srednji	Ispis sadržaja direktorijuma; nedostaju CSP i X-Frame-Options zaglavlja
A07: Greške autentifikacije	4	Srednji	Slabe i prazne lozinke; sesija se ne regeneriše niti poništava nakon odjave

Za svaki potvrđeni propust izračunat je CVSS v3.1 skor radi prioritizacije sanacije (Tabela 3). Neograničeno otpremanje datoteka dobilo je maksimalan skor 10,0 i predstavlja apsolutni prioritet, jer kompromituje sve ostale sigurnosne mehanizme aplikacije.

Tabela 3. CVSS v3.1 skorovi i prioriteti sanacije

Ranjivost	CVSS	Ozbiljnost	Prioritet
Neograničeno otpremanje datoteka (RCE)	10,0	Kritičan	1
Komunikacija isključivo preko HTTP-a	7,5	Visok	2
Slaba politika lozinki	6,5	Srednji	3
Reflektovani XSS (search.php)	6,1	Srednji	4
Odsustvo CSRF zaštite	5,4	Srednji	5
Sesija se ne regeneriše i ne poništava	5,3	Srednji	6
Ispis sadržaja direktorijuma	5,3	Srednji	7

Ručna provjera bila je ključna za ispravno okarakterisanje najozbiljnijih nalaza. Eksploatacija funkcije za otpremanje, praćena izvršavanjem skripte na serveru, potvrdila je izvršavanje proizvoljnog koda, a ne samo konfiguraciono upozorenje (Slika 2). Upozorenje na XSS, koje je skener označio kao DOM-based, nakon ručnog testiranja alatom Burp Suite preklasifikovano je u reflektovani XSS — razlika koja mijenja pristup sanaciji sa sanitizacije na klijentu na enkodiranje izlaza na serveru.



Slika 2. Izvršavanje otpremljene datoteke test.php u pregledniku, sa ispisom RCE_TEST_OK, čime je potvrđeno izvršavanje proizvoljnog koda na serveru

Nalazi o pogrešnoj konfiguraciji potvrđeni su neposrednim uvidom: pristupom direktorijumu /config/ server je vratio potpun ispis sadržaja, čime je otkriven naziv konfiguracione datoteke database.php. Nasuprot tome, tri nalaza koja su ukazivala na SQL injekciju pokazala su se neosnovanim, jer aplikacija koristi parametrizovane upite.

5. PREPORUKE ZA SANACIJU

Prioritet 1 (hitno) — neograničeno otpremanje datoteka. Potrebno je provjeravati MIME tip datoteke po principu bijele liste umjesto oslanjanja na ekstenziju, smjestiti otpremljene datoteke van korijenskog direktorijuma servera i servirati ih kroz kontroler te onemogućiti izvršavanje skripti Apache direktivama. Posljednja kontrola se sama po sebi može zaobići, pa je treba kombinovati sa premještanjem datoteka.

Prioritet 2 (visok) — HTTPS i reflektovani XSS. Cjelokupan saobraćaj treba prebaciti na HTTPS. Parametar q na search.php treba enkodirati funkcijom htmlspecialchars() sa ENT_QUOTES, uvesti Content-Security-Policy zaglavlje te postaviti zastavice HttpOnly i Secure na sesijski kolačić.

Dugoročne strategije. Usvajanje bezbjednog životnog ciklusa razvoja (SDLC) sa modelovanjem prijetnji; obuka tima o OWASP Top 10; integracija SAST i DAST analize u CI/CD proces; redovno ažuriranje Apachea, PHP-a i MySQL-a; uvođenje WAF-a; te periodično ponavljanje penetracionog testiranja.

6. DISKUSIJA

Rezultati pokazuju da CEH metodologija omogućava sistematično otkrivanje širokog spektra propusta, od kritičnih ranjivosti do propusta srednjeg rizika koji kombinovanjem proizvode znatno veći uticaj. Ispis sadržaja direktorijuma, pojedinačno ocijenjen kao srednji rizik, postaje ozbiljniji u kombinaciji sa ranjivošću otpremanja datoteka, jer napadaču omogućava da potvrdi tačnu lokaciju otpremljenih datoteka bez pogađanja, čime se skraćuje put do izvršavanja koda sa Slike 2. Izvješćavanje o CVSS skorovima po nalazu stoga je neophodno, ali ne i dovoljno: prioritizacija treba da uzme u obzir i koji nalazi nižeg skora smanjuju napor za eksploataciju nalaza višeg skora.

Udio lažno pozitivnih nalaza od 18,5 % (5 od 27) potvrđuje zaključke Alazmi i De Leon [11], prema kojima se stope detekcije značajno razlikuju između alata, što naglašava nezamjenljivu ulogu ručne provjere.

Ograničenja rada su kontrolisano okruženje i jedna testirana aplikacija, pa se rezultati ne mogu automatski generalizovati. Budući pravci obuhvataju primjenu na produkcione aplikacije i automatizaciju procesa tehnikama dubokog učenja [12].

7. ZAKLJUČAK

Primjenom svih pet faza CEH metodologije na aplikaciji MyBlogApp otkriveno je 19 stvarnih sigurnosnih propusta, među kojima se izdvajaju kritičan propust neograničenog otpremanja datoteka, koji omogućava potpunu kontrolu nad serverom, i odsustvo HTTPS zaštite. Polazna hipoteza je time potvrđena.

Glavni doprinos leži u povezivanju teorijskog okvira sa praktičnom primjenom, uz klasifikaciju nalaza prema OWASP Top 10 i prioritizaciju CVSS sistemom. Rad potvrđuje da i jednostavna aplikacija, razvijena u funkcionalne svrhe, može sadržati ozbiljne propuste.

REFERENCE

- [1] Verizon Business, "Data Breach Investigations Report," Verizon Business, 2023.
- [2] R. L. Shemonski, *Penetration Testing For Dummies*, Hoboken, NJ: Wiley, 2020.
- [3] M. E. Whitman i H. J. Mattord, *Principles of Information Security*, Cengage Learning, 2021.
- [4] P. Engebretson, *The Basics of Hacking and Penetration Testing*, Waltham, MA: Syngress, 2013.
- [5] OWASP Foundation, "OWASP Top 10," 2025. <https://owasp.org/Top10/>
- [6] E. A. Altulaihan, A. Alismail i M. Frikha, "A survey on web application penetration testing," *Electronics*, vol. 12, br. 5, 2023.
- [7] PTES Committee, "The Penetration Testing Execution Standard," 2021. www.pentest-standard.org
- [8] OWASP Foundation, "OWASP Web Security Testing Guide (WSTG)," 2024. owasp.org/wstg
- [9] B. Erickson i D. Singh, *CEH Certified Ethical Hacker All-in-One Exam Guide*, McGraw Hill, 2021.
- [10] FIRST.org, "Common Vulnerability Scoring System v3.1," 2019. www.first.org/cvss/v3.1
- [11] S. Alazmi i D. C. De Leon, "A review on web application vulnerability scanners," *Applied Sciences*, vol. 10, str. 33200-33219, 2022.
- [12] M. Alhamed i M. M. H. Rahman, "Penetration testing in networks," *IEEE Access*, vol. 11, str. 67890-67910, 2023.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



ZNAČAJ INFORMACIONIH TEHNOLOGIJA U OSAVREMENJAVANJU NASTAVE

Slavojka Lazić, Zoran Ž. Avramović, Dražen Marinković

Panevropski univerzitet APEIRON, Banja Luka, Republika Srpska, BiH

slavojka.n.lazic@apeiron-edu.eu; zoran.z.avramovic@apeiron-edu.eu; drazen.m.marinkovic@apeiron-edu.eu

Apstrakt: Obrazovanje mladih ljudi je odgovoran posao koji zahtijeva visok stepen znanja, istrajnost, sistematičnost i stalno usavršavanje. U međusobnoj sprezi nastavnika i učenika, a uz pomoć savremenih informacionih tehnologija, trebalo bi da bude pokretač razvoja društva. Danas su informacione tehnologije nezaobilazna podrška u realizaciji nastavnog procesa.

Osavremenjavanje nastavnog procesa znači uvođenje novih metoda, tehnologija i oblika rada u školu, kako bi učenje bilo efikasnije, zanimljivije i prilagođeno današnjem vremenu.

U školama e-dnevnik igra ključnu ulogu u osavremenjavanju nastavnog procesa, transformišući tradicionalnu administraciju u digitalni sistem koji poboljšava komunikaciju, transparentnost i efikasnost u obrazovanju.

Ključne riječi: obrazovanje, osavremenjavanje nastave, e-dnevnik, IKT

Abstract: Educating young people is a responsible task requiring a high level of knowledge, perseverance, a systematic approach, and continuous professional development. The interplay between teachers and students, supported by modern information technologies, should serve as a driving force for societal development. Today, information technologies are an indispensable support in the implementation of the teaching process.

Modernizing the teaching process entails introducing new methods, technologies, and forms of instruction into schools to make learning more efficient, engaging, and suited to the present day. In schools, the electronic gradebook plays a key role in modernizing the teaching process, transforming traditional administration into a digital system that enhances communication, transparency, and efficiency in education.

Key words: education, modernization of teaching, e-diaries, ICT

1. UVOD

Obrazovanje mladih ljudi spada u jedan od najplemenitijih i najljepših životnih poziva. Zahtijeva dosljednost, upornost i istrajnost. Za njega se opredjeljuju ljudi koji gaje empatije prema učenicima, kao i prema ljudima uopšte.

Obrazovanje je neprekidan i živ proces, koji konstantno zahtijeva osavremenjavanje. Dinamika i tok procesa zavise od nastavnika i učenika. Stručnost nastavnika je kompetencija koja se

podrazumijeva. Način na koji nastavnik prenosi svoje znanje učenicima je individualan ali zahtijeva stalno usavršavanje.

Prosvetni radnik mora pratiti savremena dostignuća u svojoj oblasti i u društvu uopšte, kako bi ih mogao primijeniti u nastavi. Tradicionalni oblici nastave odavno su prevaziđeni a nove generacije učenika očekuju osavremenjeni pristup nastavnom procesu. Primjena informacionih tehnologija u oblasti obrazovanja, u manjoj ili većoj mjeri je prisutna u svim njenim segmentima.

U toku svoga rada, u direktnoj komunikaciji sa učenicima, nastavnik pokušava na njih prenijeti elemente znanja iz svoje oblasti. Dobrom organizacijom aktivnosti na času i primjenom informacionih tehnologija, nastavnik će pokušati da realizuje planirani nastavni sadržaj. Za šire oblike znanja, za koje nije bilo dovoljno vremena na času, nastavnik će usmjeriti učenike na najpovoljnije e-platforme. Uloga nastavnika i dalje je dominantna u obrazovnom procesu. On će usmjeravati, voditi i pomagati učenicima.

Veoma značajna podrška obrazovnom procesu u Republici Srpskoj je jedinstveni informacioni sistem Ministarstva prosvjete i kulture, namijenjen efikasnom upravljanju i razvoju savremenog obrazovanja. Sistem omogućava e-dnevnik nastavnicima, učenicima i roditeljima, kao i uvid od strane nadležne institucije.

Ovo omogućava mnogo bržu razmjenu podataka i komunikaciju između različitih aktera u obrazovnom procesu.

2. OSAVREMENJAVANJE NASTAVNOG PROCESA

Obrazovanje mladih ljudi živ je proces, koji stalno zahtijeva usavršavanje i nadogradnju. Neprekidno trpi reforme, u cilju što boljeg usavršavanja [1]. Svim dosadašnjim reformama obrazovanja, prethodilo je sagledavanje i analiziranje razloga promjene. Donošene su mjere koje bi otklonile postojeće nedostatke i uticale na stvaranje boljih rezultata u obrazovanju [1]. Osavremenjavanje nastavnog procesa znači uvođenje novih metoda, tehnologija i oblika rada u školu kako bi učenje bilo efikasnije, zanimljivije i prilagođeno današnjem vremenu [2].

Načini osavremenjavanja nastave mogu biti:

- **Primjena digitalne tehnologije:** korištenje računara, pametnih tabli, internet alata i obrazovnog softvera čini lekcije vizuelnim i interaktivnim.
- **Interaktivne metode učenja:** prestanak učenja napamet i prelazak na rad u grupama, rješavanje problema, projektna nastava i kritičko mišljenje.
- **Individualizacija pristupa:** prilagođavanje zadataka i brzine učenja potrebama i mogućnostima svakog učenika pojedinačno.
- **Stručno usavršavanje nastavnika:** redovna obuka nastavnika za rad s novim tehnologijama i savremenim pedagoškim pristupima.
- **Praćenje i vrednovanje:** korištenje stalne povratne informacije i modernih načina ocjenjivanja napretka učenika.

3. ISTRAŽIVANJE ZNAČAJA PRIMJENE IT U NASTAVI

Jedan od načina osavremenjavanja nastave je i uvođenje elektronskog dnevnika (e-dnevnik) [3]. E-dnevnik igra ključnu ulogu u osavremenjavanju nastavnog procesa, transformišući tradicionalnu administraciju u digitalni sistem koji poboljšava komunikaciju, transparentnost i

efikasnost u obrazovanju [3]. Uvođenjem digitalnih zapisa, škole napuštaju zastarjele papirne dnevničke i prelaze na dinamično okruženje prilagođeno potrebama 21. vijeka.

E-dnevnik unosi ključne promjene u više glavnih segmenata obrazovnog sistema [3].

Administrativno rasterećenje nastavnika:

- Brži unos podataka: ocjene, izostanci i napomene unose se u nekoliko klikova.
- Automatska statistika: sistem sam računa prosjeke ocjena, postotke izostanaka i generiše izvještaje za kraj polugodišta.
- Smanjenje rizika od gubitka podataka: svi podaci sigurno su sačuvani (cloud).

Transparentnost i uključenost roditelja:

- Pristup informacijama u realnom vremenu: roditelji imaju uvid u ocjene i izostanke svoje djece čim ih nastavnik unese.
- Bolja kontrola i prevencija: pravovremena informacija omogućava roditeljima da reaguju na pad ocjena ili neopravdane izostanke, prije nego što postanu ozbiljan problem.
- Smanjenje pritiska na roditeljske sastanke: informacije su dostupne uvijek, pa se sastanci uživo mogu posvetiti pedagoškom radu, a ne pukom čitanju ocjena.

Objektivnost i analitika za učenike:

- Uvid u vlastiti napredak: učenici mogu pratiti svoje ocjene i grafičke prikaze svog uspjeha kroz vrijeme.
- Najave ispita: kalendar pisanih provjera pomaže učenicima u boljoj organizaciji vremena za učenje.
- Smanjenje subjektivnosti: sistem onemogućava naknadno neovlašteno mijenjanje ocjena i osigurava jasne kriterije ocjenjivanja.

Izazovi uvođenja e-dnevnika

Iako donosi brojne prednosti, modernizacija procesa suočava se i s određenim izazovima:

- Tehnička infrastruktura: zahtijeva stabilnu internetsku vezu i adekvatne uređaje (računare, tablete) u svakoj učionici.
- Digitalna pismenost: potrebna je kontinuirana edukacija nastavnika, ali i dijela roditelja koji se slabije snalaze s tehnologijom.
- Pritisak na učenike: stalna dostupnost ocjena roditeljima ponekad može stvoriti kontraefekat i pojačani stres kod učenika.

E-dnevnik nije samo digitalna zamjena za papir, već osnova za daljnju digitalnu transformaciju škola koja omogućava integraciju s drugim alatima poput platformi za e-učenje (npr. Teams, Moodle).

O prisutnosti e-dnevnika u nastavi svakako da svoje mišljenje imaju i učenici [3].

Rad obuhvata istraživanje o stavovima učenika o ulozi i koristi e-dnevnika u nastavi, kao i njihovo mišljenje o organizovanju on-line nastavnog procesa. Istraživanje je obuhvatilo dvije grupe učenika. Prva grupa su učenici koji su ove školske godine otpočeli srednjoškolsko

obrazovanje (I razred). Druga grupa su učenici koji ga završavaju (IV razred). Cilj istraživanja je da se utvrde stavovi različitih generacija učenika, najmlađih i najstarijih srednjoškolaca. Učenici su anonimno odgovarali na nekoliko postavljenih pitanja.

Cilj istraživanja bio je da se utvrdi mišljenje učenika o koristi e-dnevnika: primjeni, kvalitetu, objektivnosti i problemima s kojima su se susretali.

Drugi dio istraživanja bio je da se utvrde stavovi i mišljenja učenika o najsavremenijem obliku nastavnog procesa, u kojem se eliminiše fizička prisutnost nastavnika u učionici. Istraživanje omogućava upoređivanje podataka, generacijske razlike među učenicima od četiri godine. Prošle školske godine pohađali su različite nivoe obrazovanja, onovno i srednjoškolsko.


Istraživanjem su prikupljeni različiti podaci. Prije svega, mišljenje učenika o značaju i kvalitetu e-dnevnika u nastavnom procesu, kao i problemima sa kojima su se suočavali. Učenici prvih razreda imaju pozitivniji stav o korišćenju e-dnevnika u nastavi, u odnosu na učenike završnih razreda.

Osim podataka koji su prikupljeni od učenika, istraživanje uzima u obzir i stavove većine kolega, prosvetnih radnika, prikupljene u svakodnevnoj komunikaciji.

Prikupljeni podaci od učenika i iskazana mišljenja nastavnika ukazuju da je nastavni proces mnogo lakše evidentirati i kompletirati, za kasnije potrebe, putem e-dnevnika.

4. ANALIZA PRIKUPLJENIH PODATAKA

Analizom prikupljenih podataka može se zaključiti da je većina učenika zadovoljna primjenom i korišćenjem e-dnevnika u nastavi. Rezultati istražovanja mogu se prikazati i grafički, pomoću dijagrama (slika 1).




Slika 1. Mišljenja učenika o značaju e-dnevnika

Na dijagramu se može uočiti da je veći broj učenika I razreda zadovoljan primjenom e-dnevnika u nastavi (92,63%). Učenici IV razreda manje su zadovoljni primjenom e-dnevnika (83,08%).

Navodeći razloge, isticali su: čestu nedostupnost, odsustvo privatnosti, neažurnost pojedinih nastavnika.

Drugi dio ankete odnosio se na mogućnost primjene odgovarajućih oblika nastave. Učenici su odgovarali na pitanje, koji oblik nastave bi radije odabrali: tradicionalni, online ili kombinovani. Interesantno je da se većina njih, i pored toga što su se izjasnili da su zadovoljni primjenom savremenih informacionih tehnologija u nastavi, izjasnila za tradicionalni oblik nastave (slika 2).



Slika 2. Izbor oblika nastave

Na dijagramu se može uočiti da bi tri četvrtine učenika prvih razreda radije primjenjivalo tradicionalni oblik nastave u toku svog srednjoškolskog obrazovanja. Od njih se 18,75% izjasnilo za kombinaciju tradicionalne i online nastave a samo 6,25% učenika za online nastavu. Kao razloge za izbor određenog oblika nastave navodili su lakše savlađivanje gradiva kroz tradicionalni oblik nastave. Ističu, da im se lakše obratiti nastavniku za pomoć usmeno u učionici, nego online.

I učenicima IV razreda postavljeno je pitanje, za koji oblik nastave bi se opredijelili ove školske godine ako bi imali mogućnost izbora. Kao i kod prvih razreda, većina njih se izjasnila za tradicionalni oblik nastave.

Kao što je već navedeno, većina učenika se izjasnila da bi u toku svog srednjoškolskog obrazovanja radije primjenjivala tradicionalni oblik nastave (75% učenika I razreda i 72% učenika IV razreda). Uočavaju se razlike u pogledu izbora preostala dva oblika nastave. Dok bi se veći broj učenika IV razreda radije opredijelio za online nego za kombinovanu nastavu, kod učenika I razreda je drugačiji mišljenje. Za kombinovanu nastavu izjasnilo se 18,75% učenika prvih i 5,5% učenika četvrtih razreda a za online nastavu 6,25% učenika prvih i 22,5% učenika četvrtih razreda.

5. ULOGA NASTAVNIKA U OSAVREMENJAVANJU NASTAVE

Prema rezultatima istraživanja, učenici radije žele rad sa nastavnikom u učionici. Lakše im se obratiti za pomoć, navode u anketi. Prema tome, i dalje je vodeća uloga nastavnika u obrazovnom procesu [5]. Da bi učestvovao u osavremenjavanju nastavnog procesa i sam nastavnik se mora stalno usavršavati. Mediji su ispomoć, ponekad za lakši i brži prenos znanja, danas nezaobilazni [6].

Nastavnik, analizira i traži najbolje alate i platforme za učenje na daljinu za svoj predmet. Između Google učionica, direktorijuma u oblaku, Microsoft timova, Zoom-a i drugih, odmjera koji je najprihvatljiviji. Bilo koji od navedenih načina da se primijeni, učenicima će biti olakšano učenje putem interneta, kao nadopuna radu u učionici [6].

Dobar nastavnik budi kod učenika interes za istraživanje i kritičko razmišljanje [7]. U savremenoj nastavi naglasak je na učeniku, dok je nastavnik tu da usmjerava proces učenja, a ne samo da drži predavanja. Umjesto pukog davanja odgovora, savjetuje učenike i olakšava im rješavanje zadataka. Nastavnici potiču učenike na trajnu želju za učenjem i prilagođavanjem novim promjenama u društvu. [7]

6. ZAKLJUČAK

Primjena **informacionih tehnologija** u osavremenjivanju nastave donosi korjenite promjene u obrazovni sistem. Prednosti primjene su mnogostruke: **pristup ogromnoj količini informacija** i obrazovnih resursa u bilo kojem trenutku, **individualizacija učenja** i prilagođavanje tempa svakom pojedincu, **veća motivacija** i **angažovanost** učenika kroz multimedijalne sadržaje, **razvoj digitalnih vještina** učenika, učenje na daljinu.

Iako tehnologija nudi napredne alate za učenje, ona sa sobom nosi i specifične izazove.

Nedostaci bi mogli biti: **smanjenje direktne socijalne interakcije** uživo, **visoki troškovi** nabavke opreme i održavanja sistema, **digitalni jaz** – nemaju svi učenici jednak pristup internetu i uređajima, **pad koncentracije** zbog društvenih mreža i igrice, **tehnološki problemi** kao što su pad sistema, loš internet.

Korištenje e-dnevnika donosi brži i transparentniji pristup ocjenama i izostancima, ali ovisi o stabilnoj internetskoj vezi i tehničkoj opremi.

Prednosti e-dnevnika su brža i bolja komunikacija roditelja, nastavnika i nadležnih institucija kroz pravovremene informacije. Učenici i roditelji mogu u svakom trenutku pratiti ocjene, izostanke i napomene. Nastavnici brže unose podatke koji su zaštićeni od fizičkog oštećenja ili gubitka a **manje je i administracije**.

Nastavnik i dalje zadržava dominantnu ulogu, organizuje i usmjerava učenike a savremene informacione tehnologije su postale svakodnevni alat u obrazovanju učenika.

LITERATURA

- [1] Vasiljević, J., Stanković, Ž.: Ambijentalna inteligencija i e-učenje, Panevropski univerzitet Apeiron, Banja Luka, JITA, 10 [1] (2020)
- [2] https://www.google.com/search?q=osavremenjavanje+nastavnog+procesa&oq=osavremenjavanje+nastavno+procesa&gs_lcrp=EgZjaHJvbWUyBggAEEUYOT
- [3] <https://n1info.hr/magazin/tehnologija/sto-je-e-dnevnik-donosimo-detaljan-vodic-za-koristenje-ove-vazne-aplikacije/>
- [4] Talić, T., Lazić, S., Marinković, D.: E-učenje u srednjim školama u Republici Srpskoj i prijedlozi za poboljšanje, Panevropski univerzitet Apeiron, Banja Luka, 2020.
- [5] Đorđević, J. „Škola, doživotno obrazovanje i značaj savremenih informacija“, Filozofski fakultet, Beograd.
- [6] Knežević, M. „Uticaj savremenih informaciono-komunikacionih tehnologija u realizaciji vaspitno-obrazovnog procesa“, Pedagoški fakultet, Sombor.
- [7] <https://www.google.com/search?q=Uloga+nastavnika+u+obrazovanju&oq=Uloga+nastavnika+u+obrazovanju&gs>



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITEO 2026

Banja Luka, 25 - 26. 9. 2026. godine



PRIMJENA VJEŠTAČKE INTELIGENCIJE U PERSONALIZOVANOM UČENJU: KONCEPT I RAZVOJ OBRAZOVNE PLATFORME UČIM.ONLINE

Teo Milanković¹, Katarina Držajić Laketić²

¹Fakultet informacionih tehnologija, Panevropski univerzitet Apeiron, Banja Luka, teo.milankovic@apeiron-edu.eu

²Fakultet filoloških nauka, Panevropski univerzitet Apeiron, Banja Luka, katarina.p.drzajic@apeiron-edu.eu

Sažetak: Digitalna tehnologija i vještačka inteligencija sve više oblikuju savremeno obrazovanje, ali kvalitetna personalizovana podrška učenju i dalje nije jednako dostupna svim učenicima, naročito na području zapadnog Balkana. Tradicionalna nastava uglavnom je usmjerena na prosječnog učenika, zbog čega oni koji uče drugačijim tempom često ne dobijaju odgovarajuću podršku. Individualna nastava, međutim, u velikoj mjeri zavisi od finansijskih mogućnosti porodica. Polazeći od ovog problema, u radu se predstavlja koncept i razvoj obrazovne platforme Učim.Online, čiji je cilj primjena vještačke inteligencije u personalizovanom učenju. Opisuju se polazni problemi, pedagoški pristup i osnovna arhitektura platforme, koja objedinjuje interaktivne lekcije, adaptivne preporuke i virtuelnog asistenta zasnovanog na velikom jezičkom modelu, prilagođenom radu sa lokalnim obrazovnim sadržajem. Gradivo je organizovano postupno, uz primjenu elemenata gejmfikacije, dok se napredak korisnika koristi za prilagođavanje narednih aktivnosti učenja. Poseban naglasak stavlja se na pristupačnost i lokalizaciju sadržaja kako bi platforma bila primjenjiva u domaćem obrazovnom kontekstu. Brojne globalne platforme razvijene su prvenstveno za strane obrazovne sisteme i strane jezike, dok je Učim.Online usklađena sa javno dostupnim dijelovima domaćeg nastavnog programa i osmišljena kao pristupačna podrška učenju. Platforma se u radu prikazuje kao primjer primjene dostupnih tehnologija u izgradnji prilagodljivog okruženja za učenje. Na kraju se razmatraju mogućnosti, ograničenja i pravci daljeg razvoja primjene vještačke inteligencije u obrazovanju.

Ključne riječi: Učim.Online, adaptivno učenje, gejmfikacija, veliki jezički modeli

APPLICATION OF ARTIFICIAL INTELLIGENCE IN PERSONALIZED LEARNING: CONCEPT AND DEVELOPMENT OF THE UČIM.ONLINE EDUCATIONAL PLATFORM

Abstract: Digital technology and artificial intelligence increasingly shape education, yet personalized learning support remains unevenly accessible, especially in the Western Balkans. This paper presents Učim.Online, an educational platform designed to apply artificial intelligence to personalized learning in the local educational context. The platform combines interactive lessons, adaptive recommendations, gamification, progress tracking and a virtual assistant based on a large language model adapted to local educational content. Learning materials are organized progressively, while user performance guides subsequent activities. Particular emphasis is placed on accessibility, localization and alignment with publicly available parts of the local curriculum. The paper discusses the platform's pedagogical foundations, current test-stage limitations and directions for further development, presenting Učim.Online as an example of how available technologies can support adaptable learning without replacing the teacher.

Key Words: Učim.Online, adaptive learning, gamification, large language models

1. UVOD

Učenici tokom školovanja usvajaju gradivo različitim tempom, iako je nastava organizovana za odjeljenje kao cjelinu. Predavanja i zadaci pri tome rijetko odgovaraju stvarnim razlikama u tempu učenja, pa naprednijima nedostaju novi izazovi, dok onima kojima je potrebno više vremena izmiče i osnovno gradivo. Budući da jedan nastavnik istovremeno radi sa velikim brojem učenika, svakome je teško posvetiti onoliko pažnje koliko mu je potrebno. Razlike u predznanju tako se vremenom produbljuju, a učenici često ostaju bez podrške koja bi im pomogla da ih prevaziđu.

Uobičajen odgovor na taj problem su privatne instrukcije i dopunska nastava. Takva pomoć, međutim, u velikom broju slučajeva predstavlja trošak koji ne mogu podnijeti sve porodice, pa kvalitetna podrška postaje dostupna prema materijalnim mogućnostima, a ne prema stvarnoj potrebi. Na taj način se postojeće nejednakosti dodatno produbljuju, uz nezanemarljivo finansijsko opterećenje porodica [1].

Vještačka inteligencija, s druge strane, otvara mogućnost drugačijeg pristupa. Sistemi koji prate rad pojedinca mogu prilagoditi težinu i redoslijed zadataka, provjeriti stepen razumijevanja i pružiti povratnu informaciju bez odlaganja [2]. Na taj način pojedine prednosti individualnog rada postaju dostupne većem broju učenika. Gradivo sa časa moglo bi se samostalno ponoviti kod kuće, svojim tempom, čime se olakšava cjelokupan proces učenja.

Primjena postojećih obrazovnih alata u zemljama zapadnog Balkana može biti ograničena razlikama u jeziku i nastavnim programima. Iz potrebe za rješenjem prilagođenim lokalnom obrazovnom kontekstu proistekla je ideja o razvoju platforme Učim.Online.

2. VJEŠTAČKA INTELIGENCIJA I PERSONALIZOVANO UČENJE

Personalizovano učenje podrazumijeva prilagođavanje nastavnog procesa individualnim potrebama učenika. Adaptivno učenje je njegov uži, tehnološki zasnovan oblik, u kojem programski sistem na osnovu podataka o radu učenika automatski mijenja težinu i redoslijed sadržaja. Platforma Učim.Online konceptijski pripada adaptivnom pristupu.

Teorijsko uporište personalizovanog učenja nalazi se u nekoliko dobro potvrđenih pedagoških i psiholoških postavki. Ranija istraživanja pokazala su da učenici koji rade individualno sa nastavnikom postižu znatno bolje rezultate od onih u tradicionalnoj nastavi [3], [4]. Otvoreno je pitanje kako te prednosti učiniti dostupnim široj populaciji. U osnovi ovakvog pristupa nalazi se postupno savladavanje gradiva, pri čemu se novi sadržaj uvodi tek kada je prethodni usvojen. Značajnu ulogu imaju i aktivno prizivanje znanja, koje je djelotvornije od ponovnog čitanja, ponavljanje raspoređeno u vremenu i pravovremena povratna informacija [5].

Vještačka inteligencija u ovom kontekstu doprinosi na nekoliko načina: praćenjem napretka i izborom narednih zadataka, generisanjem više varijanti istog sadržaja i pružanjem podrške putem virtuelnog asistenta u trenucima kada nastavnik nije dostupan.

Rezultati istraživanja ukazuju na umjerene i kontekstom uslovljene efekte ovakvih sistema, a ne na automatski velika poboljšanja [2], [6]. Asistenti zasnovani na velikim jezičkim modelima podložni su greškama i mogu generisati netačne odgovore [7]. Zbog toga ih treba koncipirati tako da učenika navode i oslanjaju se na provjeren sadržaj, umjesto da neposredno pružaju gotova rješenja. U tom smislu ova tehnologija predstavlja podršku nastavnom procesu, a ne

zamjenu za nastavnika. Upravo su navedena teorijska polazišta bila osnova za oblikovanje koncepta platforme Učim.Online, od izbora predmeta do rasporeda gradiva.

3. RAZVOJ PLATFORME UČIM.ONLINE

Učim.Online je odgovor na problem opisan u uvodu. Dopunska podrška učenju kod nas ostaje uslovljena porodičnim budžetom. Razvoj zato nije počeo od tehnologije, nego od pitanja kako takvu podršku učiniti dostupnom i prilagođenom.

Rješenje je zamišljeno kao veb aplikacija, dostupna putem zvaničnog domena i na bilo kojem uređaju sa pristupom internetu, bez posebne opreme. Kako je internet pregledač dostupan na većini uređaja, nije potrebna dodatna instalacija aplikacije, čime se pojednostavljuje pristup platformi. Time se smanjuju tehničke i finansijske prepreke za pristup platformi. Ciljnu grupu čine đaci osnovne i srednje škole, okvirno od petog razreda naviše.

U testnoj verziji prioritet su dobili matematika, fizika, hemija i biologija, kao predmeti u kojima složenost i kumulativnost gradiva stvaraju izraženu potrebu za kontinuiranim učenjem i dodatnom podrškom. Sistematično ispitivanje potreba korisnika i analiza prikupljenih podataka biće predmet posebnog empirijskog istraživanja

Prva tri predmeta pripadaju prirodno-matematičkoj oblasti i među zahtjevnijima su, jer počivaju na formulama i obrascima koje učenik najprije mora savladati. Biologija je odabrana zbog obimnog činjeničnog gradiva koje od učenika zahtijeva kontinuirano usvajanje i obnavljanje sadržaja.

Sadržaj je vezan za maternji jezik i za javno objavljene dijelove nastavnog programa, jer podrška ima smisla samo ako prati ono što se zaista uči. Poređan je postupno, jer se prema načelu postupnog savladavanja gradivo nadograđuje samo na usvojenoj osnovi [3]. Sistem počiva na korisničkim nalogima i pohrani podataka u oblaku uz enkripciju, pa napredak ostaje vezan za profil učenika i putuje sa njim s jednog uređaja na drugi. Zaštita privatnosti postavljena je kao prioritet zbog rizika vezanih za podatke, a u konačnoj verziji predviđen je i roditeljski nalog za praćenje napretka.

Na navedenim načelima zasniva se koncept platforme Učim.Online, koja objedinjuje učenje, provjeru znanja i praćenje napretka korisnika. Testna verzija za sada obuhvata navedena četiri predmeta i odabrane razrede, kao prikaz osnovnih načina na koje se okruženje može dalje razvijati, a njen izgled prikazan je na Slici 1.



Slika 1. Početna stranica platforme sa predmetnim modulima i pregledom napretka

Vizuelna jednostavnost i zasebna boja za svaki predmet uvedene su s namjerom da se uz ponavljanje iskoristi i asocijacija, jer boja gradivo vezuje za predmet kojem pripada. Opisana rješenja su u fazi testiranja i dostupna na zvaničnom domenu, pa se provjeravaju u stvarnoj upotrebi.

4. FUNKCIONALNOSTI I PEDAGOŠKI KONCEPT

Gradivo je organizovano po predmetima i nastavnim jedinicama, koje su dalje podijeljene na lekcije raspoređene u unaprijed definisanu putanju učenja. Sljedeća lekcija otključava se tek kada je prethodna završena, čime se u praksi primjenjuje načelo postupnog savladavanja [3]: dalje se ne ide dok osnova nije usvojena. Na kraju svake jedinice nalazi se kviz znanja koji obuhvata jedinicu u cjelini, pa se gradivo priziva ponovo i nakon nekog vremena, u skladu sa ponavljanjem raspoređenim u vremenu [5], [8]. Takva putanja prikazana je na Slici 2, na primjeru hemije.



Slika 2. Prikaz nastavne jedinice i putanje lekcija sa kvizom znanja (predmet hemija)

Unutar lekcije smjenjuju se kratka objašnjenja i zadaci više vrsta, poput pitanja sa ponuđenim odgovorima, povezivanja pojmova i dopunjavanja rečenica. Ovi zadaci nisu samo provjera, nego oblik aktivnog prizivanja znanja, koje pamćenje učvršćuje trajnije nego pasivno čitanje teksta [5]. Uz to, poslije svakog odgovora slijedi obrazloženje, pa i pogrešan odgovor postaje prilika za učenje, u skladu sa značajem pravovremene povratne informacije. Primjer zadatka povezivanja dat je na Slici 3.



Slika 3. Primjer interaktivne lekcije sa zadatkom povezivanja

Sistem primjenjuje i elemente gejmfikacije: za tačne odgovore i završene cjeline dodjeljuju se bodovi, prati se niz uzastopnih dana rada, otključavaju se nivoi, a ljestvica omogućava poređenje rezultata. Njihova svrha je da podstaknu kontinuitet u učenju, što je posebno važno kod mlađih đaka, kojima je zadržavanje pažnje često presudno. Prema istraživanjima, ovakvi elementi mogu povoljno djelovati na motivaciju, mada sa ograničenim i promjenljivim efektom [9], pa su postavljeni tako da prate učenje, a ne da postanu cilj za sebe.

Prilagođavanje težine gradiva odgovara načelu adaptivnog učenja: umjesto da svi prolaze kroz isti materijal na isti način, sadržaj se približava trenutnom nivou pojedinca. Primjenom vještačke inteligencije iz istog gradiva priprema se više varijanti iste lekcije. Sistem onda nudi lakšu ili težu varijantu narednih sadržaja, u zavisnosti od utrošenog vremena, uspješnosti na provjerama i napredovanja kroz nivoe. U početku svi korisnici prolaze kroz iste module, kako bi se uspostavila polazna osnova prije prilagođavanja. U testnoj verziji ovaj mehanizam funkcioniše u početnom obliku, dok se potpuno adaptivno prilagođavanje, u kojem se na osnovu napretka oblikuju sasvim nove varijante lekcija, tek razvija za konačnu verziju.

Virtuelni asistent zasnovan na velikom jezičkom modelu učeniku pruža dodatna objašnjenja i usmjerava ga ka odgovoru u svakom trenutku, čime se donekle nadoknađuje individualna pažnja kakvu daje rad sa nastavnikom. Osmišljen je tako da usmjerava ka provjerenom sadržaju, budući da jezički modeli mogu dati i netačan odgovor [7]. Asistent je u testnoj verziji zastupljen u osnovnom obimu, a njegovo puno uvođenje, zajedno sa unapređenjem modela na kojem se zasniva, predviđeno je za konačnu verziju.

Svaka od opisanih funkcionalnosti tako je praktična primjena jednog od načela iznesenih u drugom poglavlju.

5. DISKUSIJA I MOGUĆNOSTI DALJEG RAZVOJA

Strana i domaća rješenja koja su danas u upotrebi rijetko na jednom mjestu spajaju prilagođavanje gradiva, gejmfikaciju i usklađenost sa lokalnim planom. Učim.Online te elemente objedinjuje na maternjem jeziku i bez posebnih tehničkih uslova, i u tome je vrijednost opisanog pristupa. Time se ne tvrdi da je platforma bolja od navedenih rješenja, jer bi takva ocjena zahtijevala odvojeno poređenje i mjerenje. Rad prikazuje kontekst u kojem platforma nastaje i potrebe na koje nastoji da odgovori.

Obim je za sada ograničen na uži izbor predmeta i razreda. Šire pokrivanje nastavnog sadržaja planira se za konačnu verziju, u kojoj će se sadržaj i težina zadataka dodatno prilagođavati individualnom napretku korisnika. Sistematično vrednovanje uticaja na učenje tek predstoji i biće sprovedeno na većem broju korisnika. Treba imati u vidu da su i u širim istraživanjima efekti ovakvih alata umjereni i zavisni od konteksta primjene [2], [6]. U tom smislu, dalji razvoj platforme podrazumijeva kako njeno tehničko unapređenje, tako i sistematično vrednovanje njenog obrazovnog efekta.

Sadržaj bi trebalo proširiti na sve nastavne predmete i razrede, a mehanizam prilagođavanja dalje razraditi. Dalji razvoj platforme biće zasnovan na povratnim informacijama korisnika i iskustvima stečenim tokom testiranja javno dostupne verzije. Usklađivanje sadržaja sa nastavnim planom i programom zahtijevalo bi saradnju sa nadležnim obrazovnim institucijama. U redovnoj nastavi ovakvo okruženje može poslužiti kao dopuna radu na času, a izvan nje kao sredstvo za samostalno učenje.

6. ZAKLJUČAK

U radu je predstavljena obrazovna platforma Učim.Online sa pedagoškog i razvojnog aspekta, kao obrazovno okruženje koje vještačku inteligenciju stavlja u službu personalizovanog učenja. U središtu rada nalazi se put od pedagoških načela do razvojnih odluka, pri čemu svaka od njih proizlazi iz problema koje platforma nastoji da riješi i potreba korisnika kojima je namijenjena. U tom smislu, tehnologija se u radu posmatra kao sredstvo za ostvarivanje pedagoških ciljeva, a ne kao cilj sama po sebi. Rad ukazuje na to da uspješna primjena savremenih tehnologija u obrazovanju ne zavisi samo od tehnoloških mogućnosti, već i od njihovog prilagođavanja konkretnom obrazovnom kontekstu.

Savremene tehnologije mogu predstavljati značajnu podršku nastavnom procesu, ali ne mogu zamijeniti nastavnika. Njihova najveća vrijednost ogleda se u tome što omogućavaju veću prilagođenost učenju, pravovremenu povratnu informaciju i dodatnu podršku učenicima, uz zadržavanje nastavnika kao ključnog nosioca obrazovnog procesa. U tom smislu, ovakva rješenja treba posmatrati kao dopunu nastavi i podršku samostalnom učenju, a ne kao zamjenu za postojeće oblike obrazovanja.

Posebnu pažnju zahtijeva primjena velikih jezičkih modela u obrazovanju. Njihov potencijal je značajan, ali ga prate i ograničenja, zbog čega ih je potrebno osmisliti tako da podržavaju razumijevanje gradiva, samostalno učenje i razvoj kritičkog mišljenja. Na taj način mogu doprinijeti procesu učenja, uz očuvanje aktivne uloge učenika u usvajanju i primjeni znanja.

LITERATURA

- [1] M. Bray, *Confronting the Shadow Education System: What Government Policies for What Private Tutoring?* Paris: UNESCO International Institute for Educational Planning, 2009.
- [2] J. A. Kulik and J. D. Fletcher, "Effectiveness of intelligent tutoring systems: A meta-analytic review," *Review of Educational Research*, vol. 86, no. 1, pp. 42–78, 2016, doi: 10.3102/0034654315581420.
- [3] B. S. Bloom, "The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring," *Educational Researcher*, vol. 13, no. 6, pp. 4–16, 1984, doi: 10.3102/0013189X013006004.
- [4] K. VanLehn, "The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems," *Educational Psychologist*, vol. 46, no. 4, pp. 197–221, 2011, doi: 10.1080/00461520.2011.611369.
- [5] J. Dunlosky et al., "Improving students' learning with effective learning techniques: Promising directions from cognitive and educational psychology," *Psychological Science in the Public Interest*, vol. 14, no. 1, pp. 4–58, 2013, doi: 10.1177/1529100612453266.
- [6] J. F. Pane et al., *Continued Progress: Promising Evidence on Personalized Learning*. Santa Monica, CA: RAND Corporation, RR-1365-BMGF, 2015, doi: 10.7249/RR1365.
- [7] Z. Ji et al., "Survey of hallucination in natural language generation," *ACM Computing Surveys*, vol. 55, no. 12, pp. 1–38, 2023, doi: 10.1145/3571730.
- [8] H. L. Roediger III et al., "Test-enhanced learning in the classroom: Long-term improvements from quizzing," *Journal of Experimental Psychology: Applied*, vol. 17, no. 4, pp. 382–395, 2011, doi: 10.1037/a0026252.
- [9] M. Sailer and L. Homner, "The gamification of learning: A meta-analysis," *Educational Psychology Review*, vol. 32, no. 1, pp. 77–112, 2020, doi: 10.1007/s10648-019-09498-w.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



DIGITALIZACIJA PROCESA UPRAVLJANJA STUDENTSKIM ZAVRŠNIM RADOVIMA – ANALIZA POTREBA I RAZVOJ WEB SISTEMA

Luka Lakobrija, Dražen Marinković

Panevropski univerzitet „APEIRON“, Banja Luka, Republika Srpska, Bosna i Hercegovina,
luka.lakobrija@apeiron-edu.eu; drazen.m.marinkovic@apeiron-edu.eu

Apstrakt: Digitalizacija administrativnih i organizacionih procesa predstavlja važan dio digitalne transformacije visokog obrazovanja. Jedan od procesa koji obuhvata veći broj međusobno povezanih aktivnosti jeste upravljanje studentskim završnim radovima, od objavljivanja i izbora tema, preko prijava i prijedloga studenata, do donošenja odluka, mentorstva, formiranja komisije i praćenja statusa rada. Cilj ovog rada je analiza potreba korisnika, kao i projektovanje i razvoj web informacionog sistema kojim se navedene aktivnosti objedinjuju u centralizovanom digitalnom okruženju. Kao podrška definisanju zahtjeva sprovedeno je anketno istraživanje u kojem su učestvovala 92 ispitanika. Rezultati su pokazali izraženu potrebu za boljom dostupnošću informacija, ažurnijim praćenjem statusa i elektronskom obradom zahtjeva, pri čemu je 83,7% ispitanika pozitivno ocijenilo tvrdnju da bi jedinstvena digitalna platforma unaprijedila postojeći proces. Razvijeni sistem podržava osnovne aktivnosti upravljanja završnim radovima i definiše poslovna pravila kojima se uređuju dodjela tema, obrada prijava i prijedloga, kao i formiranje komisije. Rezultati rada pokazuju da se ključne aktivnosti ovog procesa mogu objединiti u jedinstven informacioni sistem, čime se stvara osnova za preglednije i konzistentnije upravljanje podacima i postupcima vezanim za završne radove.

Ključne riječi: digitalizacija visokog obrazovanja, završni radovi, informacioni sistem, web aplikacija

DIGITALIZATION OF THE STUDENT THESIS MANAGEMENT PROCESS – NEEDS ANALYSIS AND DEVELOPMENT OF A WEB-BASED SYSTEM

Abstract: Digitalization of administrative and organizational processes represents an important aspect of the digital transformation of higher education. One process that includes a number of interconnected activities is student thesis management, ranging from publishing and selecting thesis topics, through student applications and proposals, to decision-making, supervision, committee formation and thesis status tracking. The aim of this paper is to analyze user needs and present the design and development of a web-based information system that integrates these activities into a centralized digital environment. A survey involving 92 respondents was conducted to support the definition of system requirements. The results indicated a strong need for improved information availability, more up-to-date status tracking and electronic request processing, with 83.7% of respondents positively evaluating the statement that a unified digital platform would improve the existing process. The developed system supports the main activities related to thesis management and defines business rules governing topic assignment, application and proposal processing, and committee formation. The results of the work indicate that the key activities of this process can be integrated into a unified information system, providing a basis for more transparent and consistent management of data and procedures related to student theses.

Keywords: higher education digitalization, student theses, information system, web application

1. UVOD

Digitalizacija visokoškolskih ustanova ne obuhvata samo elektronsko učenje i izvođenje nastave, već i administrativne i organizacione procese koji prate studenta tokom studiranja. Jedan od takvih procesa jeste upravljanje studentskim završnim radovima, koji obuhvata objavljivanje i izbor tema, prijavljivanje studenata, predlaganje vlastitih tema, donošenje odluka, formiranje komisije, mentorstvo i praćenje statusa rada.

U tradicionalno organizovanom procesu podaci i komunikacija mogu biti raspoređeni kroz različite evidencije, elektronsku poštu, neposredne konsultacije i druge kanale. Takav pristup može otežati pregled dostupnih tema, praćenje statusa zahtjeva i usklađivanje podataka između studenata, profesora i administracije.

Predmet ovog rada je projektovanje i razvoj web informacionog sistema kojim se ključne aktivnosti upravljanja studentskim završnim radovima objedinjuju u centralizovanom digitalnom okruženju. Sistem je namijenjen studentima, profesorima i administratorima i omogućava upravljanje temama, elektronsko podnošenje i obradu prijave i prijedloga, evidenciju komisije, mentorstvo i praćenje statusa završnog rada. Tokom projektovanja sistema pažnja je posvećena poslovnim pravilima kojima se uređuju dodjela teme studentu, obrada više prijave i prijedloga, formiranje komisije i prelazi između pojedinih stanja procesa. Na taj način informacioni sistem ne predstavlja samo centralizovanu evidenciju podataka, već podržava i pravila prema kojima se proces završnog rada odvija.

Cilj rada je prikazati analizu potreba, projektovanje i implementaciju navedenog sistema. Kao podrška definisanju funkcionalnih zahtjeva sprovedeno je anketno istraživanje čiji su konačni rezultati prikazani u narednom poglavlju. Nakon toga predstavljeni su arhitektura i model podataka, poslovna pravila, implementirane funkcionalnosti, kao i rezultati i ograničenja razvijenog rješenja.

2. ANALIZA POTREBA I DEFINISANJE ZAHTJEVA SISTEMA


U cilju procjene potrebe za digitalizacijom procesa upravljanja studentskim završnim radovima i identifikovanja funkcionalnosti koje bi potencijalnim korisnicima bile najznačajnije sprovedeno je elektronsko anketno istraživanje. Istraživanje je sprovedeno u periodu od 11.08.2026. do 16.09.2026. godine i obuhvatilo je ukupno 92 ispitanika. Upitnik je sadržao 14 pitanja i tvrdnji različitog tipa. Za dio tvrdnji korišćena je petostepena skala od 1 do 5, pri čemu više vrijednosti označavaju veći stepen slaganja.

Od ukupnog broja ispitanika, 59,8% imalo je prethodno ili trenutno neposredno iskustvo sa procesom izbora, prijave, mentorstva, odobravanja ili administrativnog praćenja završnog rada. Od toga je 33,7% učestvovalo u procesu jednom, 23,9% je u trenutku istraživanja prvi put učestvovalo u procesu, dok je 2,2% učestvovalo dva ili više puta. Preostalih 40,2% ispitanika nije imalo neposredno iskustvo sa analiziranim procesom.

Kao najčešći način razmjene informacija i sprovođenja postupka prijave teme izdvojeni su lični razgovori i konsultacije, koje je navelo 51,1% ispitanika, dok je elektronsku poštu navelo 38,0%. Manji broj ispitanika naveo je kombinovanje više međusobno nepovezanih kanala, papirne obrasce ili nedovoljnu upoznatost sa trenutnim postupkom. Rezultati pokazuju relativno niske ocjene pojedinih aspekata postojećeg procesa. Efikasnost trenutnog načina objavljivanja, izbora, prijave i odobravanja tema ocijenjena je prosječnom ocjenom 2,34 od 5. Preglednost i dostupnost informacija o temama, statusu, naučnoj oblasti i mentoru dobila je prosječnu ocjenu

2,05, dok je mogućnost jednostavnog praćenja trenutnog statusa prijave, prijedloga ili teme ocijenjena sa 2,34.

Nasuprot tome, stavovi prema uvođenju digitalnog sistema bili su izrazito pozitivni. Tvrdnja da bi jedinstvena digitalna platforma unaprijedila proces dobila je prosječnu ocjenu 4,48, pri čemu je 83,7% ispitanika dalo ocjenu 4 ili 5. Tvrdnja da bi digitalni sistem smanjio vrijeme i trud učesnika takođe je ocijenjena sa 4,48, uz 87,0% ocjena 4 i 5. Tvrdnja da bi elektronsko podnošenje, pregled i odobravanje prijava i prijedloga smanjilo administrativno opterećenje učesnika u procesu dobila je prosječnu ocjenu 4,55, dok je centralizovana evidencija tema, prijava, prijedloga, odluka i promjena statusa ocijenjena sa 4,61. Tvrdnju da bi automatsko evidentiranje promjena smanjilo mogućnost grešaka i neusaglašenih podataka ocjenom 4 ili 5 ocijenilo je 89,1% ispitanika, uz prosječnu ocjenu 4,50. Najveća prosječna vrijednost zabilježena je kod spremnosti za korišćenje digitalnog sistema kao primarnog načina učestvovanja u procesu, koja iznosi 4,68, pri čemu je 90,2% ispitanika dalo ocjenu 4 ili 5.




Slika 2. Prosječne ocjene ključnih tvrdnji anketnog istraživanja

Slika 1 pokazuje izraženu razliku između ocjene trenutnog načina organizacije procesa i stavova prema njegovoj digitalizaciji.

Dok su efikasnost, dostupnost informacija i mogućnost praćenja statusa ocijenjene prosječnim vrijednostima od približno 2 do 2,3, tvrdnje povezane sa uvođenjem jedinstvenog digitalnog sistema imaju prosječne vrijednosti između 4,48 i 4,68.

Kod pitanja u kojem je bilo moguće označiti više problema, najčešće je naveden nedovoljno jasan i centralizovan pregled dostupnih tema, koji je označilo 72,8% ispitanika. Neažurne informacije o tome da li je tema slobodna, zauzeta ili završena navelo je 69,6%, nedovoljno dostupne informacije o sadržaju i uslovima pojedinačnih tema 63,0%, a otežano pronalaženje tema prema naučnoj oblasti ili mentoru 62,0% ispitanika.

Dug period čekanja na odgovor ili odluku navelo je 60,9% ispitanika, nejasno definisane korake prijave i odobravanja teme 59,8%, dok je otežano praćenje statusa prijave ili prijedloga navelo 58,7%.



Slika 3. Najčešće uočeni problemi u postojećem procesu upravljanja završnim radovima

Rezultati ukazuju da najveći dio identifikovanih poteškoća nije vezan za samo postojanje pojedinačnih informacija, već za njihovu raspoređenost, ažurnost i mogućnost praćenja procesa kroz jedinstvenu evidenciju. Zbog toga su centralizacija podataka, ažuriranje statusa i dostupnost informacija izdvojeni kao važni zahtjevi budućeg sistema.

Ispitanici su kao najkorisnije funkcionalnosti digitalnog sistema najčešće izdvojili pretragu tema prema nazivu ili ključnim riječima i pregled detaljnih informacija o temi, mentoru i komisiji, koje je označilo po 78,3% ispitanika. Elektronsko podnošenje prijave na izabranu temu navelo je 73,9%, filtriranje tema prema statusu, naučnoj oblasti ili mentoru 68,5%, dok je praćenje statusa prijave, prijedloga ili teme označilo 67,4% ispitanika.

Dobijeni rezultati korišćeni su kao podrška definisanju funkcionalnih zahtjeva sistema. Na osnovu najčešće identifikovanih problema i očekivanja korisnika, razvijeno rješenje usmjereno je na centralizovan katalog tema, pretragu i filtriranje, detaljan prikaz podataka, elektronsko podnošenje i obradu prijava i prijedloga, evidentiranje komisije i praćenje statusa završnog rada.

3. PROJEKTOVANJE SISTEMA

Sistem za upravljanje studentskim završnim radovima projektovan je kao web aplikacija zasnovana na klijent-server arhitekturi. Projektovanje je obuhvatilo definisanje tehnološke arhitekture, korisničkih uloga, modela podataka i poslovnih pravila kojima se uređuju prijavljivanje studenata, dodjela tema, obrada prijedloga i formiranje komisije. Posebna pažnja posvećena je povezivanju podataka i ograničavanju stanja sistema tako da pojedinačne korisničke akcije ne dovedu do međusobno nekonzistentnih evidencija.


3.1. Arhitektura sistema

Sistem se sastoji od klijentske aplikacije, serverskog Web API-ja i relacione baze podataka. Ovakva organizacija omogućava razdvajanje korisničkog interfejsa od poslovne logike i trajnog čuvanja podataka. Serverski dio realizovan je na .NET 8 platformi, koja predstavlja razvojno okruženje za izgradnju različitih tipova aplikacija [1]. Za realizaciju serverskog interfejsa korišćen je ASP.NET Core Web API, preko kojeg klijentska aplikacija pristupa poslovnim funkcionalnostima sistema HTTP zahtjevima [2].

Klijentski dio aplikacije razvijen je korišćenjem biblioteke React i programskog jezika TypeScript. React omogućava organizaciju korisničkog interfejsa kroz komponente i upravljanje

njihovim stanjem [3], dok TypeScript proširuje JavaScript sistemom statičkih tipova i omogućava preciznije definisanje strukture podataka koji se razmjenjuju između klijenta i serverske aplikacije [4]. Za pristup podacima korišćen je Entity Framework Core, objektno-relacioni mapper kojim se rad sa relacionom bazom povezuje sa .NET objektima i kontekstom podataka [5]. Trajno čuvanje poslovnih i korisničkih podataka realizovano je u Microsoft SQL Server sistemu za upravljanje relacionim bazama podataka [6].

Komunikacija između klijentskog i serverskog dijela odvija se HTTP zahtjevima, uz razmjenu podataka u JSON formatu. Korisnička akcija, kao što su pretraga tema, podnošenje prijave ili obrada studentskog prijedloga, pokreće odgovarajući zahtjev prema Web API-ju. Serverska aplikacija provjerava ovlaštenja i poslovne uslove, pristupa bazi podataka i rezultat vraća klijentskoj aplikaciji.



Slika 4. Arhitektura sistema za upravljanje studentskim završnim radovima

3.2. Korisničke uloge i funkcionalne cjeline

Sistem razlikuje tri osnovne korisničke uloge: studenta, profesora i administratora. Dio podataka, prvenstveno katalog tema i detalji pojedinačne teme, dostupan je i neprijavljenim korisnicima. Student može pregledati i pretraživati dostupne teme, prijaviti se na postojeću slobodnu temu, predložiti vlastitu temu i pratiti stanje svojih zahtjeva. Vlastiti prijedlog može mijenjati dok se nalazi u statusu „Na čekanju“, dok nakon njegovog prihvatanja sadržaj prijedloga više nije moguće mijenjati.

Profesor može kreirati teme, uređivati i skrivati teme nad kojima ima odgovarajuća prava, obrađivati prijave studenata na postojeće teme i odlučivati o prijedlozima za koje je predložen kao mentor. Profesor takođe ima pregled tema pod svojim mentorstvom i mogućnost evidentiranja završetka odnosno odbrane rada.


Administrator ima širi nivo pristupa i može pregledati i upravljati temama, studentskim prijavama i prijedlozima nezavisno od konkretnog mentorstva. Kontrola pristupa realizovana je i na nivou korisničkog interfejsa i na serverskoj strani za zaštićene operacije.

3.3. Model podataka

Centralni poslovni entitet sistema je Tema. Tema sadrži podatke o naslovu i opisu rada, naučnoj oblasti, mentoru, profesoru koji ju je postavio, statusu i vidljivosti. Student se ne evidentira kao direktno polje entiteta Tema, već se veza između studenta i teme ostvaruje preko evidencije prijave. Za klasifikaciju tema koristi se entitet NaucnaOblast, dok entitet TipStatusaTeme predstavlja šifarnik osnovnih stanja teme. U implementiranom sistemu osnovni životni ciklus teme obuhvata statuse „Slobodna“, „Zauzeta“ i „Odbranjena“. Veza između studenta i postojeće teme ostvaruje se preko entiteta TemaPrijava. Jedan student tokom korišćenja sistema može podnijeti prijave na različite teme, dok jedna slobodna tema može primiti više prijave prije donošenja odluke. Zbog toga odnos studenta i teme preko prijave na nivou istorije predstavlja vezu više-prema-više. Status prijave određuje da li je zahtjev na čekanju, prihvaćen ili odbijen.

Studentsko predlaganje vlastite teme evidentira se zasebnim entitetom PrijedlogStudenta. On čuva originalni prijedlog studenta, izabranu naučnu oblast, predloženog mentora i status zahtjeva. Nakon prihvatanja prijedloga, polje KreiranaTemaId omogućava povezivanje izvornog studentskog prijedloga sa temom koja je na osnovu njega kreirana. Komisija se modeluje pomoću spojnog entiteta TemaKomisija, koji povezuje temu i profesora i dodatno čuva ulogu profesora u komisiji. Na taj način jedan profesor može učestvovati u komisijama više tema, dok jedna tema može imati više članova komisije.

Na slici 4 prikazani su ključni entiteti sistema, njihovi primarni i strani ključevi, kao i veze i kardinalnosti između tabela. Naučna oblast povezana je sa više tema, profesor može biti mentor ili autor više tema, dok se veze studenta i teme, odnosno profesora i komisije, ostvaruju preko spojnih entiteta TemaPrijava i TemaKomisija



Slika 5. Relacioni model baze podataka sistema

3.4. Poslovna pravila sistema

Poslovna pravila definišu dozvoljena stanja sistema i uslove pod kojima korisničke akcije mogu biti izvršene. Ona dopunjuju ograničenja relacionog modela i omogućavaju očuvanje konzistentnosti podataka tokom prijavljivanja, odlučivanja i dodjele tema.

Tabela 1. Ključna poslovna pravila sistema

Poslovno pravilo	Implementirano ponašanje
Aktivna tema studenta	Student u jednom trenutku može imati najviše jednu aktivnu temu. Aktivnom se smatra tema povezana sa prihvaćenom prijavom čiji status nije „Odbranjena“.
Vlastiti prijedlog teme	Student može imati samo jedan vlastiti prijedlog sa statusom „Na čekanju“. Dok prijedlog čeka odluku može ga uređivati, nakon prihvatanja je zaključan, a nakon odbijanja može poslati novi prijedlog.
Prijava na postojeću temu	Student se može prijaviti samo na vidljivu i slobodnu temu, pod uslovom da nema aktivnu temu niti vlastiti prijedlog na čekanju. Ponovna prijava istog studenta na istu temu nije dozvoljena dok odgovarajući zapis postoji.
Više prijava studenta	Student može imati više prijava na čekanju, ali prihvatanjem jedne od njih dobija jednu aktivnu temu, dok se njegovi ostali zahtjevi na čekanju automatski odbijaju.
Više kandidata za istu temu	Jedna slobodna tema može imati više prijava na čekanju. Prihvatanjem jedne prijave tema prelazi u status „Zauzeta“, dok se ostale prijave na čekanju za tu temu odbijaju.
Sastav komisije	Komisija mora imati najmanje dva različita profesora: jednog predsjednika komisije i profesora koji je mentor teme. Treći i dodatni članovi komisije su opcioni.
Prihvatanje vlastitog prijedloga	Konačnim prihvatanjem prijedloga kreiraju se povezana tema, komisija i prihvaćena prijava, a izvorni prijedlog se povezuje sa nastalom temom. Prije konačne odluke mentor ili administrator može definisati konačni naslov, opis, naučnu oblast i sastav komisije. Tek nakon potvrde kreira se nova vidljiva tema sa statusom „Zauzeta“, upisuju se članovi komisije, kreira prihvaćena prijava koja povezuje studenta sa temom i prijedlog se povezuje sa nastalom temom.
Obrada istovremenih zahtjeva	Serverska logika prije izmjene ponovo provjerava stanje podataka, dok se povezane operacije izvršavaju u okviru koordinisane transakcije kako bi se spriječile višestruke aktivne dodjele ili djelimični upisi.

4. RAZVOJ I IMPLEMENTACIJA SISTEMA

Razvijena aplikacija obuhvata nekoliko međusobno povezanih funkcionalnih cjelina: upravljanje temama i komisijama, studentske prijave na postojeće teme, predlaganje vlastitih tema, obradu zahtjeva, mentorstvo, praćenje statusa rada i kontrolu pristupa. Implementacija je zasnovana na prethodno opisanom relacionom modelu i poslovnim pravilima, pri čemu klijentska aplikacija upravlja korisničkom interakcijom, dok serverski dio provjerava ovlaštenja, trenutno stanje podataka i uslove za izvršavanje poslovnih operacija.

4.1. Upravljanje temama i komisijom

Javni katalog tema predstavlja osnovnu funkcionalnu cjelinu sistema. Korisniku omogućava pregled raspoloživih tema, pretragu i filtriranje prema statusu, naučnoj oblasti i mentoru, kao i pristup detaljnom prikazu pojedinačne teme. Za svaku temu mogu se prikazati osnovni podaci, naučna oblast, mentor, status, sastav komisije i, kada postoji prihvaćena prijava, student kojem je tema dodijeljena. Profesor i administrator imaju mogućnost kreiranja novih tema. Direktno kreirana tema dobija status „Slobodna“ i postaje vidljiva u katalogu. Kod profesora serverska aplikacija identitet prijavljenog profesora koristi kao mentora i profesora koji je temu postavio, dok administrator može upravljati širim skupom podataka.

Formiranje komisije sastavni je dio kreiranja i uređivanja teme. Klijentska aplikacija koristi zajedničku komponentu za uređivanje sastava komisije, dok serverska aplikacija prije trajnog upisa primjenjuje jedinstvenu validaciju. Komisija mora sadržati najmanje dva različita postojeća profesora: jednog sa ulogom predsjednika komisije i profesora koji je mentor teme. Treći i dodatni članovi sa ulogom člana komisije su opcioni. Ista serverska validacija primjenjuje se pri kreiranju teme, opštem uređivanju postojeće teme i prihvatanju studentskog prijedloga vlastite teme. Time se izbjegava mogućnost da različiti korisnički tokovi formiraju teme prema različitim pravilima komisije.

Prilikom izmjene teme provjerava se konačni mentor i konačni sastav komisije prije izmjene podataka. Ako se dostavlja novi sastav komisije, postojeća članstva se zamjenjuju novim, validnim skupom.

Kod kreiranja nove teme podaci o temi i članovima komisije čuvaju se kao jedna cjelina. Neispravan sastav komisije prekida operaciju prije objavljivanja teme. Na taj način korisnički interfejs olakšava pravilan izbor članova, ali se konačna provjera ipak izvršava na serverskoj strani. Profesor može uređivati i skrivati teme kojima je mentor, dok administrator ima proširen nivo upravljanja. Uklanjanje teme iz javnog kataloga realizovano je kao logičko skrivanje promjenom atributa vidljivosti, a ne fizičkim brisanjem zapisa iz baze.

4.2. Prijava na postojeću temu

Student se može prijaviti na postojeću temu samo ako je tema vidljiva i nalazi se u statusu „Slobodna“. Serverska aplikacija identitet studenta određuje iz autentifikovanog korisničkog naloga, tako da podaci poslani kroz formu ne mogu promijeniti vlasnika prijave. Prije kreiranja prijave provjerava se da student nema aktivnu temu, da nema vlastiti prijedlog teme sa statusom „Na čekanju“ i da prethodno nije poslao prijavu na istu temu koja još postoji u sistemu. Uspješnim podnošenjem nastaje zapis prijave sa statusom „Na čekanju“, ali se sama tema u tom trenutku ne zauzima.

Jedan student može imati više prijava na različite teme dok nijedna nije prihvaćena. Slično tome, jedna slobodna tema može imati više kandidata. Odluku o prijavi donosi mentor odgovarajuće teme ili administrator.


Pri prihvatanju prijave sistem ponovo provjerava njeno trenutno stanje, dostupnost teme i postojanje druge aktivne teme studenta. Uspješnim prihvatanjem prijava dobija status „Prihvaćeno“, a tema prelazi iz statusa „Slobodna“ u „Zauzeta“. Istovremeno se odbijaju ostale prijave na čekanju za istu temu, kao i preostali zahtjevi tog studenta na čekanju koji više ne mogu rezultovati drugom aktivnom dodjelom. Promjena statusa teme iz slobodne u zauzetu u

ovom toku evidentira se i u istoriji statusa. Odbijanje prijave, sa druge strane, mijenja samo status odgovarajuće prijave i ne zauzima temu. Na ovaj način sistem dozvoljava da student razmatra više raspoloživih tema kroz više prijava, ali konačna poslovna odluka može rezultovati samo jednom aktivnom temom.

4.3. Predlaganje i prihvatanje vlastite teme

Pored prijavljivanja na postojeće teme, student može inicirati proces predlaganjem vlastite teme. Prilikom kreiranja prijedloga unose se naslov, opis, naučna oblast i predloženi mentor. Student može imati samo jedan vlastiti prijedlog sa statusom „Na čekanju“ i ne može kreirati novi prijedlog ako već ima aktivnu temu.

Nakon prvog slanja prijedlog dobija status „Na čekanju“. Student može ponovo otvoriti isti prijedlog i uređivati naslov, opis, naučnu oblast i predloženog mentora sve dok odluka nije donesena. Pri tome se ne kreira novi zapis, već se mijenja postojeći prijedlog sa istim identifikatorom. O prijedlogu može odlučivati predloženi mentor ili administrator. Odbijanjem prijedlog dobija status „Odbijen“, nakon čega student može poslati novi prijedlog. Prihvatanje je složenija operacija i ne izvršava se neposredno pritiskom na dugme za odobravanje. Prije konačnog prihvatanja otvara se posebna forma u kojoj mentor ili administrator pregledava i po potrebi uređuje konačni naslov, opis i naučnu oblast, kao i sastav komisije. Predloženi mentor ostaje mentor teme. Sistem inicijalno predlaže predsjednika komisije, mentora i, kada postoji odgovarajući kandidat, opcionog trećeg člana. Treći i dodatni članovi mogu se ukloniti ili zamijeniti, dok konačni sastav mora zadovoljiti opšte pravilo komisije.



Slika 6. Osnovni tok upravljanja završnim radom

Konačna potvrda vlastitog prijedloga predstavlja povezanu poslovnu operaciju. Serverska aplikacija ponovo provjerava da je prijedlog još uvijek na čekanju, da korisnik ima pravo donošenja odluke, da student nema aktivnu temu, da su podaci teme ispravni i da komisija zadovoljava propisana pravila. U slučaju uspjeha u okviru iste transakcije kreira se nova vidljiva tema sa statusom „Zauzeta“, upisuju se članovi komisije, kreira se prihvaćena TemaPrijava koja povezuje studenta sa novom temom, prijedlog dobija status „Prihvaćen“ i povezuje se sa kreiranom temom. Istovremeno se odbijaju ostali zahtjevi studenta na čekanju. Izvorni

studentski prijedlog ostaje sačuvan, dok novokreirana tema sadrži konačne podatke potvrđene prilikom odobravanja. Ovaj tok je u implementaciji realizovan kao jedna transakcijska cjelina.

The image shows two side-by-side web forms. The left form, titled 'Prijava za temu' (Topic Registration), has a blue header and contains fields for 'Tema: Optimizacija upita u distribuiranim bazama podataka', a note about auto-filled data, and input fields for 'Ime *', 'Prezime *', 'Broj indeksa', and 'Fakultet'. It also has a 'Poruka (opcionalno)' text area and 'Otkazi' and 'Pošalji prijavu' buttons. The right form, titled 'Prijedlog vlastite teme' (Propose your own topic), has a green header and includes a note about having only one proposal, a student data section with 'Ime *', 'Prezime *', 'Broj indeksa', and 'Fakultet', and a proposal data section with 'Naslov teme *', 'Opis teme', 'Naučna oblast', and 'Predloženi mentor'. It also has 'Otkazi' and 'Pošalji prijedlog' buttons.

Slika 7. Studentske forme za prijavu na postojeću i predlaganje vlastite teme

The image shows a web form titled 'Uredi i objavi temu iz prijedloga' (Edit and publish topic from proposal) with a blue header. It displays 'Student: Test_Ime Test_Prezime' and 'Mentor: Luka Lakobrija'. A light blue box contains instructions: 'Provjerite konačni naslov, opis i komisiju. Prijedlog će biti prihvaćen tek kada kliknete „Prihvati i objavi temu“.' Below are input fields for 'Konačni naslov *', 'Opis', and 'Naučna oblast *' (set to 'Računarske nauke'). The 'Komisija *' section lists 'Predsjednik komisije' (Siniša Tomić), 'Mentor' (Luka Lakobrija), and 'Član komisije' (Dražen Marinković), with a 'Dodaj člana komisije' button. At the bottom are 'Odustani' and 'Prihvati i objavi temu' buttons.

Slika 8. Konačna obrada i prihvatanje studentskog prijedloga

4.4. Mentorstvo i praćenje statusa rada

Mentorstvo u razvijenom sistemu nije modelovano kao zaseban entitet. Ono se izvodi iz postojećih podataka o temama tako što se za prijavljenog profesora izdvajaju vidljive teme kod

kojih je on mentor i koje se nalaze u statusu „Zauzeta“ ili „Odbranjena“. Student povezan sa takvom temom određuje se preko prihvaćene prijave.

Profesor na svojoj stranici može pregledati prijave, studentske prijedloge i teme pod mentorstvom. Kada je rad završen, mentor ili administrator može označiti zauzetu temu kao odbranjenu. Ova operacija dozvoljena je samo za temu koja se trenutno nalazi u statusu „Zauzeta“, nakon čega njen status prelazi u „Odbranjena“.

Status prihvaćene prijave pri tome ostaje nepromijenjen, jer predstavlja činjenicu da je studentu određena tema, dok status teme opisuje trenutno stanje samog završnog rada. Time su stanje zahtjeva i životni ciklus rada odvojeni u modelu.

Osnovni životni ciklus teme u implementiranom sistemu može se predstaviti kao:

Slobodna → Zauzeta → Odbranjena.

Direktno kreirana tema započinje kao slobodna, dok tema nastala prihvatanjem vlastitog studentskog prijedloga odmah nastaje kao zauzeta, jer je u istoj operaciji dodijeljena konkretnom studentu. Odbranjena tema više se ne smatra aktivnom temom studenta, pa student nakon toga može ponovo koristiti funkcionalnosti prijavljivanja i predlaganja u skladu sa ostalim poslovnim pravilima.

Trenutna implementacija evidentira osnovni status završetka rada, ali ne obuhvata termin odbrane, ocjenu, zapisnik niti elektronsku predaju završnog dokumenta.

4.5. Autentifikacija i kontrola pristupa

Upravljanje korisničkim identitetom realizovano je pomoću ASP.NET Core Identity sistema. Identity obezbjeđuje upravljanje korisničkim nalogima, lozinkama i ulogama, dok aplikacija poslovne podatke studenta i profesora povezuje sa odgovarajućim korisničkim nalogom [7]. Sistem koristi tri korisničke uloge: Student, Profesor i Admin. Nakon uspješne prijave korisnika serverska aplikacija generiše JWT token. JSON Web Token predstavlja standardizovan način prenosa skupa claims podataka između učesnika u komunikaciji [8].

Generisani token sadrži podatke potrebne za identifikaciju korisnika i određivanje njegove uloge, uključujući identifikator korisnika, e-mail, ime i, kada postoje, poslovne identifikatore studenta ili profesora. Klijentska aplikacija token uključuje u naredne autorizovane HTTP zahtjeve kao Bearer token.

Na klijentskoj strani informacije o prijavljenom korisniku koriste se za prilagođavanje navigacije i prikazanih funkcionalnosti. Studentu se prikazuju mogućnosti vezane za prijavljivanje i vlastite prijedloge, profesoru upravljanje temama i studentskim zahtjevima, dok administrator ima pristup administrativnim prikazima.

5. REZULTATI I DISKUSIJA

Rezultati anketnog istraživanja prikazani u poglavlju 2 ukazuju na potrebu za centralizovanim pristupom informacijama, jednostavnijim praćenjem statusa i elektronskom obradom zahtjeva u procesu upravljanja studentskim završnim radovima. Na osnovu identifikovanih potreba razvijen je sistem koji objedinjuje pregled i pretragu tema, prijavljivanje na postojeće teme, predlaganje vlastite teme, obradu zahtjeva, upravljanje komisijom, mentorstvo i praćenje statusa rada. Definisana poslovna pravila ograničavaju nedozvoljena i međusobno nekonzistentna stanja

sistema. Student može imati najviše jednu aktivnu temu, dok se prihvatanjem jedne prijave odbijaju ostali zahtjevi koji bi mogli dovesti do druge aktivne dodjele, a sastav komisije se provjerava prema jedinstvenim pravilima. Kod prihvatanja vlastitog studentskog prijedloga kreiranje teme, komisije i prihvaćene prijave izvršava se kao povezana transakcijska operacija.

Ispravnost ključnih poslovnih tokova dodatno je provjerena automatizovanim testovima. Serverski dio prošao je 66 integracionih provjera nad izolovanom SQL Server bazom, kojima su obuhvaćeni scenariji prijavljivanja, prihvatanja i odbijanja zahtjeva, upravljanja aktivnom temom, formiranja komisije i obrade studentskog prijedloga. Klijentski dio uspješno je izgrađen, dok je 14 dodatnih provjera obuhvatilo izbor i validaciju sastava komisije. Navedene provjere potvrđuju ponašanje sistema u obuhvaćenim scenarijima.

Trenutna verzija sistema obuhvata ključne aktivnosti upravljanja temom od njenog objavljivanja ili predlaganja do evidentiranja odbrane. Funkcionalnosti koje nisu obuhvaćene trenutnom verzijom predstavljaju pravce daljeg razvoja sistema.

6. ZAKLJUČAK

U ovom radu predstavljeni su analiza potreba, projektovanje i razvoj web informacionog sistema za upravljanje studentskim završnim radovima. Razvijeno rješenje objedinjuje ključne aktivnosti procesa, uključujući pregled i izbor tema, studentske prijave i prijedloge, obradu zahtjeva, formiranje komisije, mentorstvo i praćenje statusa završnog rada.

Rezultati sprovedenog anketnog istraživanja ukazali su na izraženu potrebu za centralizovanim pristupom informacijama i digitalizacijom postojećeg procesa. U skladu sa identifikovanim zahtjevima, razvijeni sistem podržava glavne poslovne tokove i pravila potrebna za konzistentno upravljanje temama, prijavama, prijedlozima i komisijama.

Modernizacija ovakvog procesa ima značaj prvenstveno u objedinjavanju informacija i aktivnosti koje su u tradicionalnom pristupu često raspoređene kroz različite evidencije i komunikacione kanale. Centralizovan sistem omogućava jasniji pregled trenutnog stanja procesa, lakši pristup relevantnim podacima i dosljedniju primjenu definisanih poslovnih pravila. Digitalizacija ne podrazumijeva samo prenošenje postojećih obrazaca u elektronski oblik, već omogućava da se sam proces preciznije definiše i da se pojedine odluke i promjene statusa evidentiraju na kontrolisan i međusobno povezan način.

REFERENCE

- [1] Microsoft, "Introduction to .NET," Microsoft Learn, 2026.
- [2] Microsoft, "Create web APIs with ASP.NET Core," Microsoft Learn, 2026.
- [3] React, "React Reference Overview," React Documentation, 2026.
- [4] Microsoft, "The TypeScript Handbook," TypeScript Documentation, 2026.
- [5] Microsoft, "Overview of Entity Framework Core," Microsoft Learn, 2024.
- [6] Microsoft, "What Is SQL Server?," Microsoft Learn, 2026.
- [7] Microsoft, "Introduction to Identity on ASP.NET Core," Microsoft Learn, 2026.
- [8] Internet Engineering Task Force (IETF), "JSON Web Token (JWT)," RFC 7519, 2015. DOI: 10.17487/RFC7519.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



PRIMJENA BIOMETRIJSKOG PREPOZNAVANJA LICA U AUTOMATIZACIJI EVIDENCIJE PRISUSTVA U NASTAVI

Danijel Gajić, Tijana Talić

Fakultet informacionih tehnologija, Panevropski univerzitet „APEIRON“, Banja Luka, Bosna i Hercegovina,
danijel.gajic@apeiron-edu.eu; tijana.z.talic@apeiron-edu.eu

Sažetak: Evidencija prisustva studenata u obrazovnim ustanovama i dalje se najčešće svodi na liste za potpis i usmenu prozivku. Takvi pristupi troše vrijeme nastave, lako se zloupotrebljavaju i zahtijevaju naknadni ručni unos podataka. Rad opisuje sistem Evidentia, razvijen kao samostalno rješenje za automatsko bilježenje prisustva putem prepoznavanja lica u realnom vremenu. Implementacija je izvedena na Raspberry Pi 4, bez grafičkog procesora i bez stalne veze sa spoljnom mrežom. Detekcija lica koristi HOG metodu, a identifikacija se vrši poređenjem 128-dimenzionih enkodiranja euklidskom udaljenošću. Pouzdanost se postiže praćenjem lica kroz vrijeme, uklanjanjem višestrukih detekcija, glasanjem preko više kadrova za određivanje identiteta i potvrdom tek nakon minimalnog zadržavanja u kadru. Opisana je aplikacija, njene mogućnosti i uočena ograničenja, uz prijedlog nadogradnje preko višemodalne biometrije i dodatnog faktora autentifikacije.

Ključne riječi: prepoznavanje lica, biometrija, evidencija prisustva, računarski vid, HOG

APPLICATION OF BIOMETRIC FACE RECOGNITION IN AUTOMATING ATTENDANCE RECORDING IN TEACHING

Abstract: Recording student attendance in educational institutions usually relies on sign-in sheets and roll calls; methods that consume teaching time, are prone to misuse and require subsequent manual data entry. This paper presents Evidentia, a system developed as a standalone solution for automatic attendance recording based on real-time face recognition. The system is implemented on the Raspberry Pi 4 embedded platform, without relying on a graphics processor and without the need for a permanent connection to an external network. Face detection is performed using the HOG approach, while identification is carried out by comparing 128-dimensional encodings using Euclidean distance. Reliability is achieved by tracking faces over time, removing duplicate detections, determining identity by voting across multiple frames, and confirming a face only after a minimum dwell time. The developed application, its functionality and the observed limitations are described, together with a proposal for an upgrade through multimodal biometrics and an additional authentication factor.

Keywords: face recognition, biometrics, attendance recording, computer vision, HOG

1. UVOD

Evidentiranje prisustva studenata spada u redovne aktivnosti obrazovnih ustanova, no u praksi se još uvijek najčešće obavlja na stari način. Liste kruže prostorijom, prozivka ide po spisku, prisustvo se bilježi rukom. Ti pristupi imaju nekoliko jasnih nedostataka. Prozivka i kruženje liste oduzimaju vrijeme nastave, naročito u većim grupama; samo evidentiranje može potrajati

nekoliko minuta na početku svakog časa. Potpis predstavlja slab dokaz prisustva jer se lako falsifikuje, pa student može upisati odsutnog kolegu i time ugroziti pouzdanost cijele evidencije. Naknadni prepis podataka u digitalni oblik unosi dodatne greške i troši vrijeme nastavnog osoblja, dok se podaci prikupljeni na papiru teško obrađuju; uvid u prisustvo pojedinog studenta tokom semestra zahtijeva ručni pregled i prebrojavanje.

Cilj rada je razvoj sistema za automatsko evidentiranje prisustva studenata zasnovanog na prepoznavanju lica u realnom vremenu. Prepoznavanje lica kao biometrijska metoda ovdje nudi nekoliko prednosti: identifikacija je beskontaktna i ne traži nikakvu dodatnu radnju studenta osim prisustva u prostoriji, lice je teže falsifikovati od potpisa, a podaci se odmah pohranjuju u strukturiranom obliku pogodnom za analizu i izvoz.

U okviru rada projektovan je i implementiran sistem pod nazivom Evidentia. Cjelokupno rješenje postavljeno je na jedan uređaj, Raspberry Pi 4, koji radi bez grafičkog procesora i bez zavisnosti od spoljne mrežne infrastrukture; sistemu se pristupa putem web pregledača.

2. METODE I TEHNIKE KORIŠTENE U RADU

Biometrijske tehnologije

Prepoznavanje lica spada u fiziološku biometriju, jer koristi geometriju lica kao fizičku karakteristiku [1].

Metoda je beskontaktna jer ne traži fizički dodir sa senzorom, dovoljno je da se lice nađe u vidnom polju kamere. U poređenju sa otiskom prsta, prednost je u higijeni i prirodnijem načinu rada, uz odsustvo potrebe za rukovanjem uređajem; nedostatak je veća osjetljivost na osvjtljenje i položaj glave. U poređenju sa RFID karticama, koje su brze i jednostavne, prednost je u tome što se lice ne može izgubiti, ukrasti niti posuditi drugoj osobi, što je u kontekstu evidencije prisustva od posebnog značaja.

Detekcija i prepoznavanje lica

Detekcija lica i prepoznavanje lica predstavljaju dva odvojena koraka u toku obrade. Detekcija utvrđuje da li se lice pojavljuje u slici i vraća njegovu lokaciju, oslanjajući se na opšte obrasce crta lica. Prepoznavanje utvrđuje identitet lica u odnosu na bazu poznatih osoba i zahtijeva specifične, prepoznatljive karakteristike pojedinca. U praksi se prepoznavanje oslanja na detekciju: najprije se lice locira, a zatim se vrši identifikacija.

Za detekciju je u radu primijenjen histogram orijentisanih gradijenata (HOG), koji objekat opisuje kroz raspodjelu orijentacija gradijenata u lokalnim područjima slike [2]. Postupak uključuje računanje gradijenata po obje ose, grupisanje njihovih orijentacija, organizaciju po ćelijama i lokalnu normalizaciju po blokovima, čime metod postaje otporniji na promjene osvjtljenja. Izbor HOG pristupa predstavlja svjestan kompromis između tačnosti i računarskog troška. Haar kaskadni detektor [3] je po pravilu brži, ali manje stabilan na varijacije poze, dok konvolucione neuronske mreže, poput MTCNN arhitekture [4], daju najvišu tačnost uz osjetno veće zahtjeve prema procesoru. Na platformi bez grafičke kartice, HOG obezbjeđuje prihvatljivu tačnost uz računarski trošak koji omogućava rad u realnom vremenu.


Prepoznavanje se zasniva na preslikavanju slike lica u prostor u kojem udaljenost predstavlja mjeru sličnosti. Taj pristup popularizovan je kroz FaceNet arhitekturu, koja kroz triplet loss uči

preslikavanje takvo da sidreni primjer bude bliži pozitivnom nego negativnom primjeru za definisanu marginu [5]. U ovom radu korištena je biblioteka `face_recognition`, koja predstavlja omotač oko biblioteke `dlib` [6]. Ona koristi duboku mrežu zasnovanu na ResNet arhitekturi, obučenu metodama dubokog metričkog učenja, koja lice prevodi u vektor od 128 vrijednosti. Poređenje dva lica svodi se na računanje euklidske udaljenosti između njihovih vektora:

$$d = \|e_1 - e_2\|_2$$

Prag udaljenosti nosi direktan praktičan značaj, smanjenjem vrijednosti broj lažnih prihvatanja pada ali lažna odbijanja rastu; literatura za `dlib` obično spominje 0,6 dok je ovdje primijenjeno 0,5 kao stroži kriterijum radi manje šanse pogrešne evidencije. Kada nijedno poznato lice ne prođe prag sistem vraća oznaku nepoznat.

Tok prepoznavanja ide od detekcije pa kroz logiku praćenja sve do potvrđenog lica.



Slika 1. Tok prepoznavanja: od detekcije, kroz logiku praćenja, do potvrđenog lica

Tehnologije implementacije

Odabir tehnologija slijedio je potrebu za stabilnošću i rad na skromnim resursima uz oslanjanje na provjerene komponente otvorenog koda. Serverska strana napisana je u Pythonu i koristi radni okvir Flask; teške operacije obrade slike izvršavaju optimizovane C i C++ biblioteke dok Python služi kao sloj za upravljanje tokom i povezivanje dijelova aplikacije. Flask daje REST rute i posluživanje statičkih datoteka, proširenje flask-sock donosi WebSocket komunikaciju dakle stalnu dvosmjernu vezu pogodnu za neprekidan prenos slike i podataka o prepoznatim licima. Pored biblioteke face_recognition tu su OpenCV za pomoćne korake obrade i JPEG kodiranje kadra, NumPy za numeričke operacije nad matricama i vektorima.


Trajno čuvanje podataka oslanja se na relacioni bazu MySQL; studenti sesije i zapisi prisustva jasno su povezani entiteti pa relacioni model pristaje prirodi problema. MySQL je izabran zbog stabilnosti i dobre podrške na Linux okruženju ciljnog uređaja. Korisnički dio realizovan je kao jednostranična aplikacija u biblioteci React uz Vite za razvoj i izgradnju; komponentni pristup dobro pristaje aplikaciji gdje se sadržaj često mijenja poput prikaza kamere uživo lista studenata i evidencije. Jednostranični model dopušta izmjenu sadržaja bez ponovnog učitavanja stranice.

Hardversku osnovu čini Raspberry Pi 4 Model B s četverojezgamim procesorom Cortex-A72 i preporučeno najmanje 4 GB radne memorije za rad u realnom vremenu. Rad s kamerom ide kroz biblioteku Picamera2 zasnovanu na okviru libcamera [7][8][9] ona je na aktuelnim izdanjima operativnog sistema zamijenila ranije alate i biblioteke.

Arhitektura sistema

Sistem organizovan je po troslojnom modelu gdje informacija putuje od kamere do korisničkog ekrana; sloj snimanja preuzima sliku sa kamere u rezoluciji 640×480 piksela i svaki kadar priprema u dvije varijante sirovu za analizu i JPEG verziju za prenos prema klijentu. Sloj prepoznavanja prima sirovi kadar detektuje lica računa enkodiranja i poredi ih sa bazom poznatih lica tu je i logika praćenja lica kroz vrijeme. Sloj prezentacije web aplikacija u pregledaču prikazuje video uživo sa okvirima oko prepoznatih lica vodi liste studenata i evidenciju te nudi kontrole za upravljanje.

Slojevi ne rade istim ritmom; nezavisni su a obrada raspodijeljena na tri niti koje teku paralelno. Nit snimanja radi onoliko brzo koliko kamera i procesor dozvoljavaju, nit prepoznavanja računarski najzahtjevnija radi znatno sporije pa se kadar prije obrade smanjuje na polovinu originalne veličine radi ubrzanja. Nit prenosa šalje klijentu posljednji kadar i posljednju listu prepoznatih lica namjerno ograničenim ritmom tako se postiže tečan prikaz bez nepotrebnog opterećenja mreže i procesora. Razmjena podataka odvija se kroz zajedničko stanje u memoriji servera; pristup zaštićen je odvojenim zaključavanjima za sliku stanje i podatke praćenja čime se sprječava konflikt istovremenog čitanja i upisa.



Slika 2. Arhitektura sistema i dijagram slučajeja upotrebe

3. REZULTATI: RAZVIJENA APLIKACIJA

Rezultat rada je funkcionalna aplikacija Evidentia postavljena kao samostalna cjelina na jednom uređaju; slijedi opis njenih ključnih funkcionalnosti.

Prikaz uživo i registracija lica

Središnji element interfejsa predstavlja prikaz kamere uživo; aplikacija putem WebSocket veze prima sliku kadra listu detektovanih i prepoznatih lica sa koordinatama i imenima. Preko slike iscrtavaju se okviri oko lica zajedno sa oznakom identiteta imenom osobe ili oznakom da je lice nepoznato a okviri se kreću u skladu sa kretanjem lica u kadru.

Da bi prepoznavanje bilo moguće osoba mora prethodno biti registrovana; registracija je osmišljena tako da se obavlja direktno iz prikaza uživo uz minimalan broj koraka. Pojavi li se u kadru lice koje sistem ne povezuje ni sa jednim poznatim identitetom ono se označava kao nepoznato dok je takvo lice dovoljno stabilno u pozadini se prikupljaju njegove slike i privremeno čuvaju. Broj slika ograničen je po osobi automatsko brisanje najstarijih po prekoračenju limita sprječava nekontrolisano gomilanje podataka. Klikom na nepoznato lice pokreće se registracija unose se podaci o osobi enkodiranje se trajno upisuje u bazu lica se povezuje sa odgovarajućim studentskim zapisom; poslije toga memorijski keš poznatih lica se osvježava i novo lice odmah postaje dostupno u procesu prepoznavanja.



Slika 3. Prikaz uživo sa okvirom oko prepoznatog lica

Logika pouzdanosti prepoznavanja

Detekcija na nivou pojedinačnog kadra nije dovoljna da bi evidencija bila pouzdana; lice može privremeno nestati iz kadra prepoznavanje može pogriješiti u jednom kadru osoba može samo proći kroz prostoriju bez stvarnog zadržavanja. Zato je uvedeno praćenje lica kroz vrijeme kao centralni element pouzdanosti sistema i ujedno glavni doprinos ovog rada.

Prvi mehanizam uključuje uklanjanje višestrukih detekcija unutar istog kadra; za isto lice može nastati više preklapajućih detekcija sistem ih prepoznaje po blizini centara i zadržava samo jednu pri čemu prednost imaju poznata lica u odnosu na nepoznata. Potom se detekcije povezuju kroz uzastopne kadrove; za svako lice održava se zapis praćenja koji se ažurira iz kadra u kadar nova detekcija najprije se povezuje sa postojećim zapisom prema blizini položaja u odnosu na prethodni kadar. Ako to nije moguće pouzdano izvesti recimo zbog naglog pomjeranja povezivanje se pokušava po sličnosti numeričkog opisa čime isti subjekt ostaje praćen i kada mijenja poziciju u slici.

Pošto identifikacija u jednom kadru može biti pogrešna identitet se određuje glasanjem; unutar zapisa praćenja pamti se koliko puta je dodijeljeno koje ime kao konačno uzima se najčešće a poznato ime ima prednost. Time se umanjuje uticaj povremenih pogrešnih klasifikacija. Uvedeno je minimalno vrijeme zadržavanja lica u kadru; lice se ne tretira kao potvrđeno odmah po pojavi nego tek nakon definisanog perioda prisutnosti tako se filtriraju prolazni slučajevi poput osobe koja samo prođe kroz vidno polje kamere. Zapis praćenja uklanja se nakon isteka definisanog perioda bez nove detekcije oslobađaju se resursi i sprječava zadržavanje zastarjelih zapisa. Sistem kontroliše da ista osoba ne bude predstavljena kroz dva različita zapisa praćenja; pojavi li se duplirani zapis zadržava se najstariji. Tek nakon svih tih provjera kada je lice stabilno prepoznato i jedinstveno rezultat se prosljeđuje na evidentiranje.

Sistem zadržava samo ona lica koja su u potpunosti unutar kadra; djelimično odsječena lica na ivicama slike uklanjaju se takvi slučajevi često proizvode nestabilne i nepouz dane ishode.

Model podataka i keširanje enkodiranja

Podaci se čuvaju u relacionoj bazi. Tabele obuhvataju osobe, enkodiranja lica, evidencije prisustva, studente, sesije i veze sesija sa studentima; strani ključevi između tabela održavaju referencijalni integritet.

Prepoznavanje zahtijeva poređenje svakog lica iz kadra sa svim poznatim enkodiranjima. Obrada se ponavlja više puta u sekundi. Pristup bazi znatno je sporiji od pristupa radnoj memoriji, pa bi čitanje enkodiranja iz baze za svaki kadar bitno usporilo rad. Enkodiranja se zato pri pokretanju sistema učitavaju u memorijski keš; on sadrži same vektore, imena osoba i njihove identifikatore. Nit prepoznavanja čita podatke iz tog keša. Postiže se osjetno brže poređenje. Keš se osvježava pri pokretanju sistema i nakon svake promjene skupa poznatih lica, recimo pri registraciji nove osobe ili brisanju postojeće, a pristup mu je, kao i ostalim dijeljenim strukturama, zaštićen zaključavanjem.


Sesije, evidencija prisustva i izvoz

Sistem podržava dvije vrste sesija; svaka ima drugačija pravila evidencije. Predavanje je otvorena sesija, bez unaprijed definisane liste. Evidentira se svaka osoba koju sistem prepozna dok sesija traje. Ispit je zatvorena sesija. Pri kreiranju se bira lista studenata koji pristupaju ispitu; sistem prati isključivo te studente i za svakog bilježi da li je potvrđen i u kojem trenutku. Lista se može mijenjati i naknadno, ali student koji je već potvrđen ne može biti uklonjen. U svakom trenutku može postojati najviše jedna aktivna sesija; prisustvo se bilježi samo tokom njenog trajanja.

Evidentiranje prisustva uslovljeno je sa dva preduslova. Prvi je postojanje aktivne sesije. Ako sesija nije aktivna, sistem i dalje prepoznaje lica i prikazuje rezultate, ali ne upisuje prisustvo; sprječava se bilježenje van vremena namijenjenog nastavi ili ispitu. Drugi preduslov je pouzdano prepoznavanje, odnosno prolazak kroz kompletnu logiku praćenja opisanu u podnaslovu „Logika pouzdanosti prepoznavanja“, pri čemu se nepoznata lica ne evidentiraju.

Sprečavanje duplikata izvedeno je u dva sloja. Na nivou aplikacije vodi se zapis o osobama koje su već evidentirane; isti identitet se ne upisuje ponovo, zapis se resetuje pri aktiviranju nove sesije, pa svaka sesija počinje iz početnog stanja. Na nivou baze postoji dodatno ograničenje koje onemogućava dvostruki zapis za istu osobu; duplikati se blokiraju i u slučaju greške na aplikativnom nivou. Upis se izvršava u posebnoj, kratkotrajnoj niti, kako obrada narednog kadra ne bi bila usporena čekanjem na bazu.

Prikupljeni zapisi mogu se izvesti u CSV format, pogodan za dalju obradu u tabličnim kalkulatorima. Struktura datoteke zavisi od tipa sesije: kod predavanja izvoz sadrži listu svih evidentiranih osoba sa vremenom dolaska, sortiranu po vremenu. Kod ispita sadrži listu studenata sa brojem indeksa, oznakom prisustva i vremenom prijave; prisutni su izdvojeni na vrhu.



Slika 4. Tab za rad sa sesijama i pregled evidencije

Sigurnost

Sistem obrađuje podatke o studentima i njihovom prisustvu; pristup funkcijama i podacima je ograničen. Sistemu se pristupa prijavom korisničkim imenom i lozinkom, nakon čega server otvara korisničku sesiju koja pamti prijavljeni status. Lozinka se ne čuva u čitljivom obliku; čuva se kao heš vrijednost dobijena kriptografskom heš funkcijom. Pristupni podaci i tajni ključ za potpisivanje sesija zadaju se kroz promjenljive okruženja; nisu dio izvornog koda. Sve rute koje mijenjaju podatke ili omogućavaju pristup osjetljivim informacijama zaštićene su provjerom prijavljenog stanja; ista kontrola primjenjuje se i na prenos slike uživo, WebSocket veza se prekida ako korisnik nije prijavljen.

4. ZAKLJUČAK

U radu je projektovan i realizovan funkcionalan sistem za automatsko evidentiranje prisustva studenata zasnovan na prepoznavanju lica u realnom vremenu. Rješenje je izvedeno kao samostalna cjelina na pristupačnoj hardverskoj platformi Raspberry Pi 4, uz pristup preko web pregledača. Pokazuje da se prepoznavanje lica za ovu namjenu može realizovati na uređaju bez grafičke kartice i sa ograničenim resursima.

U odnosu na tradicionalne metode, postignuto je beskontaktno evidentiranje koje ne zahtijeva nikakvu dodatnu radnju studenta. Otežano je evidentiranje odsutnih osoba i obezbijeđena je trenutna pohrana podataka u obliku pogodnom za pregled i izvoz. Ključni razlog za stabilnost rezultata jeste logika praćenja lica kroz vrijeme: umjesto oslanjanja na jedan kadar, sistem uklanja višestruke detekcije, određuje identitet glasanjem kroz više kadrova i potvrđuje lice tek nakon minimalnog vremena zadržavanja, čime se osjetno smanjuje broj pogrešnih evidentiranja. Arhitektura u tri sloja i raspodjela posla po nitima omogućavaju istovremeno snimanje, prepoznavanje i prikaz bez primjetnih zastoja.

Tokom izrade uočena su i ograničenja. Najznačajnije je odsustvo provjere živosti lica; sistem u trenutnoj formi nema mehanizam za otkrivanje pokušaja prevare fotografijom ili prikazom lica

na ekranu drugog uređaja. Tačnost prepoznavanja zavisi od uslova osvetljenja i ugla pod kojim je lice okrenuto prema kameri. Rješenje je vezano za jedan uređaj i jednu prostoriju. Poređenje sa poznatim licima izvodi se linearno, što je primjereno grupama u kojima je sistem testiran, ali zahtijeva dodatnu optimizaciju pri znatno većem broju registrovanih osoba. Sistem obrađuje biometrijske podatke, koji predstavljaju posebnu kategoriju ličnih podataka; šira primjena bi zahtijevala jasno definisan pravni osnov, pristanak studenata i rok čuvanja podataka.

Navedena ograničenja istovremeno ukazuju na pravce daljeg razvoja. Najprirodnije unapređenje je uvođenje dodatnog identifikacionog kanala; prelazak sa jednomodalnog na višemodalni biometrijski sistem. Prepoznavanje lica bi se kombinovalo sa drugom biometrijskom modalnošću, poput otiska prsta ili prepoznavanja glasa. Fuzija više biometrijskih izvora poznato je sredstvo za povećanje tačnosti i otpornosti sistema na pojedinačne izvore grešaka [10]. Alternativno ili paralelno, sistem se može proširiti dodatnim faktorom klasične autentifikacije, kao što su PIN, studentska kartica ili jednokratni kod; lice bi ostalo primarni, beskontaktni kanal, a drugi faktor pokrivaio slučajeve neuspjelog prepoznavanja i dodatno otežavao zloupotrebu. Takav dvofaktorski pristup djelimično bi ublažio i problem odsustva provjere živosti, iako bi uvođenje namjenskih metoda za otkrivanje prevare [11] ostalo poželjno. Dalji pravci obuhvataju proširenje sistema na više prostorija i uređaja, te povezivanje sa postojećim studentskim informacionim sistemima.

LITERATURA

- [1] Dargan, S., & Kumar, M. (2020). A comprehensive survey on the biometric recognition systems based on physiological and behavioral modalities. *Expert Systems with Applications*, 143, 113114. DOI: 10.1016/j.eswa.2019.113114
- [2] Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 1, 886–893. DOI: 10.1109/CVPR.2005.177
- [3] Viola, P., & Jones, M. (2001). Rapid Object Detection using a Boosted Cascade of Simple Features. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 1, I-511–I-518. DOI: 10.1109/CVPR.2001.990517
- [4] Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 23(10), 1499–1503. DOI: 10.1109/LSP.2016.2603342
- [5] Schroff, F., Kalenichenko, D., & Philbin, J. (2015). FaceNet: A Unified Embedding for Face Recognition and Clustering. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 815–823. DOI: 10.1109/CVPR.2015.7298682
- [6] King, D. E. (2009). Dlib-ml: A Machine Learning Toolkit. *Journal of Machine Learning Research*, 10, 1755–1758.
- [7] libcamera. libcamera, an open source camera stack. <https://libcamera.org>
- [8] Raspberry Pi Ltd. Camera software. https://www.raspberrypi.com/documentation/computers/camera_software
- [9] Raspberry Pi Ltd. The Picamera2 Library. <https://github.com/raspberrypi/picamera2>
- [10] Ross, A., & Jain, A. (2003). Information fusion in biometrics. *Pattern Recognition Letters*, 24(13), 2115–2125. DOI: 10.1016/S0167-8655(03)00079-5
- [11] Galbally, J., Marcel, S., & Fierrez, J. (2014). Biometric Antispoofing Methods: A Survey in Face Recognition. *IEEE Access*, 2, 1530–1552. DOI: 10.1109/ACCESS.2014.2381273



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



AUTOMATSKO TESTIRANJE I CI/CD PIPELINE U KONSTRUISANJU SOFTVERA – UTICAJ NA PRODUKTIVNOST I KVALITET

Anastasija Vasilic, Drazen Marinkovic

Fakultet informacionih tehnologija, Panevropski univerzitet Apeiron, Banja Luka, anastasija.d.vasilic@apeiron-edu.eu;
drazen.m.marinkovic@apeiron-edu.eu

Apstrakt: Automatsko testiranje i CI/CD (Continuous Integration/Continuous Delivery) pipeline predstavljaju danas standardnu praksu u konstruisanju softvera, s ciljem ranog otkrivanja grešaka i ubrzanja isporuke. Rad polazi od teorijskih osnova automatskog testiranja (piramida testiranja, razvoj vođen testovima) i arhitekture CI/CD pipeline-a, nakon čega slijedi komparativna analiza dva najzastupljenija alata: GitHub Actions i Jenkins, sa aspekta jednostavnosti primjene, fleksibilnosti i troškova. Uticaj na produktivnost i kvalitet razmatran je kroz relevantne metrike iz literature, dok praktični primjer prati pokrivenost testovima, vrijeme izvršavanja CI pipeline-a i rano otkrivene konfiguracione/integracione greške. Teorijska razmatranja potkrijepljena su praktičnim primjerom implementacije GitHub Actions pipeline-a na demonstracionom projektu, čiji rezultati (100% pokrivenost testovima, vrijeme izvršavanja pipeline-a od 20 sekundi i automatsko otkrivanje dvije greške u ranoj fazi) pokazuju mehanizme kojima ove prakse mogu doprinijeti produktivnosti i kvalitetu, dok se njihov stvarni uticaj u širem smislu zasniva na nalazima iz literature. Rad zaključuje da automatsko testiranje i CI/CD nisu univerzalno rješenje, ali značajno smanjuju kategoriju problema koji su skupi kada se zanemare: spore povratne informacije, nedosljedne isporuke i kasno otkrivanje grešaka.

Ključne riječi: automatsko testiranje, CI/CD pipeline, GitHub Actions, kvalitet softvera

AUTOMATED TESTING AND CI/CD PIPELINE IN SOFTWARE CONSTRUCTION – IMPACT ON PRODUCTIVITY AND QUALITY

Abstract: Automated testing and CI/CD (Continuous Integration/Continuous Delivery) pipelines are now standard practice in software construction, aimed at early defect detection and faster delivery. The paper starts from the theoretical foundations of automated testing (the testing pyramid, test-driven development) and CI/CD pipeline architecture, followed by a comparative analysis of the two most widely used tools: GitHub Actions and Jenkins, in terms of ease of use, flexibility and cost. The impact on productivity and quality is discussed through relevant metrics from the literature, while the practical example tracks test coverage, CI pipeline execution time, and early-detected configuration/integration errors. The theoretical considerations are illustrated with a practical example of a GitHub Actions pipeline implementation on a demonstration project, whose results (100% test coverage, a 20-second pipeline execution time, and automatic detection of two errors at an early stage) demonstrate mechanisms through which these practices can contribute to productivity and quality, while their broader real-world impact is grounded in findings from the literature. The paper concludes that automated testing and CI/CD are not a universal solution, but significantly reduce a category of problems that are costly when neglected, slow feedback loops, inconsistent deliveries and late error detection.

Keywords: automated testing, CI/CD pipeline, GitHub Actions, software quality

1. UVOD

Softverska industrija danas funkcionise pod stalnim pritiskom, timovi isporučuju promjene brže nego ikad, a tolerancija prema greškama u produkciji sve je manja. Automatsko testiranje i prakse kontinualne integracije i isporuke, poznate pod akronimom CI/CD, nastale su upravo kao odgovor na ovaj izazov i danas predstavljaju jedan od temelja savremenog softverskog inženjerstva. Kada se promjene koda automatski testiraju i isporučuju kroz definisani pipeline, programeri troše manje vremena na ručnu provjeru ispravnosti koda, a više na razvoj novih funkcionalnosti, greške se otkrivaju ranije, a ciklusi povratne informacije postaju kraći. U savremenim distribuiranim sistemima sastavljenim od desetina ili stotina mikroservisa koji se razvijaju paralelno, CI/CD pipeline nije luksuz, on je preduslov za koordinaciju timova i funkcionisanje sistema u cjelini.

Motivacija za ovaj rad proizlazi iz jaza koji i dalje postoji između organizacija koje su u potpunosti usvojile CI/CD prakse i onih koje tek počinju s implementacijom. DORA istraživanje (DevOps Research and Assessment) [1] godinama prati ovaj raskorak i pokazuje da tzv. elitne organizacije, one s visokim stepenom automatizacije pipeline-a, isporučuju softver višestruko češće i uz znatno nižu stopu neuspješnih promjena. Izbor alata analiziranih u radu, GitHub Actions i Jenkins nije slučajna: radi se o dva rješenja koja dominiraju na tržištu, ali dolaze iz fundamentalno različitih paradigmi (cloud-nativno rješenje tijesno integrisano s platformom za upravljanje kodom, naspram open-source rješenja s dugom istorijom i izuzetnom fleksibilnošću), pa njihova komparativna analiza daje širu sliku o tome kako se isti cilj postiže različitim sredstvima.

Rad ima tri cilja: (1) izgraditi jasnu teorijsku osnovu automatskog testiranja i arhitekture CI/CD pipeline-a, (2) uporediti GitHub Actions i Jenkins sa aspekta primjene, fleksibilnosti i troškova, i (3) analizirati uticaj ovih praksi na produktivnost i kvalitet kroz metrike pokrivenosti testovima, vremena izvršavanja CI pipeline-a i grešaka otkrivenih u ranoj fazi procesa, ilustriran praktičnim primjerom implementacije. U skladu s tim, rad odgovara na sljedeća istraživačka pitanja: na koji način automatsko testiranje i CI/CD pipeline utiču na produktivnost razvojnog tima; koji su mjerljivi indikatori poboljšanja kvaliteta softvera; i koje su ključne razlike između GitHub Actions-a i Jenkins-a?


2. TEORIJSKE OSNOVE AUTOMATSKOG TESTIRANJA I CI/CD PIPELINE-A

Automatsko testiranje podrazumijeva korišćenje programskog koda za verifikaciju ponašanja drugog programskog koda. Za razliku od manualnog testiranja, automatizovani test se jednom napiše i zatim izvršava na zahtjev ili automatski, kao dio pipeline-a, što fundamentalno mijenja način na koji tim percipira sigurnost pri uvođenju promjena [2]. Osim otkrivanja grešaka, ključna funkcija automatskih testova je prevencija regresija i ekonomska isplativost. Cijena ispravljanja greške raste između pet i dvadeset puta za svaku fazu razvojnog ciklusa u kojoj ostane neotkrivena [3].

Distribucija testova prema nivou apstrakcije opisuje se modelom piramide testiranja koji je popularizovao Mike Cohn [4]. Na dnu piramide nalaze se jedinični testovi: najbrojniji, najbrži i najjeftiniji, provjeravaju jednu izolovanu jedinicu koda uz izolaciju spoljnih zavisnosti pomoću mock objekata. Srednji sloj čine integracioni testovi, koji provjeravaju interakciju više komponenti (npr. komunikaciju servisa s bazom podataka). Na vrhu su end-to-end (E2E) testovi, koji simuliraju stvarno korisničko iskustvo, ali su najsporiji i najosjetljiviji na promjene sistema. Zdrava distribucija podrazumijeva mnogo jediničnih testova, umjeren broj

integracionih i svega nekoliko E2E testova za najkritičnije korisničke tokove, čime se direktno utiče na brzinu i stabilnost CI/CD pipeline-a.

Kontinualna integracija (CI) je praksa u kojoj programeri često, idealno više puta dnevno, integrišu promjene u zajednički repozitorijum, pri čemu svaka integracija automatski pokreće izgradnju i testiranje sistema [5]. Kontinualna isporuka (CD) znači da je softver u svakom trenutku spreman za produkciju, dok kontinualno postavljanje ide korak dalje i automatski isporučuje svaku promjenu koja prođe sve provjere, bez ljudskog odobrenja. Tipičan pipeline sastoji se od faza izgradnje, testiranja, analize koda i isporuke, pri čemu neuspjeh u bilo kojoj fazi zaustavlja dalji tok (**Ilustracija 1**). Pipeline se aktivira okidačima (push, pull request, schedule) i izvršava uvijek istim redoslijedom, čime eliminiše nedosljednost svojstvenu ručnim procesima.



Ilustracija 1 Arhitektura CI/CD pipeline-a – faze izgradnje, testiranja, analize koda i isporuke

Metodologija razvoja vođenog testovima (Test-Driven Development, TDD) dodatno pojačava ove efekte: testovi se pišu prije implementacije kroz ciklus Crveno-Zeleno-Refaktoriši, čime se prirodno postiže visoka pokrivenost testovima i testabilan dizajn koda **Invalid source specified..** Efikasnost cijelog sistema zavisi i od načina organizovanja grana koda, pri čemu su strategije sa čestom integracijom (npr. trunk-based development) u znatno boljoj harmoniji s CI/CD principima od strategija sa dugovječnim granama, poput GitFlow-a **Invalid source specified..**

3. ALATI: GITHUB ACTIONS I JENKINS

Teorijski okvir CI/CD pipeline-a ostaje apstraktan bez konkretnih alata kojima se realizuje. GitHub Actions i Jenkins zauzimaju posebno mjesto na tržištu, ne samo zbog raširenosti nego i zato što reprezentuju dvije fundamentalno različite filozofije automatizacije. Jednu koja polazi od platforme, drugu koja polazi od fleksibilnosti.

GitHub Actions je uveden 2019. godine kao integralni dio GitHub platforme, s ciljem da programerima omogući automatizaciju direktno tamo gdje već čuvaju kod **Invalid source specified..** Svaki workflow definiše se YAML datotekom koja živi, verzionira se i recenzira uz kod, a ekosistem GitHub Marketplace nudi hiljade gotovih akcija. Najveća prednost je niska barijera za ulazak. Tim koji već koristi GitHub može imati funkcionalan pipeline u roku od sat vremena, bez ikakve dodatne infrastrukture. Glavno ograničenje je zavisnost od same GitHub platforme.

Jenkins ima znatno dužu istoriju, nastao je 2011. godine kao fork projekta Hudson iz 2004. godine, i danas ostaje referentno rješenje za organizacije kojima je potpuna kontrola nad infrastrukturom prioritet **Invalid source specified..** Kao self-hosted rješenje, zahtijeva da organizacija sama instalira i održava server, što donosi punu kontrolu, ali i punu odgovornost za

funkcionisanje. Savremeni Jenkins koristi Pipeline-as-Code pristup kroz Jenkinsfile, sa deklarativnom sintaksom koja nudi veću ekspresivnost od GitHub Actions YAML-a, posebno u pogledu uslovnog izvršavanja faza i post-akcija, zahvaljujući Groovy osnovi.

Tabela 1 sumira ključne dimenzije poređenja. Pitanje koji je alat bolji nije produktivno postaviti, produktivnije je pitati koji je alat bolji za određeni kontekst. Tim na GitHubu bez potrebe za internom infrastrukturom prirodno bira GitHub Actions, dok organizacija sa strogim regulatornim zahtjevima (npr. finansijski sektor) koja ne smije slati kod na eksterne servere poseguće za Jenkinsom. U praksi, mnoge organizacije ne biraju između jednog i drugog, već koriste oba alata u različitim ulogama: GitHub Actions za CI dio procesa, Jenkins za složenije pipeline-ove isporuke koji zahtijevaju specifičnu infrastrukturu.

Tabela 1 Komparativna analiza GitHub Actions i Jenkins

Kriterijum	GitHub Actions	Jenkins
Infrastruktura	Cloud, upravljana od strane GitHuba	Self-hosted, vlastita odgovornost
Konfiguracija	YAML, u repozitorijumu	Jenkinsfile (Groovy), u repozitorijumu
Barijera za ulazak	Niska, spreman za ~1h	Visoka, zahtijeva infrastrukturu
Kontrola okruženja	Ograničena	Potpuna
Ekosistem	GitHub Marketplace akcije	Preko 1800 pluginova
Cijena	Besplatno za javne repozitorijume	Besplatan alat, operativni troškovi
Skalabilnost	Automatska (cloud)	Ručna (dodavanje agenata)

4. METRIKE I ANALIZA UTICAJA NA PRODUKTIVNOST I KVALITET

Tvrdnja da CI/CD poboljšava kvalitet softvera zvuči uvjerljivo, ali bez precizno definisanih metrika ostaje tek tvrdnja. Tri metrike se najčešće koriste za prelazak od utisaka ka dokazima. Pokrivenost testovima (Test Coverage) izražava procenat izvornog koda koji se izvrši tokom testiranja, najčešće kao linijska pokrivenost. Prag od 80% se u literaturi navodi kao praktični cilj **Invalid source specified.**, ali visoka pokrivenost ne garantuje kvalitet testova, to je neophodan, ali ne i dovoljan uslov. Vrijeme isporuke (Deployment Time) mjeri ukupno vrijeme od slanja promjene do njene dostupnosti u ciljnom okruženju i predstavlja jedan od četiri ključna DORA indikatora performansi isporuke softvera, pri čemu elite organizacije postižu vrijeme mjereno u minutama **Invalid source specified.** Gustoća defekata (Defect Density) normalizuje broj pronađenih grešaka u odnosu na veličinu softvera (po hiljadu linija koda, KLOC), omogućavajući poređenje kvaliteta između projekata različitih dimenzija. Tri metrike nisu nezavisne, tek zajedno daju smislenu sliku, jer visoka pokrivenost bez kratkog deployment time-a znači dobre testove koji se rijetko izvršavaju automatski.

Uticaj CI/CD-a na produktivnost ostvaruje se prvenstveno kroz eliminaciju ručnog rada i skraćivanje povratne petlje. Greška otkrivena nekoliko minuta nakon nastanka lakše se ispravlja od one otkrivene danima kasnije, dok je kontekst već zaboravljen **Invalid source specified.** Forsgren, Humble i Kim **Invalid source specified.** dokumentuju da organizacije s visokim stepenom

automatizacije isporučuju softver 208 puta češće, uz 106 puta kraći lead time od organizacija s niskim stepenom automatizacije. Uticaj na kvalitet proizlazi iz ranog otkrivanja grešaka: cijena ispravljanja raste eksponencijalno s vremenom proteklom od nastanka do otkrivanja greške **Invalid source specified.**, a konzistentnost automatizovanog procesa isporuke smanjuje kategoriju grešaka nastalih zbog razlika između okruženja ili propuštenih ručnih koraka.

Za potrebe empirijske provjere razvijena je manja Python aplikacija (biblioteka za osnovne matematičke operacije, ukupno 29 linija izvornog koda) sa pratećim skupom jediničnih testova od 41 testa. Odabir namjerno jednostavnog projekta omogućio je izolaciju i precizno mjerenje pokrivenosti i vremena izvršavanja pipeline-a bez uticaja spoljnih zavisnosti karakterističnih za veće sisteme. Pipeline nije uključivao stvarno postavljanje aplikacije u ciljno okruženje, pa se izmjereno vrijeme u nastavku naziva vrijeme izvršavanja CI pipeline-a (CI pipeline execution time), a ne deployment time u smislu DORA metrike **Invalid source specified.**

Praktičnim primjerom implementacije GitHub Actions pipeline-a ilustrovani su mehanizmi opisani u prethodnim poglavljima: primjer ne predstavlja mjerenje stvarnog uticaja na produktivnost tima, jer ne obuhvata poređenje rada prije i poslije uvođenja CI/CD-a. Pipeline je uključivao fazu izgradnje, izvršavanje 41 jediničnog testa uz mjerenje pokrivenosti (pytest-cov) i čuvanje artefakata. Istorija pokretanja pipeline-a pokazuje neposredan primjer mehanizma ranog otkrivanja grešaka: prva dva pokretanja su automatski zaustavljena zbog konfiguracione/integracione greške u pipeline-u (ModuleNotFoundError, odnosno greška importa modula), za 14, odnosno 16 sekundi, nakon čega su ispravke rezultirale uspješnim izvršavanjem svih testova. Ove dvije greške su konfiguracione/integracione prirode, a ne klasični softverski defekti u logici aplikacije, pa se ne uklapaju u standardnu definiciju gustoće defekata iz literature, u **Tabela 2** su stoga prikazane opisno, a ne kao KLOC-normalizovana metrika. **Tabela 2** sumira rezultate demonstracionog primjera.

Tabela 2 Rezultati praktičnog (demonstracionog) primjera implementacije pipeline-a

Metrika	Rezultat	Napomena
Pokrivenost testovima	100% (29/29 linija)	Mali demonstracioni projekat/ilustrativna vrijednost, ne generalizuje se na veće sisteme
Vrijeme izvršavanja pipeline-a (CI execution time)	20 sekundi	Ne uključuje stvarni deployment u ciljno okruženje; nije direktno uporedivo sa DORA deployment time metrikom Invalid source specified.
Automatski otkrivene greške u pipeline-u	2 (ModuleNotFoundError, greška importa), otkrivene za 14-16 s	Konfiguracione/integracione greške pipeline-a, ne klasični softverski defekti; ilustruju mehanizam ranog otkrivanja
Ukupno testova	41/41 prošlo	–

Ograničenje ovog primjera je njegov manji obim i demonstracioni karakter: realni projekti imaju složenije zavisnosti i duže testne suite-ove koji mogu značajno produžiti vrijeme izvršavanja pipeline-a. Odsustvo klasičnih softverskih defekata u ovom projektu ne predstavlja dokaz povećanog kvaliteta, već je posljedica malog obima i jednostavnosti koda. Iz istog razloga, rezultati primjera ne dozvoljavaju direktan zaključak o uticaju na produktivnost tima, taj zaključak u radu prvenstveno se oslanja na nalaze iz literature **Invalid source specified.**, **Invalid source specified.**

5. ZAKLJUČAK

Ovaj rad istražio je vezu između automatskog testiranja i CI/CD pipeline-a s jedne strane, i produktivnosti i kvaliteta softvera s druge, nastojeći da temi pristupi objektivno, da pokaže šta ove prakse stvarno donose, ali i da bude pošten prema njihovim ograničenjima. Teorijska analiza pokazala je da automatsko testiranje i CI/CD nisu prolazni tehnološki trend, već odgovor na fundamentalan problem softverskog inženjerstva: kako osigurati da sistem koji se kontinuirano mijenja ostaje ispravan i isporučiv. Komparativna analiza GitHub Actions i Jenkins pokazala je da ne postoji univerzalno superiorno rješenje. Svaki alat ima jasno definisan kontekst u kojem donosi najveću vrijednost, a zrele organizacije često koriste oba u komplementarnim ulogama.

Odgovarajući direktno na postavljena istraživačka pitanja: automatsko testiranje i CI/CD pipeline utiču na produktivnost prvenstveno kroz eliminaciju ručnog rada i skraćivanje povratne petlje, što empirijski potvrđuju podaci o 208 puta učestalijoj isporuci u visoko automatizovanim organizacijama **Invalid source specified..** Mjerljivi indikatori poboljšanja kvaliteta su pokrivenost testovima, vrijeme izvršavanja CI pipeline-a i broj grešaka otkrivenih u ranoj fazi procesa, koje zajedno čine sistem pokazatelja, a ne izolovane brojke.

Praktični primjer implementacije ilustrovao je mehanizme opisane u teoriji, a ne direktno mjerenje uticaja na produktivnost: pokrivenost testovima od 100% i vrijeme izvršavanja CI pipeline-a od 20 sekundi, uz istoriju pipeline-a koja pokazuje automatsko zaustavljanje pri konfiguracionim/integracionim greškama za manje od 20 sekundi, pokazuju kako rana povratna informacija funkcioniše u praksi. Stvarni uticaj ovih praksi na produktivnost i kvalitet u širem smislu prvenstveno se zaključuje na osnovu nalaza iz literature **Invalid source specified., Invalid source specified..** Na osnovu analiziranih podataka, uvođenje CI/CD-a treba biti postepeno: prvo automatizacija testiranja i izgradnje, a zatim faze isporuke, uz uvođenje metrika od prvog dana, jer podaci prikupljeni od samog početka omogućavaju praćenje trenda i opravdavanje investicije. Automatsko testiranje i CI/CD pipeline ne mogu nadomjestiti neadekvatan dizajn sistema ili nedovoljno domensko znanje, ali uklanjaju kategoriju problema koji nisu inherentno teški, a iznimno su skupi kada se ignorišu: spore povratne petlje, nedosljedni procesi isporuke i kasno otkrivanje grešaka.

LITERATURA

- [1] N. Forsgren, J. Humble and G. Kim, "State of DevOps Report 2023," Google Cloud, Mountain View, CA, 2023.
- [2] G. J. Myers, C. Sandler and T. Badgett, The Art of Software Testing, Hoboken: John Wiley & Sons, 2011.
- [3] B. Boehm and V. R. Basili, "Software Defect Reduction Top 10 List," IEEE Computer, vol. 34, no. 1, p. 135–137, 2001.
- [4] M. Cohn, Succeeding with Agile: Software Development Using Scrum, Upper Saddle River: Addison-Wesley Professional, 2009.
- [5] M. Fowler, "Continuous Integration," 2006. [Online]. Available: <https://martinfowler.com/articles/continuousIntegration.html>. [Accessed 10 April 2026].
- [6] K. Beck, Test-Driven Development: By Example, Boston: Addison-Wesley Professional, 2002.
- [7] N. Forsgren, J. Humble and G. Kim, Accelerate: The Science of Lean Software and DevOps, Portland: IT Revolution Press, 2018.
- [8] GitHub, "GitHub Actions Documentation," 2024. [Online]. Available: <https://docs.github.com/en/actions>. [Accessed 10 April 2026].
- [9] Jenkins Project, "Jenkins User Documentation," 2024. [Online]. Available: <https://www.jenkins.io/doc/>. [Accessed 10 April 2026].



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITEO 2026

Banja Luka, 25 - 26. 9. 2026. godine



PLATFORM INŽENJERING U ENTERPRISE KOMPAIJAMA: STUDIJA SLUČAJA IAC AUTOMATIZACIJE

Mišo Stamenić, Dražen Marinković, Zoran Ž. Avramović,
Panevropski Univerzitet Apeiron, Banja Luka

Sažetak: Ovaj rad predstavlja studiju slučaja implementacije platform inženjeringa u enterprise kontekstu, zasnovane na korišćenju Terragrunt-a, Cookiecutter-a i LocalStack-a za automatizaciju infrastrukture. Implementacija adresira dvije ključne bolne tačke uobičajene u enterprise okruženjima: nekonzistentno podešavanje infrastrukturnih projekata i prekomjeran ručni napor. Rezultati pokazuju da je vrijeme inicijalizacije projekta smanjeno, a konzistentnost garantovana šablonom umjesto da zavisi od discipline inženjera. Rad demonstrira da se principi platform inženjeringa mogu realizovati odgovarajućim alatima, donoseći mjerljive dobitke u produktivnosti i čineći replikabilan model za enterprise infrastrukturne timove.

Ključne riječi: Platform Inženjering, IaC, DevOps, SRE

PLATFORM ENGINEERING IN ENTERPRISE COMPANIES: CASE STUDY OF IAC AUTOMATIZATION

Abstract: The paper presents a case study of a platform engineering implementation in an enterprise context, grounded in the use of Terragrunt, Cookiecutter, and LocalStack for infrastructure automation. The implementation addresses two key pain points common in enterprise environments: inconsistent infrastructure project setup and excessive manual effort. Results show that project initialization time was reduced, with consistency guaranteed by the template rather than dependent on individual discipline. The paper demonstrates that platform engineering principles can be realized delivering measurable productivity gains and forming a replicable model for enterprise infrastructure teams.

Key words: Platform Engineering, IaC, DevOps, SRE

1. UVOD

U posljednjih petnaest godina softverska industrija prošla je kroz radikalnu transformaciju. Aplikacije su migrirale iz monolitnih data centara u cloud okruženja, timovi su prešli na agilne metodologije i DevOps prakse, a brzina isporuke softvera postala je jedan od ključnih konkurentskih faktora. Sve ovo donijelo je ogromnu vrijednost, ali i novi, manje očigledan problem: kako da stotine razvojnih timova u jednoj velikoj kompaniji efikasno upravljaju infrastrukturom?

U enterprise okruženju, tipičan scenario izgleda ovako: svaki razvojni tim ima vlastitu konfiguraciju Kubernetes klastera, vlastite CI/CD pipeline-ove, vlastite Terraform skripte i vlastite konvencije za deploy. Na papiru, timovi imaju slobodu. U praksi, dolazi do fragmentacije: nema standardnih obrazaca, znanje je izolovano po timovima, isti problemi se rješavaju iznova i iznova, a bezbjednosne i regulatorne zahtjeve niko ne primjenjuje

konzistentno. Novi inženjeri troše sedmice da razumiju infrastrukturu, senior inženjeri gube vrijeme na ručne operacije umjesto na kreiranje vrijednosti, a organizacija kao cjelina postaje sporija i skuplja nego što bi trebalo da bude.

Platform inženjering nastaje kao odgovor na ovaj problem. Umjesto da svaki tim gradi vlastite infrastrukturne kapacitete, specijalizovani tim, Platform tim, gradi zajedničku, standardizovanu platformu kojom se svi razvojni timovi mogu služiti. Cilj je, paradoksalno, postići veću slobodu za razvojne timove time što im se daju bolji alati, a ne više odgovornosti za infrastrukturu.

Ovaj rad predstavlja studiju slučaja konkretne implementacije platform inženjeringa: Terragrunt boilerplate sistema sa Cookiecutter templateing-om, u kombinaciji sa LocalStack-om za lokalnu AWS simulaciju. Studija slučaja se koristi za utemeljennje šire teorijske rasprave o principima platform inženjeringa u mjerljivim, stvarnim rezultatima.

2. METODOLOGIJA

Platform inženjering je inženjerska disciplina koja se bavi dizajnom, izgradnjom i održavanjem internih razvojnih platformi, to jest skupova alata, servisa i automatizovanih procesa koji razvojnim timovima omogućavaju da brže i sigurnije isporučuju softver.

Gartner je svrstao platform inženjering kao jednu od vodećih pet strateških trendova u razvoju softvera. 2024. godine je predvidio da će do 2026. 80% velikih softverskih organizacija uspostaviti platform inženjering timove što predstavlja drastičanu promijenu u odnosu na 45% posto kompanije iz 2022. godine [1].

Jedan od najvažnijih konceptualnih pomaka u platform inženjeringu je ideja da se platforma treba graditi i upravljati kao softverski proizvod, a ne kao interna infrastruktura. Kada se nešto tretira kao infrastruktura, fokus je na tehničkoj ispravnosti i dostupnosti. Kada se tretira kao proizvod, fokus je na korisnicima, njihovim potrebama, iskustvu i zadovoljstvu.

Golden Path, predstavlja preporučeni, standardizovani način za obavljanje određenog zadatka (pokretanje nove mikroservise, podizanje okruženja, konfigurisanje CI/CD pipeline-a) koji je unaprijed isprobjan, podržan i dokumentovan. Ono što Golden Path čini elegantnim je odsustvo prisile. Razvojni timovi nisu obavezni da ga koriste, slobodni su da biraju vlastite pristupe. Međutim, Golden Path je toliko dobro dizajniran i podržan da za većinu slučajeva predstavlja put manjeg otpora. Timovi koji ga slijede dobijaju automatsku podršku, integracije i alate. Timovi koji skrenu s njega preuzimaju odgovornost za vlastitu infrastrukturnu kompleksnost.

Platform inženjering se oslanja na bogat ekosistem alata koji pokrivaju različite aspekte internih razvojnih platformi.

Terraform je deklarativni alat koji omogućava opis cloud infrastrukture pomoću koda kroz verzionisane konfiguracione fajlove [2]. Terragrunt nadograđuje Terraform uvodeći DRY principe i upravljanje višestrukim okruženjima [3]. OpenTofu, fork otvorenog koda Terraform-a nastao 2023. godine, sve više dobija na popularnosti [4]. Pulumi predstavlja alternativu koja infrastrukturu definiše koristeći opšte-namjenske programske jezike (Python, TypeScript, Go).

Kubernetes je alat otvorenog koda koji se koristi za orkestrisanje kontejnera u enterprise okruženjima. Platforma tipično apstrahuje Kubernetes sposobnosti kroz jednostavniji interfejs. Helm standardizuje pakovanje i deploy Kubernetes aplikacija, a upravljani servisi kao što su Amazon EKS, Google GKE i Azure AKS smanjuju operativni teret upravljanja control plane-om.

Cookiecutter je popularan alat za generisanje projekata iz šablona, posebno korišćen u IaC kontekstu. Scaffolding funkcionalnosti u Backstage-u omogućavaju kreiranje novih servisa direktno kroz developer portal, uz automatsku primjenu organizacionih standarda.

Platform inženjering i Infrastructure as Code (IaC) nisu sinonimi, ali su duboko isprepleteni. IaC je jedan od ključnih principa i alata koje platform timovi koriste za izgradnju i upravljanje platformom.

Terraform i Terragrunt predstavljaju infrastrukturni sloj na kome se gradi platforma. Platform tim koristi IaC da standardizuje provisioning infrastrukture. Umjesto ručnog klikanja kroz AWS konzolu ili pisanja ad-hoc skripti, infrastruktura se definiše kao kod koji se može verzionisati, testirati i ponovo koristiti. Terragrunt je posebno relevantan u enterprise kontekstu gdje platforma mora da podrži desetine ili stotine okruženja sa konzistentnom konfiguracijom.

Alati za generisanje boilerplate koda, kao što je Cookiecutter, direktno doprinose self-service sposobnostima platforme. Kada razvojni tim želi da podigne novu mikroservisnu infrastrukturu, može koristiti unaprijed definisan šablon koji generiše konzistentnu, već validovanu strukturu projekta. To praktičan primjer Golden Path koncepta u akciji.

Platforma mora da pruži razvojnim timovima okruženja pogodna za razvoj i testiranje bez finansijskog tereta produkcione infrastrukture. Alati kao što je LocalStack, koji simulira AWS servise lokalno, direktno se uklapaju u ovaj koncept. Oni smanjuju troškove, ubrzavaju iteracije i omogućavaju bezbjedno eksperimentisanje bez rizika od neželjenih promjena na produkciji.

I platform inženjering i IaC dijele isti fundamentalni princip: infrastruktura treba da se tretira kao softverski proizvod, a ne kao ručna operacija. Oba pristupa zahtijevaju version control, testiranje, dokumentaciju i iterativni razvoj. Ova filozofska kongruencija nije slučajna, platform inženjering nastao je iz zajednice koja je već prihvatila IaC principe i primijenila ih na širi problem organizacije razvojnih timova.

3. REZULTATI

Studija slučaja sprovedena je u kontekstu infrastrukturnog tima koji upravlja višestrukim AWS okruženjima kroz nekoliko projekata. Svaki novi projekat zahtijevao je ručno podešavanje Terraform/Terragrunt konfiguracionih fajlova, provider blokova, backend konfiguracije i definicija varijabli. Ovaj proces bio je repetitivan, podložan greškama i trajao je između 30 i 60 minuta po projektu pri čemu je konzistentnost zavisila isključivo od discipline pojedinih inženjera, a ne od nametnutih standarda.

Tim je identifikovao dvije ključne bolne tačke:

1. Nekonzistentnost: različiti projekti imali su različite strukture direktorijuma, konvencije imenovanja i obrasce konfiguracije, što je otežavalo inženjerima prelazak između projekata
2. Vremenski trošak: ručni proces podešavanja bio je direktan porez na produktivnost bez poslovne vrijednosti, koji se ponavljao za svaki novi projekat ili okruženje

Da bi se adresirala ova dva problema, razvijen je Terragrunt boilerplate šablon koristeći Cookiecutter kao alat izabrani alat komandne linije koji generiše strukture projekata iz šablona. Rješenje se sastoji od:

- Cookiecutter šablona koji definiše stan dardnu strukturu projekta, sa parametrizovanim ulazima za naziv projekta, AWS region, okruženje i ostale varijable
- Pre-generation hook-a koji automatski validira ulazne parametre prije kreiranja projekta, hvatajući greške prije nego što se prošire
- Terragrunt konfiguracionog sloj-a koji implementira DRY principe, dijeljeni provider i backend konfiguracija definisani jednom i naslijeđeni kroz sva okruženja
- LocalStack integracija za lokalnu simulaciju AWS servisa, omogućavajući razvoj i testiranje bez nastajanja cloud troškova ili rizikovanja produkcijskih okruženja

Šablon enkodira Golden Path tima za nove infrastrukturne projekte: preporučenu, unaprijed isprobanu strukturu koja po defaultu zadovoljava organizacione standarde.

Implementacija je evaluirana u poređenju sa ručnim procesom podešavanja kroz sljedeće dimenzije:

Tabela 1. Poređenje ručnog podešavanja projekta i korišćenja Cookiecutter šablona

Aspekt	Ručno podešavanje	Cookiecutter šablon
Vrijeme inicijalizacije projekta	30 – 60 minuta	1 – 2 minute
Konzistentnost između projekata	Zavisí od discipline	Garantovano šablonom
Validacija ulaznih parametara	Ručna	Automatska
Dokumentovanje podrazumijevanih vrijednosti	Odvojen README	Ugrađeno u cookiecutter.json
Skaliranje na nove projekte	Ponavljjanje istih koraka	Jedna komanda
Verzionisanje šablona	Nije promjenjivo	Git repozitorijum šablona

Vrijeme inicijalizacije projekta smanjeno je sa 30–60 minuta na 1–2 minute. Što je još važnije, konzistentnost je postala strukturalna, a ne bihevioralna. Šablon nameće standarde bez obzira na to ko ga pokreće. LocalStack integracija skratila je petlju povratnih informacija za infrastrukturne promjene sa minuta (cloud deploy) na sekunde (lokalna simulacija), direktno omogućavajući brže iteracije. On se piše jednom i koristi beskonačno. Kako broj projekata raste, akumulirana ušteda vremena raste proporcionalno dok troškovi održavanja šablona ostaju relativno stabilni.

4. ZAKLJUČAK

Platform inženjering nije prolazni trend, to je odgovor na fundamentalne organizacione izazove koje donosi moderan, cloud-nativan razvoj softvera u enterprise kompanijama. Dok je DevOps revolucija prethodne decenije riješila problem silosne organizacije i ubrzala isporuku softvera, ostavila je za sobom novi problem: kognitivno opterećenje razvojnih timova koji moraju da budu eksperti i za domenski kod i za infrastrukturu.

Platform inženjering rješava ovaj problem gradnjom internih razvojnih platformi koje apstrahuju infrastrukturnu kompleksnost i razvojnim timovima daju samouslužni pristup standardizovanim,

preporučenim praksama. Rezultat je povećana produktivnost, skraćeno vrijeme do produkcije, konzistentna bezbjednost i poboljšano iskustvo razvojnih inženjera.

Za enterprise kompanije, benefiti su posebno izraženi: ekonomske uštede kroz eliminaciju redundantnog infrastrukturnog rada, ubrzanje digitalnih transformacija, upravljanje regulatornom usklađenošću kroz centralizovane politike i povećana sposobnost privlačenja i zadržavanja inženjerskih talenata. Kada stotine inženjera ne moraju da troše vrijeme na infrastrukturne zadatke koji su standardizovani kroz platformu, akumulirana ušteda je mjerljiva u milionima dolara godišnje.

Alati koji čine ekosistem platform inženjeringa (poput: Terraform, Terragrunt, Kubernetes, Backstage, Helm, ArgoCD, Prometheus i mnogi drugi), zreli su i dobro podržani. Međutim, tehnologija je samo dio priče. Uspješna implementacija platforme zahtijeva organizacionu posvećenost, pažljivo upravljanje promjenama i tretiranje razvojnih timova kao internih korisnika čije potrebe platforma mora da zadovolji.

Organizacije koje investiraju u platform inženjering ne grade samo infrastrukturu, one grade organizacionu sposobnost koja postaje diferentna komparativna prednost u digitalnoj ekonomiji. Platform inženjering je, u krajnjoj liniji, ulaganje u sposobnost organizacije da kreira vrijednost kroz softver. To je ulaganje koje se, sa pravim pristupom, višestruko isplati.

REFERENCE

- [1] Gartner, "Top Five Strategic Technology Trends in Software Engineering for 2024", Gartner Research, 2024. Dostupno: <https://www.gartner.com/en/newsroom/press-releases/2024-05-16-gartner-identifies-the-top-five-strategic-technology-trends-in-software-engineering-for-2024>
- [2] HashiCorp, "Terraform Documentation", HashiCorp Terraform, 2026. Dostupno: <https://developer.hashicorp.com/terraform/docs>
- [3] Gruntwork, "Terragrunt Documentation", Terragrunt by Gruntwork, 2026. Dostupno: <https://docs.terragrunt.com>
- [4] LinuxFondation, "Insights Popularity", 2026. Dostupno: <https://insights.linuxfoundation.org/project/opentf/popularity?timeRange=previous5Year&start=2021-01-01&end=2025-12-31>
- [5] Pulumi, "Compare Pulumi to other solutions", Pulumi, 2026. Dostupno: <https://www.pulumi.com/docs/iac/comparisons/>
- [6] Kubernetes, "Documentation", Kubernetes, 2026. Dostupno: <https://kubernetes.io/docs/home/>



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



PROJEKTOVANJE I RAZVOJ SISTEMA ZA UPRAVLJANJE RADIOKOMUNIKACIONOM INFRASTRUKTUROM

Daniel Menićanin, Jelena Radanović, Dražen Marinković

Panevropski Univerzitet „APEIRON“, Banja Luka, daniel.menicanin1@apeiron-edu.eu;
jelena.radanovic1@apeiron-edu.eu; drazen.m.marinkovic@apeiron-edu.eu

Apstrakt: Različiti komunikacioni protokoli i odvojeni upravljački interfejsi radioamaterske opreme otežavaju jedinstveno upravljanje stanicom i povezivanje tog procesa sa evidencijom ostvarenih radio-veza. U radu je predstavljen razvoj integrisanog softversko-hardverskog sistema HAM Radio Control, namijenjenog centralizovanom upravljanju radio-opremom i podršci operatorskom radu. Arhitektura sistema zasnovana je na servisu RadioCatBridge, koji posreduje između klijentskih aplikacija i radio-stanica povezanih putem različitih CAT protokola. Hardverski dio sistema obuhvata bežični PTT i šestokanalni antenski preklopnik integrisani u prenosivu konfiguraciju. Evidencija radio-veza realizovana je kroz Android aplikaciju Ham Logger sa lokalnom SQLite bazom podataka, čime su unos, čuvanje i obrada QSO zapisa dostupni i bez mrežne veze. Za takmičarski rad sa više operatora implementirana je centralna PostgreSQL baza na mini računaru sa Proxmox VE platformom, zajedno sa servisom za dvosmjernu sinhronizaciju više Ham Logger instanci. Time je omogućeno objedinjavanje QSO zapisa i održavanje zajedničkog takmičarskog dnevnika, dok lokalne baze omogućavaju nastavak rada i pri prekidu mrežne veze. Podaci o pozivnim znakovima povezuju se sa DXCC entitetima i istorijom prethodnih kontakata, dok se raspoloživi geografski podaci koriste za približan proračun udaljenosti i azimuta prema korespondentu. Na ovaj način objedinjeni su lokalno vođenje dnevnika, višekorisnički takmičarski rad i upravljanje radio-opremom.

Ključne riječi: Ham Logger, RadioCatBridge, SQLite, PostgreSQL

DESIGN AND DEVELOPMENT OF A SYSTEM FOR RADIO COMMUNICATION INFRASTRUCTURE MANAGEMENT

Abstract: Different communication protocols and separate control interfaces of amateur radio equipment complicate unified station management and its integration with radio-contact logging. This paper presents the development of HAM Radio Control, an integrated software-hardware system designed for centralized radio-equipment management and operator support. The system architecture is based on the RadioCatBridge service, which acts as an intermediary between client applications and radio transceivers using different CAT protocols. The hardware part includes a wireless PTT device and a six-channel antenna switch integrated into a portable configuration. Radio-contact logging is implemented through the Ham Logger Android application with a local SQLite database, enabling QSO entry, storage, and processing without continuous network connectivity. For multi-operator contest operation, a central PostgreSQL database and a bidirectional synchronization service have been implemented on a mini computer running Proxmox VE. This enables multiple Ham Logger instances to exchange QSO records and maintain a shared contest log, while local databases preserve operation during temporary network outages. Callsign data are associated with DXCC entities and previous-contact history, while available geographical data are used for approximate distance and azimuth calculations. The resulting system integrates local logging, multi-operator contest operation, and radio-equipment control.

Keywords: Ham Logger, RadioCatBridge, SQLite, PostgreSQL

1. UVOD

Radioamaterski rad podrazumijeva upotrebu različitih softverskih i hardverskih sistema za upravljanje radio-stanicama, vođenje dnevnika uspostavljenih veza i kontrolu dodatne opreme. Problem predstavlja činjenica da radio-stanice različitih proizvođača koriste različite CAT protokole, dok loggeri, antenski preklopnici i drugi upravljački uređaji često funkcionišu kroz zasebne aplikacije i komunikacione interfejse.

Poseban izazov javlja se tokom terenskog i takmičarskog rada, kada operator istovremeno upravlja radio-stanicom, izborom antene, PTT funkcijama, spotovima i evidencijom QSO veza. Kod rada sa više operatora potrebno je i zajedničko stanje dnevnika kako bi sve operatorske pozicije imale uvid u prethodno ostvarene veze.

U radu je predstavljen integrisani softversko-hardverski sistem HAM Radio Control, koji objedinjuje Android aplikaciju Ham Logger, RadioCatBridge servis i mrežno povezane ESP32 uređaje. Ham Logger omogućava lokalno i offline vođenje dnevnika, dok RadioCatBridge povezuje klijentske aplikacije sa radio-stanicama različitih CAT protokola i dodatnom opremom. Za višekorisnički takmičarski rad implementirani su centralizovana PostgreSQL baza i servis za dvosmjernu sinhronizaciju QSO zapisa između više operatorskih pozicija.

Doprinos rada ogleda se u integraciji lokalnog offline logovanja, dvosmjerne višekorisničke sinhronizacije i upravljanja heterogenom radio-opremom u jedinstvenu arhitekturu, uz očuvanje osnovnog rada pri prekidu mrežne veze ili nedostupnosti pojedinih uređaja.

2. ARHITEKTURA SISTEMA

Arhitektura HAM Radio Control sistema objedinjuje evidenciju radio-veza, upravljanje radio-stanicama i kontrolu dodatne radioamaterske opreme. Osnovne cjeline sistema čine Ham Logger aplikacija sa pripadajućim lokalnim SQLite bazama podataka, zajednički RadioCatBridge servis, radio-oprema i centralni PostgreSQL sloj za višekorisnički takmičarski rad.

Svaka operatorska pozicija koristi sopstvenu instancu Ham Logger aplikacije i lokalnu SQLite bazu realizovanu putem Room biblioteke. QSO se prvo čuva lokalno, tako da unos i obrada veza ostaju dostupni i bez mrežne konekcije. Centralna PostgreSQL baza i sinhronizacioni servis implementirani su na mini računaru sa Proxmox VE platformom. Sinhronizacioni servis razmjenjuje nove, izmijenjene i obrisane QSO zapise između lokalnih baza i zajedničkog takmičarskog dnevnika, čime operatorske pozicije raspolažu ažuriranim stanjem ostvarenih veza.


Zajednički upravljački dio sistema predstavlja RadioCatBridge (RCB), razvijen u C#/.NET okruženju. RCB preuzima komunikaciju sa radio-stanicama i pomoćnim uređajima, obrađuje razlike između CAT protokola i prema klijentskim aplikacijama izlaže objedinjeno stanje i upravljačke funkcije. Ham Logger sa RCB-om komunicira putem HTTP/JSON interfejsa.

Na fizičkom nivou sistem podržava radio-stanice Kenwood TS-590SG [1] i Yaesu FT-857D [2]. Dodatnu opremu čine bežični ESP32 PTT/footswitch i šestokanalni antenski preklopnik zasnovan na ESP32-S3 mikrokontroleru. Footswitch koristi TCP komunikaciju preko Wi-Fi mreže, antenski preklopnik HTTP/JSON, dok se UDP koristi za detekciju pomoćnih uređaja.

Važan princip arhitekture jeste razdvajanje lokalnog čuvanja QSO podataka, njihove sinhronizacije i upravljanja fizičkom radio-opremom. Prekid veze sa centralnim serverom ne

onemogućava lokalno evidentiranje veza, a nakon ponovnog uspostavljanja veze podaci se usklađuju sa zajedničkim takmičarskim dnevnikom.

Na Sl. 1 prikazana je arhitektura sistema sa dvije operatorske pozicije. Svaka pozicija koristi sopstvenu instancu Ham Logger aplikacije i lokalnu SQLite bazu, dok obje pozicije dijele zajednički RadioCatBridge servis. Centralni takmičarski sloj čine PostgreSQL baza i sinhronizacioni servis smješteni na mini računaru sa Proxmox VE platformom.



Slika 9. Arhitektura sistema HAM Radio Control sa dvije operatorske pozicije, zajedničkim RadioCatBridge servisom i centralnim takmičarskim slojem


Kombinovanjem Ham Logger aplikacije, lokalnih SQLite baza, zajedničkog RadioCatBridge servisa, centralne PostgreSQL baze i mrežno povezanih uređaja formirana je jedinstvena softversko-hardverska arhitektura. Praktična realizacija fizičkog dijela sistema prikazana je na Sl. 2.



Slika 10. Praktična realizacija HAM Radio Control sistema u terenskoj konfiguraciji

3. HAM LOGGER I BAZA PODATAKA

Ham Logger razvijen je kao Android aplikacija za evidentiranje radioamaterskih veza, sa posebnim fokusom na POTA aktivnosti i rad bez stalne internet konekcije. Primijenjen je offline-first pristup, pa unos, izmjena, pretraga, brisanje i izvoz QSO zapisa ne zavise od mreže ili radio-opreme [3]. Na taj način osnovne funkcije dnevnika ostaju dostupne i u terenskim uslovima ili pri privremenom prekidu mrežne veze. POTA spotovi, QRZ, POTA katalog i CAT podaci koriste se kao dodatni izvori informacija za brži unos i obradu podataka, dok se trajni QSO zapisi prvo čuvaju lokalno. Na Sl. 3 prikazan je interfejs Ham Logger aplikacije za unos novog QSO zapisa.




Slika 11. Unos novog QSO zapisa u Ham Logger aplikaciji

Lokalna baza realizovana je u SQLite-u putem Room biblioteke i sadrži jedanaest aplikacijskih tabela za logbookove, aktivacije, QSO zapise, programske reference, dodatna ADIF polja, POTA i DXCC podatke. Tabela qso sadrži UUID identifikator, pozivni znak, vrijeme veze, frekvenciju, band, mod, RST i prateće podatke. Frekvencija se čuva kao cjelobrojna vrijednost u hercima, a vrijeme kao Unix vrijeme u milisekundama.

QSO može pripadati tabeli operation, koja predstavlja aktivaciju ili operatorsku sesiju. Programske reference izdvojene su u tabele qso_reference i operation_reference, dok se dodatna ADIF polja čuvaju u tabeli qso_adif_extra. POTA i DXCC podaci smješteni su u zasebne kataloge, čime se izbjegava nepotrebno proširivanje osnovne QSO strukture.

Brisanje QSO-a realizovano je označavanjem zapisa poljem deleted_at, što omogućava povratak kroz Trash funkciju, dok se izmjene i brisanja prate lokalnom revizijom. Na Sl. 4 prikazan je pregled QSO zapisa sa mogućnošću pretrage, ADIF importa i eksporta te pristupa obrisanim zapisima.



Slika 12. Pregled sačuvanih QSO zapisa i funkcija logbooka

Više povezanih QSO zapisa kreira se u jednoj transakciji. Kada udaljena POTA stanica daje više parkovskih referenci, Ham Logger kreira zaseban QSO za svaki park sa istim osnovnim podacima o vezi, ali različitom POTA referencom. Zapisi se povezuju internim APP_HAMLOGGER_CONTACT_ID identifikatorom, koji se ne izvozi u ADIF.

Struktura baze proširena je kontrolisanim migracijama do verzije 9 bez brisanja postojećih podataka. Migracijama su uvedene programske reference, POTA katalog i spotovi, dodatna ADIF polja, logbookovi, DXCC i geografski podaci te podaci o operatoru i stanici.

Za rad sa više operatora implementirani su centralna PostgreSQL baza i sinhronizacioni servis na mini računaru sa Proxmox VE platformom. Servis obavlja dvosmjernu razmjenu novih, izmijenjenih i obrisanih QSO zapisa između lokalnih SQLite baza i centralnog takmičarskog dnevnika [4]. UUID identifikatori, lokalne revizije i oznake brisanja koriste se za prepoznavanje i usklađivanje promjena između više Ham Logger instanci. Time operatorske pozicije raspolažu zajedničkim stanjem dnevnika, dok lokalne baze zadržavaju mogućnost rada tokom prekida mrežne veze [5]. Struktura centralne baze podataka i veze između ključnih entiteta prikazane su na Sl. 5.

Kenwood TS-590SG koristi tekstualne CAT komande sa profilom 115200 bit/s, 8N1, dok Yaesu FT-857D koristi binarne okvire od pet bajtova na 38400 bit/s, 8N2. Zbog različitih mogućnosti uređaja RCB koristi model podržanih funkcija, tako da klijentska aplikacija koristi samo funkcije dostupne na odgovarajućoj radio-stanici.

RCB podržava dva radio slota za Kenwood TS-590SG i Yaesu FT-857D i omogućava nezavisno usmjeravanje komandi prema radio-stanici pridruženoj odgovarajućoj operatorskoj poziciji. Više Ham Logger instanci koristi zajednički RCB, pri čemu su stanje i upravljačke komande razdvojeni prema radio slotovima. Time je omogućen istovremeni višekorisnički rad bez miješanja stanja i komandi između radio-stanica.

RCB podržava i virtuelni COM interfejs za povezivanje sa postojećim loggerima, pri čemu fizički CAT port ostaje pod njegovom kontrolom, a klijent koristi drugi kraj virtuelnog serijskog para.

5. ANTENSKI PREKLOPNIK I BEŽIČNI PTT

Hardverski dio sistema čine bežični PTT/footswitch zasnovan na ESP32 mikrokontroleru i šestokanalni antenski preklopnik realizovan na ESP32-S3 platformi. Oba uređaja povezana su sa RadioCatBridge servisom.

Footswitch koristi Wi-Fi i TCP vezu sa RCB-om, [8] dok se UDP koristi za detekciju uređaja. Pritiskom i otpuštanjem tastera šalju se PTT događaji, a dodatni funkcijski taster omogućava promjenu antene za aktivni band i pokretanje automatskog tunera kada ga radio-stanica podržava.

Šestokanalni antenski preklopnik sadrži lokalni HTTP server preko kojeg RCB bira antenski izlaz i prima JSON potvrdu stanja. Relejmima se upravlja preko sklopa GPIO → ULN2803A → PNP/2N2906A high-side drajver → 12 V relejna linija.

Pri promjeni antene koristi se *break before make* princip, prethodni relej se isključuje, slijedi programirana pauza od 120 ms, a zatim se uključuje novi izlaz. Navedena vrijednost predstavlja softversko kašnjenje između komandi, a ne izmjereno RF vrijeme prebacivanja.[9]

Kod Kenwood TS-590SG antenska ruta može obuhvatati dva nivoa: CAT izbor ANT1/ANT2 priključka i kanal eksternog šestokanalnog preklopnika. RCB zato odvojeno određuje oba nivoa rute uz provjeru stanja predaje prije promjene.

6. METOD EVALUACIJE I TESTIRANJA

Evaluacija sistema sprovedena je kroz funkcionalno, integraciono i višekorisničko testiranje. Provjerene su osnovne funkcije Ham Logger aplikacije, lokalna SQLite baza, centralna PostgreSQL baza, dvosmjerna sinhronizacija QSO zapisa, komunikacija sa RadioCatBridge servisom i ponašanje sistema pri nedostupnosti mrežnih i radio servisa. Posebno je provjeravano da prekid veze sa centralnim sistemom ne onemogući lokalno evidentiranje QSO zapisa te da se podaci nakon ponovnog uspostavljanja veze mogu uskladiti sa centralnom bazom.

Funkcionalnim testovima obuhvaćeni su kreiranje, izmjena i brisanje QSO zapisa, povezivanje sa logbookovima i aktivacijama, rad sa više POTA referenci, Trash/restore funkcija, ADIF import i eksport te migracije lokalne baze od verzije 1 do 9. Integracionim testiranjem provjerena je razmjena novih, izmijenjenih i obrisanih QSO zapisa između lokalnih SQLite baza pojedinačnih Ham Logger instanci i centralne PostgreSQL baze.

Automatizovanim JVM i Android testovima obuhvaćeni su QSO zapisi, POTA, ADIF, spotovi, DXCC, mape, CAT komunikacija i Room baza. [10] U jednom testnom ciklusu izvršena su 63 JVM i 26 Android testa, dok je zaseban ciklus za rotaciju, filtere i mape obuhvatio 21 JVM i jedan Android test. Dodatne provjere izvršene su na Android tabletu i u višekorisničkoj konfiguraciji sa više Ham Logger instanci, pri čemu su provjereni zajedničko stanje takmičarskog dnevnika i odvojeno upravljanje radio-stanicama preko zajedničkog RadioCatBridge servisa.

7. REZULTATI

Evalucijom je potvrđeno da Ham Logger zadržava osnovne funkcije evidentiranja i obrade QSO zapisa i bez dostupnosti QRZ servisa, POTA kataloga, spotova, RadioCatBridge servisa ili povezane radio-stanice. Funkcionalnim testovima potvrđeni su kreiranje, izmjena i brisanje QSO zapisa, rad sa više POTA referenci, Trash/restore funkcija, ADIF import i eksport, migracije baze te lokalno čuvanje podataka.

Integracionim testiranjem potvrđena je dvosmjerna sinhronizacija QSO zapisa između lokalnih SQLite baza i centralizovane PostgreSQL baze. Više Ham Logger instanci može razmjenjivati podatke i održavati zajedničko stanje takmičarskog dnevnika, dok lokalne baze omogućavaju nastavak evidentiranja veza tokom prekida mrežne konekcije i naknadno usklađivanje podataka nakon ponovnog uspostavljanja veze.

U višekorisničkoj konfiguraciji potvrđen je rad više Ham Logger instanci preko zajedničkog RadioCatBridge servisa uz odvojeno usmjeravanje stanja i upravljačkih komandi prema pripadajućim radio-stanicama. RadioCatBridge je omogućio komunikaciju sa Kenwood TS-590SG i Yaesu FT-857D stanicama uprkos razlikama u CAT protokolima. Potvrđena je i komunikacija sa ESP32 footswitch uređajem i ESP32-S3 antenskim preklopnikom, uključujući PTT događaje, potvrdu stanja i *break before make* promjenu antenske rute.

CAT podaci i POTA spotovi mogu se koristiti za pripremu novog QSO zapisa, ali ne dovode do njegovog automatskog snimanja. Na taj način trajno sačuvani podaci ostaju odvojeni od trenutnog stanja radio-opreme i podataka dobijenih iz mrežnih servisa.

8. DISKUSIJA

Jedna od važnijih osobina sistema jeste razdvajanje trajno sačuvanih QSO podataka od trenutnog stanja radio-stanice i mrežnih servisa. Frekvencija, mod, POTA spot ili drugi podaci mogu pomoći operatoru pri unosu kontakta, ali se QSO trajno čuva tek nakon komande Save. Time se smanjuje mogućnost nastanka pogrešnog zapisa usljed promjene frekvencije, zastarjelog spota ili mrežnog događaja.

SQLite baza pogodna je za terenski i POTA rad jer se dnevnik nalazi lokalno na Android uređaju, pa unos i obrada QSO zapisa ne zavise od internet konekcije ili udaljenog servera. Relaciona organizacija baze omogućava čuvanje više programskih referenci i dodatnih ADIF podataka bez nepotrebnog proširivanja osnovne QSO tabele.

Kod takmičarskog rada sa više operatora lokalna baza jednog uređaja nije dovoljna za održavanje zajedničkog dnevnika. Implementirani centralni PostgreSQL sloj i sinhronizacioni servis omogućavaju da više Ham Logger instanci razmjenjuje QSO zapise i održava zajedničko stanje takmičarskog dnevnika. Svaka operatorska pozicija pritom zadržava sopstvenu lokalnu

SQLite bazu, čime je omogućen nastavak rada i pri privremenom prekidu veze sa centralnim serverom.

Zajednički RadioCatBridge omogućava da više operatorskih pozicija koristi različite radio-stanice kroz odvojene radio slotove, dok protokolske razlike ostaju skrivene unutar odgovarajućih CAT drajvera. Time su zajednički dnevnik i upravljanje radio-opremom povezani u jedinstven sistem, ali ostaju funkcionalno razdvojeni.

Dalja evaluacija treba da obuhvati rad sa veoma velikim logovima, veći broj istovremenih operatorskih pozicija i potpuniju hardversku provjeru svih CAT funkcija.

9. ZAKLJUČAK

U radu je predstavljen razvoj sistema HAM Radio Control, koji objedinjuje Ham Logger aplikaciju, lokalne SQLite baze podataka, centralnu PostgreSQL bazu, RadioCatBridge servis i mrežno povezanu radioamatersku opremu.

Ham Logger koristi offline-first pristup, pri čemu se QSO prvo trajno čuva lokalno, a zatim sinhronizuje sa centralnim takmičarskim dnevnikom. Pouzdanost čuvanja podataka podržana je kontrolisanim migracijama baze, lokalnim revizijama i Trash/restore funkcijom.

Za rad sa više operatora implementirani su centralna PostgreSQL baza i servis za dvosmjernu sinhronizaciju više Ham Logger instanci. Time je omogućeno objedinjavanje QSO zapisa sa više operatorskih pozicija i održavanje zajedničkog takmičarskog dnevnika, uz zadržavanje lokalnog rada tokom prekida mrežne veze.

RadioCatBridge povezuje operatorske aplikacije sa radio-stanicama različitih CAT protokola, bežičnim PTT uređajem i šestokanalnim antenskim preklopnikom. Zajednički RCB omogućava nezavisno upravljanje radio-stanicama kroz odvojene radio slotove, čime su evidencija radio-veza i upravljanje fizičkom opremom objedinjeni u jedinstven sistem.

Dalji razvoj obuhvatiće optimizaciju sistema za veći broj istovremenih operatorskih pozicija, testiranje sa veoma velikim logovima i proširenje podrške za dodatne radio-stanice i takmičarske funkcije.

LITERATURA

- [1] JVCKENWOOD Corporation, *TS-590SG Instruction Manual*, sec. 12, "Computer Control," p. 62.
- [2] Yaesu Musen Co., Ltd., *FT-857D Operating Manual*, "CAT Operation," pp. 115–118.
- [3] M. Kleppmann, A. Wiggins, P. van Hardenberg, and M. McGranaghan, "Local-first software: You own your data, in spite of the cloud," in *Proc. 2019 ACM SIGPLAN Int. Symp. New Ideas, New Paradigms, and Reflections on Programming and Software (Onward! '19)*, Athens, Greece, 2019, pp. 154–178, doi: 10.1145/3359591.3359737.
- [4] M.-Y. Choi, E.-A. Cho, D.-H. Park, C.-J. Moon, and D.-K. Baik, "A database synchronization algorithm for mobile devices," *IEEE Trans. Consumer Electron.*, vol. 56, no. 2, pp. 392–398, May 2010, doi: 10.1109/TCE.2010.5505945.
- [5] O. Koskimies, J. Wikman, T. Mikola, and A. Taivalsaari, "EDB: A multi-master database for liquid multi-device software," in *Proc. 2nd ACM Int. Conf. Mobile Software Engineering and Systems (MOBILESoft)*, Florence, Italy, 2015, pp. 125–128, doi: 10.1109/MobileSoft.2015.27.
- [6] C. D. Căleanu, V. Tiponut, I. Bogdanov, S. Ionel, and I. Lie, "C# and .NET Framework for uC communication protocol implementation," in *Proc. 11th WSEAS Int. Conf. on Computers*, Agios Nikolaos, Crete, Greece, 2007, pp. 583–586.
- [7] T. Vedavathi, R. Karthick, R. Senthamil Selvan, and P. Meenalochini, "Data Communication and Networking Concepts in User Datagram Protocol (UDP)," *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 8, no. 5, pp. 2765–2768, Jan. 2020, doi: 10.35940/ijrte.D8758.018520

- [8] W. Eddy, Ed., “Transmission Control Protocol (TCP),” RFC 9293, Internet Engineering Task Force (IETF), Aug. 2022, doi: 10.17487/RFC9293.
- [9] Toshiba Electronic Devices & Storage Corporation, “What is a break-before-make circuit?,” *Toshiba Semiconductor Knowledge Base*. [Online]. Available: Toshiba – What is a break-before-make circuit?
- [10] Android Developers, “Save data in a local database using Room,” *Android Developers*. [Online]. Available: <https://developer.android.com/training/data-storage/room>.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



MREŽNA SEGMENTACIJA I KONTROLA PRISTUPA U ZAŠTITI POSLOVNE MREŽE

Marko Majstorović

Fakultet informacionih tehnologija, Panevropski univerzitet Apeiron, Banja Luka, marko.majstorovic@apeiron-edu.eu

Sažetak: Savremene poslovne mreže povezuju veliki broj korisnika, računara, servera i drugih mrežnih uređaja, zbog čega je potrebno obezbijediti kontrolisanu komunikaciju između različitih dijelova infrastrukture. Jedan od pristupa povećanju bezbjednosti jeste mrežna segmentacija, kojom se fizička ili logička mreža dijeli na više odvojenih cjelina. U ovom radu prikazana je studija slučaja poslovne mreže podijeljene na segmente za upravu, računovodstvo, IT sektor, gostujuće korisnike i servere. Segmentacija je realizovana primjenom VLAN tehnologije, dok je kontrola komunikacije između segmenata ostvarena firewall pravilima na MikroTik RouterOS platformi. Za svaki segment definisan je zaseban adresni prostor, a komunikacija je dozvoljena samo kada je potrebna za obavljanje poslovnih funkcija. Posebna pažnja posvećena je izolaciji gostujuće mreže od internih resursa. Predloženo rješenje pokazuje kako kombinacija VLAN segmentacije i firewall pravila može doprinijeti boljoj organizaciji mreže i kontroli komunikacije između njenih segmenata.

Ključne riječi: mrežna segmentacija, VLAN, kontrola pristupa, MikroTik

NETWORK SEGMENTATION AND ACCESS CONTROL IN BUSINESS NETWORK PROTECTION

Abstract: Modern business networks connect a large number of users, computers, servers and other network devices, which is why it is necessary to provide controlled communication between different parts of the infrastructure. One approach to increasing security is network segmentation, which divides a physical or logical network into several separate units. This paper presents a case study of a business network divided into segments for administration, accounting, IT sector, guest users and servers. Segmentation is implemented using VLAN technology, while control of communication between segments is achieved by firewall rules on the MikroTik RouterOS platform. A separate address space is defined for each segment, and communication is allowed only when it is needed to perform business functions. Special attention is paid to the isolation of the guest network from internal resources. The proposed solution shows how the combination of VLAN segmentation and firewall rules can contribute to better organization of the network and control of communication between its segments.

Keywords: network segmentation, VLAN, access control, MikroTik

1. UVOD

Savremene poslovne organizacije u velikoj mjeri zavise od računarskih mreža. Mrežna infrastruktura omogućava zaposlenima pristup poslovnim aplikacijama, serverima, bazama podataka, Internetu i drugim resursima. Istovremeno, povezivanje velikog broja uređaja u jedinstvenu mrežu povećava potrebu za kontrolom komunikacije i zaštitom internih resursa.

U jednostavno projektovanoj mreži svi uređaji mogu pripadati istoj logičkoj cjelini. Takav pristup olakšava početnu konfiguraciju, ali otežava kontrolu saobraćaja između korisnika i sistema. Ako jedan uređaj bude kompromitovan, napadaču može biti omogućena komunikacija prema većem broju drugih uređaja [2]. Zbog toga se u poslovnim mrežama primjenjuju različiti oblici segmentacije.

Cilj ovog rada je prikazati praktičan model segmentacije i kontrole pristupa u poslovnoj mreži. Kao primjer je izabrana mreža organizacije sa više funkcionalnih cjelina. Mreža je podijeljena korištenjem VLAN-ova, dok se komunikacija između segmenata kontroliše firewall pravilima. Poseban cilj je pokazati da se pristup može ograničiti prema principu potrebe za komunikacijom, tako da korisnici imaju pristup resursima koji su im potrebni, ali ne i cijeloj internoj mreži.

2. MREŽNA SEGMENTACIJA I VLAN

Osnovna ideja mrežne segmentacije jeste podjela mreže na manje cjeline između kojih ne postoji podrazumijevana potpuna dostupnost. U poslovnom okruženju kriterijum za podjelu mogu biti organizaciona pripadnost korisnika, vrsta uređaja, osjetljivost podataka ili namjena servisa. Na taj način se računari računovodstva mogu izdvojiti od gostujućih uređaja, dok serverski resursi mogu biti smješteni u zaseban segment sa strožim pravilima pristupa [2].

Jedan od najčešće korištenih mehanizama za logičku segmentaciju jeste VLAN. IEEE 802.1Q definiše mehanizme za rad bridged LAN mreža i virtuelnih LAN-ova, čime se omogućava logičko razdvajanje mrežnog saobraćaja [1]. VLAN segmentacija omogućava da se više logičkih mreža realizuje preko zajedničke fizičke infrastrukture. Kada je potreban saobraćaj između VLAN-ova, on prolazi kroz uređaj koji obavlja usmjeravanje, gdje se mogu primijeniti firewall pravila.

Za potrebe studije slučaja koristi se privatni IPv4 adresni prostor iz opsega 192.168.0.0/16, rezervisan za privatne internete prema RFC 1918 [3]. Predložena adresacija omogućava jednostavno prepoznavanje segmenta na osnovu trećeg okteta IP adrese.

Tabela 1. VLAN i IP struktura poslovne mreže

VLAN ID	Segment	Mreža	Gateway
10	Uprava	192.168.10.0/24	192.168.10.1
20	Računovodstvo	192.168.20.0/24	192.168.20.1
30	IT	192.168.30.0/24	192.168.30.1
40	Gosti	192.168.40.0/24	192.168.40.1
50	Serveri	192.168.50.0/24	192.168.50.1

3. KONTROLA PRISTUPA IZMEĐU SEGMENTA


Segmentacija daje strukturu mreži, ali njena bezbjednosna vrijednost zavisi od pravila kojima se određuje komunikacija između segmenata. U najjednostavnijem modelu može se primijeniti princip najmanjih privilegija: korisniku ili uređaju omogućava se samo ona komunikacija koja je potrebna za obavljanje poslovne funkcije. CISA preporučuje snažnu mrežnu segmentaciju uz korištenje VLAN-ova, ACL mehanizama, stateful inspekcije i firewall funkcionalnosti kao dijela šireg pristupa odbrani u dubinu [4].

U predloženom modelu serverski segment predstavlja posebno osjetljivu zonu. Uprava, računovodstvo i IT sektor mogu imati opravdan razlog da pristupe određenim servisima na serverima, dok gostujući korisnici takav pristup ne trebaju imati. Gosti mogu dobiti pristup internetu, ali se njihov saobraćaj prema internim mrežama blokira.

Za MikroTik RouterOS relevantna je funkcionalnost firewall filtera. Prema službenoj dokumentaciji, firewall filter može dozvoliti ili blokirati pakete, a saobraćaj koji prolazi kroz ruter obrađuje se u FORWARD lancu [5]. To je mehanizam potreban za kontrolu komunikacije između različitih VLAN mreža kada ruter predstavlja njihovu gateway tačku.

4. STUDIJA SLUČAJA

1. Mrežna topologija



Slika 1. Mrežna topologija

Na slici je prikazana logička topologija mreže.

MikroTik router je centralni uređaj koji obezbeđuje međusobnu komunikaciju između VLAN-ova, kao i pristup Internetu.

Konfigurisani su sledeći VLAN-ovi:

- VLAN 10 – Uprava (192.168.10.0/24)
- VLAN 20 – Računovodstvo (192.168.20.0/24)
- VLAN 30 – IT (192.168.30.0/24)
- VLAN 40 – Gosti (192.168.40.0/24)
- VLAN 50 – Serveri (192.168.50.0/24)

Svi VLAN-ovi su povezani preko bridge-a (bridge-lan), pri čemu je port ether2 konfigurisan kao access port za VLAN 40 (Gosti).

2. Konfiguracija VLAN interfejsa

```
MikroTik-Router [Running] - Oracle VirtualBox
File Machine View Input Devices Help
[admin@MikroTik] > /interface vlan print
Flags: R - RUNNING
Columns: NAME, MTU, ARP, VLAN-ID, INTERFACE
# NAME MTU ARP VLAN-ID INTERFACE
0 R vlan10-uprava 1500 enabled 10 bridge-lan
1 R vlan20-racunovodstvo 1500 enabled 20 bridge-lan
2 R vlan30-it 1500 enabled 30 bridge-lan
3 R vlan40-gosti 1500 enabled 40 bridge-lan
4 R vlan50-serveri 1500 enabled 50 bridge-lan
[admin@MikroTik] >
```

Slika 2. Prikaz konfigurisanih VLAN interfejsa

Na slici je prikazan spisak VLAN interfejsa sa njihovim ID-ovima i pripadajućim bridge interfejsom. Svi VLAN-ovi su aktivni (RUNNING) i vezani za bridge-lan.

3. VLAN tabela na bridge-u

```
MikroTik-Router [Running] - Oracle VirtualBox
File Machine View Input Devices Help
[admin@MikroTik] > /interface bridge vlan print detail
Flags: D - DYNAMIC
# bridge-bridge-lan vlan-ids=10 tagged=bridge-lan untagged=""
1 bridge-bridge-lan vlan-ids=20 tagged=bridge-lan untagged=""
2 bridge-bridge-lan vlan-ids=30 tagged=bridge-lan untagged=""
3 bridge-bridge-lan vlan-ids=40 tagged=bridge-lan untagged=""
4 bridge-bridge-lan vlan-ids=50 tagged=bridge-lan untagged=""
[admin@MikroTik] >
```

Slika 3. VLAN tabela na bridge-u

Na slici je prikazana VLAN tabela bridge-a. Svi VLAN-ovi su tagovani na bridge-lan, dok je interfejs ether2 postavljen kao untagged samo za VLAN 40 (Gosti), što znači da je ether2 access port za mrežu Gosti.

4. Firewall pravila i rezultati testiranja

```
MikroTik-Router [Running] - Oracle VirtualBox
File Machine View Input Devices Help
[admin@MikroTik] > /ip firewall filter print state
Columns: CHAIN, ACTION, BYTES, PACKETS
# CHAIN ACTION BYTES PACKETS
1 IT -> Serveri
0 forward accept 240 4
1 Računovodstvo -> Serveri
1 forward accept 0 0
2 Uprava -> Serveri
1 forward accept 0 0
3 IT -> Uprava
1 forward accept 0 0
4 Gosti -> Serveri BLOCK
4 forward drop 240 4
5 Gosti -> Uprava BLOCK
5 forward drop 0 0
6 Gosti -> Računovodstvo BLOCK
6 forward drop 0 0
7 Gosti -> IT BLOCK
7 forward drop 0 0
[admin@MikroTik] >
```

Slika 4. Firewall pravila i statistika

Na slici je prikazana statistika firewall pravila nakon testiranja komunikacije između VLAN-ova. Rezultati pokazuju da:

- IT → Serveri: 4 paketa (240 B) su uspešno prošla (ACCEPT),
- Gosti → Serveri: 4 paketa (240 B) su blokirana (DROP),
- ostala pravila trenutno nemaju zabilježen saobraćaj.

Ovo potvrđuje da su firewall pravila ispravno konfigurirana i da je komunikacija između VLAN-ova ograničena u skladu sa zahtjevima.

5. Zaključak

U ovom radu je uspešno konfigurirana VLAN mreža na MikroTik routeru, implementirana segmentacija mreže i osnovna sigurnosna pravila između VLAN-ova. Testiranjem je potvrđeno da komunikacija funkcioniše prema postavljenim pravilima. Ovakvo segmentirana mreža omogućava veću sigurnost, bolju organizaciju i jednostavnije upravljanje mrežnom infrastrukturom.

Slika 1. Mrežna topologija poslovne mreže sa VLAN segmentacijom

Posmatra se hipotetička poslovna organizacija koja koristi jedan fizički mrežni sistem, ali ima više grupa korisnika i resursa. Uprava obrađuje osjetljive poslovne informacije, računovodstvo koristi aplikacije i podatke vezane za finansijsko poslovanje, IT sektor upravlja infrastrukturom,

gosti koriste mrežu bez potrebe za pristupom internim resursima, dok se poslovni serveri koriste za aplikacije i zajedničke podatke. Zbog različitih zahtjeva formira se pet VLAN segmenata iz Tabele 1.

Na ruteru se za svaki segment definiše gateway adresa. Saobraćaj između segmenata zatim se kontroliše firewall pravilima. U praktičnoj konfiguraciji definišu se potrebni tokovi saobraćaja između segmenata, dok se nedozvoljeni tokovi blokiraju odgovarajućim firewall pravilima. MikroTik dokumentacija opisuje FORWARD lanac za obradu saobraćaja koji prolazi kroz ruter, kao i ACCEPT i DROP akcije za kontrolu takvog saobraćaja [5].

Tabela 2. Očekivani pristup između mrežnih segmenata

Izvorni VLAN	Odredišni VLAN	Očekivani pristup
IT (VLAN 30)	Serveri (VLAN 50)	Dozvoljen
Računovodstvo (VLAN 20)	Serveri (VLAN 50)	Dozvoljen
Uprava (VLAN 10)	Serveri (VLAN 50)	Dozvoljen
IT (VLAN 30)	Uprava (VLAN 10)	Dozvoljen
Gosti (VLAN 40)	Uprava (VLAN 10)	Blokiran
Gosti (VLAN 40)	Serveri (VLAN 50)	Blokiran
Gosti (VLAN 40)	Računovodstvo (VLAN 20)	Blokiran
Gosti (VLAN 40)	IT (VLAN 30)	Blokiran

```

MikroTik-Router [Running] - Oracle VirtualBox
File Machine View Input Devices Help
[admin@MikroTik] / > bridge=bridge-lan vlan-ids=1 tagged="" untagged=bridge-lan
mvrp-forbidden="" current-tagged="" current-untagged=bridge-lan
[admin@MikroTik] / > /interface bridge vlan set [find vlan-ids=30] tagged=bridge-lan un
tagged=""
[admin@MikroTik] / > /interface bridge vlan print detail
Flags: D - DYNAMIC
0 bridge=bridge-lan vlan-ids=10 tagged=bridge-lan untagged=""
mvrp-forbidden="" current-tagged=bridge-lan current-untagged=""
1 bridge=bridge-lan vlan-ids=20 tagged=bridge-lan untagged=""
mvrp-forbidden="" current-tagged=bridge-lan current-untagged=""
2 bridge=bridge-lan vlan-ids=30 tagged=bridge-lan untagged=""
mvrp-forbidden="" current-tagged=bridge-lan current-untagged=""
3 bridge=bridge-lan vlan-ids=40 tagged=bridge-lan untagged=ether2
mvrp-forbidden="" current-tagged=bridge-lan current-untagged=ether2
4 bridge=bridge-lan vlan-ids=50 tagged=bridge-lan untagged=""
mvrp-forbidden="" current-tagged=bridge-lan current-untagged=""
5 D ::: added by pvid
bridge=bridge-lan vlan-ids=1 tagged="" untagged=bridge-lan
mvrp-forbidden="" current-tagged="" current-untagged=bridge-lan
[admin@MikroTik] / >

```

Slika 2. Konfiguracija VLAN segmentacije na MikroTik RouterOS platform

Primjer pravila za gostujući segment je zabrana komunikacije iz mreže 192.168.40.0/24 prema internim mrežama 192.168.10.0/24, 192.168.20.0/24, 192.168.30.0/24 i 192.168.50.0/24. Istovremeno, gostima se može dozvoliti izlaz prema internetu. Za IT segment može se dozvoliti administrativni pristup serverima, dok se nepotrební pristup drugim korisničkim segmentima blokira.

Tabela 3. Primjer firewall pravila za kontrolu pristupa između VLAN segmenata

Izvorni segment	Odredišni segment	Akcija
IT (VLAN 30)	Serveri (VLAN 50)	ACCEPT
Računovodstvo (VLAN 20)	Serveri (VLAN 50)	ACCEPT
Uprava (VLAN 10)	Serveri (VLAN 50)	ACCEPT
IT (VLAN 30)	Uprava (VLAN 10)	ACCEPT
Gosti (VLAN 40)	Serveri (VLAN 50)	DROP
Gosti (VLAN 40)	Uprava (VLAN 10)	DROP
Gosti (VLAN 40)	Računovodstvo (VLAN 20)	DROP
Gosti (VLAN 40)	IT (VLAN 30)	DROP

Jedan od primijenjenih primjera firewall pravila odnosi se na dozvoljavanje saobraćaja iz IT segmenta prema serverskom segmentu. Pravilo koristi FORWARD lanac i dozvoljava saobraćaj iz mreže 192.168.30.0/24 prema mreži 192.168.50.0/24.

chain=forward

src-address=192.168.30.0/24

dst-address=192.168.50.0/24

action=accept

Suprotno tome, saobraćaj iz gostujućeg segmenta prema serverskom segmentu blokira se odgovarajućim DROP pravilom:

chain=forward

src-address=192.168.40.0/24

dst-address=192.168.50.0/24

action=drop

5. ANALIZA I REZULTATI

Predloženi model omogućava logičku organizaciju poslovne mreže i definisanje kontrolisanih tokova komunikacije između pojedinih segmenata. VLAN-ovi omogućavaju razdvajanje mreže na logičke cjeline, dok firewall pravila određuju koji su tokovi saobraćaja između tih cjelina dozvoljeni, a koji blokirani. Na taj način moguće je ograničiti nepotrebnu dostupnost između različitih dijelova mrežne infrastrukture.

Praktično testiranje izvršeno je sa računara smještenog u gostujućem VLAN-u 40, sa IP adresom 192.168.40.10, pri čemu je testiran pokušaj komunikacije prema adresnom prostoru serverskog VLAN-a 50. Testiranje je izvedeno slanjem ICMP saobraćaja pomoću ping naredbe prema adresi 192.168.50.10, pri čemu je odgovarajuće DROP firewall pravilo zabilježilo četiri paketa. Na isti način testiran je saobraćaj sa testnog računara konfigurisanog u IT VLAN-u 30 prema adresi 192.168.50.10, pri čemu je odgovarajuće ACCEPT pravilo zabilježilo četiri paketa. Rezultati su provjereni praćenjem broja paketa na firewall pravilima u MikroTik RouterOS-u. Cilj testiranja bio je provjeriti da li saobraćaj odgovara definisanim firewall pravilima, odnosno da li se odgovarajući paketi prihvataju ili blokiraju, a ne provjeriti dostupnost konkretnog aplikativnog servisa na određenoj adresi.

```

MikroTik-Router [Running] - Oracle VirtualBox
File Machine View Input Devices Help

nvrp-forbidden="" current-tagged=bridge-lan current-untagged=""

5 D ::: added by puid
  bridge=bridge-lan vlan-ids=1 tagged="" untagged=bridge-lan
  nvrp-forbidden="" current-tagged="" current-untagged=bridge-lan
[admin@CHR] > /ip firewall filter print stats
Columns: CHAIN, ACTION, BYTES, PACKETS
# CHAIN ACTION BYTES PACKETS
::: IT -> Serveri
0 forward accept 240 4
::: Racunovodstvo -> Serveri
1 forward accept 0 0
::: Uprava -> Serveri
2 forward accept 0 0
::: IT -> Uprava
3 forward accept 0 0
::: Gosti -> Serveri BLOCK
4 forward drop 240 4
::: Gosti -> Uprava BLOCK
5 forward drop 0 0
::: Gosti -> Racunovodstvo BLOCK
6 forward drop 0 0
::: Gosti -> IT BLOCK
7 forward drop 0 0
[admin@CHR] >

```

Slika 3. Rezultati testiranja firewall pravila na MikroTik RouterOS platformi

Posebno je značajna izolacija gostujuće mreže od internih resursa. U prikazanom modelu saobraćaj gostujućeg segmenta prema internim segmentima ograničen je definisanim firewall pravilima, dok se pristup internetu može dozvoliti nezavisno od pristupa internim resursima. Na taj način se ostvaruje kontrola komunikacije između gostujuće i interne mreže, bez potrebe za fizičkim razdvajanjem infrastrukture.

Ograničenje ovog modela jeste činjenica da sama VLAN segmentacija ne rješava sve bezbjednosne probleme. Potrebno je pravilno održavati firewall pravila, pratiti promjene u poslovnim zahtjevima, evidentirati odbijeni saobraćaj i redovno provjeravati da li su dozvole i dalje opravdane. Kod većih sistema granularnost se može povećati mikrosegmentacijom. NIST SP 800-215 opisuje mikrosegmentaciju kao pristup koji omogućava finije politike od tradicionalnog segmentnog modela [6].

6. ZAKLJUČAK

Mrežna segmentacija predstavlja efikasan način za organizaciju poslovne mreže i kontrolu komunikacije između njenih logičkih segmenata. Podjelom mreže na zasebne logičke segmente omogućava se bolje upravljanje korisnicima i resursima, dok kontrola komunikacije između segmenata ograničava pristup samo na potrebne mrežne resurse. U okviru prikazane studije slučaja formirano je pet VLAN segmenata namijenjenih upravi, računovodstvu, IT sektoru, gostujućim korisnicima i serverskim resursima, pri čemu je za svaki segment definisan zaseban IP adresni prostor.

Praktična implementacija na MikroTik RouterOS platformi pokazala je da se kombinacijom VLAN segmentacije i firewall pravila može definisati kontrolisana komunikacija između različitih dijelova poslovne mreže. Testiranjem je potvrđeno da je saobraćaj iz IT segmenta prema adresnom prostoru serverskog segmenta prihvaćen odgovarajućim firewall pravilom, dok je saobraćaj iz gostujućeg segmenta prema serverskom segmentu blokiran. Na taj način potvrđena je funkcionalnost definisanih firewall pravila u testiranim scenarijima i značaj pravilno definisane kontrole pristupa.

Predloženo rješenje predstavlja jednostavan i primjenjiv model organizacije poslovne mreže i kontrole pristupa, koji se može prilagoditi različitim organizacijama. Njegova prednost je u tome što omogućava unapređenje kontrole pristupa i ograničavanje nepotrebne komunikacije bez potrebe za potpunim fizičkim razdvajanjem mrežne infrastrukture, uz mogućnost daljeg proširenja i prilagođavanja bezbjednosnim zahtjevima organizacije.

REFERENCE

- [1] IEEE, IEEE Standard for Local and Metropolitan Area Networks—Bridges and Bridged Networks (IEEE 802.1Q-2018), IEEE, 2018.
- [2] R. Chandramouli, Analysis of Network Segmentation Techniques in Cloud Data Centers, National Institute of Standards and Technology, 2015.
- [3] Y. Rekhter, B. Moskowitz, D. Karrenberg, G. J. de Groot and E. Lear, Address Allocation for Private Internets (RFC 1918), Internet Engineering Task Force, 1996.
- [4] Cybersecurity and Infrastructure Security Agency (CISA), Enhanced Visibility and Hardening Guidance for Communications Infrastructure, CISA, 2024.
- [5] MikroTik, RouterOS Documentation – Firewall Filter, MikroTik, 2026.
- [6] R. Chandramouli, Guide to a Secure Enterprise Network Landscape (NIST SP 800-215), National Institute of Standards and Technology, 2022.



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITeO 2026

Banja Luka, 25 - 26. 9. 2026. godine



SISTEMI ZA UPRAVLJANJE LABORATORIJSKIM INFORMACIJAMA (LIMS) OTVORENOG KODA

Igor Grujic^{1,2*}, Mira Obradovic^{1,3}

¹Visoka medicinska škola - Prijedor, Nikole Pasića 4A, 79202 Prijedor, Republika Srpska, Bosna i Hercegovina

²Fakultet informacionih tehnologija, Panevropski Univerzitet Apeiron, Vojvode Pere Krece 13, 78102 Banja Luka, Bosna i Hercegovina

³Medicinski fakultet Univerziteta u Novom Sadu, Hajduk Veljkova 3, Novi Sad, Republika Srbija

*e-mail: igor.r.grujic@apeiron-edu.eu

Sažetak: Sistem za upravljanje laboratorijskim informacijama (LIMS) podržava i pojednostavljuje laboratorijske operacije. On pruža digitalni okvir u kojem se laboratorijski procesi izvršavaju i evidentiraju, poboljšavajući efikasnost, smanjujući greške i pružajući potpunu vidljivost laboratorijskih operacija. Vlasnici medicinskih i srodnih laboratorija prilikom kupovine su u dilemi koji LIMS da izaberu. U ovom radu autori su na osnovu uvida u naučnu literaturu i vlastitog rada tokom korištenja informacionog sistema u laboratoriji predstavili suštinu LIMS-a, sa posebnim naglaskom na LIMS-ove otvorenog koda. Analizirane su karakteristike i struktura, prednosti i nedostaci, te usklađenost sa propisima LIMS-a otvorenog koda u odnosu na komercijalne platforme. LIMS-ovi otvorenog koda u potpunosti mogu ispuniti zahtjeve laboratorija, pod uslovom da se laboratorije pridržavaju određenih zahtjeva.

Ključne riječi: Informacioni sistemi, Sistemi za upravljanje laboratorijskim informacijama, LIMS, medicinske laboratorije, sistemi sa otvorenim kodom

1. UVOD

LIMS ima višestruku ulogu u radu laboratorije. To je alat koji upravlja procesima tokom rada (dodjeljivanje testova i zakazivanje analiza), prikupljanja i skladištenje podataka, generisanja izvještaja itd. [1-5]. Informacioni sistemi u laboratoriji uspostavljaju skalabilan okvir za standardizirano upravljanje internim i eksternim provjerama kvaliteta u medicinskim laboratorijama [6]. Kontrola kvaliteta rada u laboratoriji je jednostavnija uz pomoć LIMS-a [7, 8]. Tokom vremena LIMS platforme su od najjednostavnijih rješenja, koja su podrazumijevala osnovno praćenje uzoraka, razvijene u moderne sveobuhvatne sisteme, koji mogu uključivati upravljanje zalihama, analizu podataka ispitivanja, elektronske laboratorijske bilježnice (ELN), pa čak i elemente planiranja resursa. Pored toga, moderna LIMS rješenja pružaju fleksibilne arhitekture i interfejse za razmjenu podataka, omogućavajući integraciju sa instrumentima i drugim softverima.

U regulisanim oblastima, LIMS je neophodan za sprovođenje standardizovanih tokova rada, održavanje integriteta podataka i obezbjeđenje usklađenosti putem funkcija praćenja tragova i kontrole pristupa korisnika.

Mnogi LIMS-ovi pružaju alate za izvještavanje i kontrolne table tako da laboratorije mogu da prate vrijeme obrade, opterećenje i metriku kvaliteta u stvarnom vremenu. Na primjer, moderni

LIMS automatski evidentiraju vrijeme i osobu koja je rukovala uzorkom, pratiti mjesto skladištenja uzorka (lokacija zamrzivača, itd.) i sprovesti standardne operativne procedure putem softverskih tokova rada. Automatizacijom takvih procesa, LIMS minimizira ručnu transkripciju (prepisivanje, unos) podataka, što smanjuje greške, i osigurava da su laboratorijski podaci konzistentni i dostupni za pregled ili analizu podataka.

Pored vlasničkih platformi, brojne laboratorije koriste LIMS sistema otvorenog koda. Otvoreni kod promoviše transparentnost i reproduktivnost i podstiče kolaborativni razvoj [9]. On omogućava istraživačima i praktičarima da nadograđuju postojeći rad, umjesto da započnu razvoj novog softvera, prilagođavajući alate za specifične tokove rada. Nadalje, otvoreni kod demokratizuje pristup naprednim analitičkim alatima, posebno za institucije sa ograničenim resursima, podstiče inovacije kroz globalne doprinose i olakšava standardizaciju i interoperabilnost neophodne za široko usvajanje DP-a [10, 11].

2. MATERIJAL I METODE

U radu je proveden sistematski pregled publikacija referisanih u naučnim bazama ScienceDirect, Scopus-u i PubMed. U pregledu su posmatrane publikacije objavljene u periodu od 2015. do 2026. godine. Definisano je nekoliko kriterijuma za uključivanje i isključivanje, kako bi se postavile granice za pregled i filtriranje rezultata pretrage. Kriterijumi za uključivanje fokusirali su se na recenzirane članke objavljene u priznatim časopisima. Pored toga, analizirani su nacionalni propisi više zemalja i tehnički standardi koji se odnose na ovu oblast. Kriterijumi za isključivanje eliminisali su članke koji nisu na engleskom jeziku, mišljenja i studije koje nisu direktno povezane sa medicinskim laboratorijama i LIMS-ovima otvorenog koda. Članci su odabrani na osnovu njihove relevantnosti za istraživačke ciljeve.

3. REZULTATI I DISKUSIJA

3.1. Lims otvorenog koda

LIMS-ovi otvorenog koda se distribuiraju pod besplatnim licencama, tako da se njihov izvorni kod može slobodno pregledavati, mijenjati i dijeliti [12]. To ih čini visoko prilagodljivim i isplativim alternativama komercijalnim sistemima. U nastavku su prikazani neki od LIMS-a otvorenog koda uz navođenje kratkih opisa za svaki od njih. Tokom opisa korištene su informacije iz opisane u publikacijama [13, 14]. S obzirom na karakteristike, funkcionalnost i namjenu za upotrebu, te prednosti koje imaju, zajednice koja podržava LIMS-ove otvorenog koda, LIMS-ovi se dijele na: LIMS-ove opšte namjene, LIMS-ove za sisteme biobanke i LIMS-ove za genomiku i sekvenciranje (slika 1).



Slika 13 - Primjeri LIMS-a otvorenog koda

Većina LIMS -ova je razvijena u svhu primjene u specijalizovanim uslovima (tabela 1).

Tabela 3 - Primjeri primjene LIMS-ova otvorenog koda

Naziv LIMS-a	Namjena LIMS-a
Drops LIMS	Otvoreni LIMS za kliničke laboratorije
MISO – MI crosystem	LIMS otvorenog koda za centre za sekvenciranje
gP2S	LIMS za laboratorije za krioelektronsku mikroskopiju
LimBuS	Sistem za upravljanje biobankama otvorenog koda
Lab manager	LIMS za kliničke molekularne laboratorije
Open-LIMS	LIMS za upravljanje projektima u biologiji
iSkyLIMS	LIMS fokusiran na masovne tokove sekvenciranja
NEMO	LIMS za upravljanje laboratorijskom logistikom i resursima
Sequencescape	LIMS za visokopropusne tokove rada sekvenciranja
Aquarium Lab	"Laboratorijski operativni sistem" za dizajn i izvršavanje protokola istraživanja
UniVersaLIS	LIMS za pristup uzorcima, upravljanje rezultatima i interfejsima instrumenata
Biobank	LIMS dizajniran za repozitorije bioloških uzoraka
Labrat	Python framework za upravljanje laboratorijom

3.2. Prednosti i mane LIMS-ova otvorenog koda

Primjena LIMS-ova otvorenog koda nudi nekoliko prednosti u odnosu na tradicionalne komercijalne (vlasničke) LIMS platforme: smanjenje troškova; povećanje slobode i fleksibilnosti u radu laboratorije i izbjegavanje zavisnosti od jednog dobavljača. Međutim, u nekim slučajevima komercijalni softveri ipak imaju prednost, o čemu rukovodstvo laboratorije mora voditi računa prilikom kupovine informacionog sistema. Najčešći izazovi sa kojima se laboratorije susreću u toku primjene LIMS-a otvorenog koda su: nedostatak profesionalne podrške; potreba za IT resursima za podešavanje, održavanje, validaciju i ažuriranje; postojanje rizika po bezbjednost zbog velike vidljivosti otvorenog koda i povećanja ranjivosti sistema. Sistemima otvorenog koda nedostaju "gotovi" alati za osiguranje bezbjednosti i provođenje validacije koje pružaju dobavljači. Laboratorija mora osigurati da LIMS otvorenog koda ima robusnu autentifikaciju korisnika. Sve navedeno zahtijeva vrijeme i povećava troškove implementacije i korištenja LIMS-a.

3.3. Tehnička arhitektura LIMS platformi otvorenog koda

LIMS/LIS platforme otvorenog koda uglavnom dijele modernu troslojnu web arhitekturu: baza podataka za skladištenje laboratorijskih podataka, sloj aplikacije na strani servera koji implementira poslovnu logiku (često sa web serverom) i web-bazirani korisnički interfejs [15]. Tehnološki paketi se razlikuju u zavisnosti od projekta, ali obično uključuju robusne komponente poslovnog nivoa.

Bekend (Backend) i baza podataka: Mnogi LIMS-ovi otvorenog koda koriste relacione sisteme baza podataka (kao što su PostgreSQL-a ili MySQL-a) za skladištenje strukturiranih laboratorijskih podataka (uzorci, rezultati testova itd.), osiguravajući usklađenost sa ACID-om i jednostavnost upita. Bez obzira na specifičnu bazu podataka, pozadinski sistemi LIMS-a otvorenog koda naglašavaju integritet podataka, često uključujući ugrađenu mogućnost praćenja (bilježenje svih promjena podataka) kako bi podržali GLP i druge smjernice kvaliteta.

Aplikacijski sloj i integracija: LIMS otvorenog koda obično otkriva tačke integracije kao što su RESTful API-ji ili SDK-ovi, omogućavajući drugom softveru (ili laboratorijskim instrumentima) da se povežu sa LIMS-om.

Integracija sa laboratorijskim instrumentima je veoma važno arhitektonsko pitanje. LIMS otvorenog koda podržava integraciju instrumenata putem standardizovanih datoteka za uvoz/izvoz ili konektora, a ne komercijanih drajvera. Oni se mogu konfigurisati za parsiranje izlaznih datoteka instrumenata (CSV, XML, itd.) ili korištenje posredničkog softvera. Neki moderni sistemi usvajaju standarde kao što je SiLA (*Standard for Industry Lab Automation*) ili HL7 za kliničke instrumente. U praksi, integracija instrumenata se postiže ili korištenjem direktorijuma upita za datoteke sa rezultatima ili korištenjem API-ja, ako softver instrumenta može da ga pozve.

Korisnički interfejs (Frontend): Korisnici obično komuniciraju sa LIMS-om otvorenog koda putem web pretraživača. Sloj korisničkog interfejsa omogućava pristup zasnovan na ulogama (npr., menadžer laboratorije može da vidi i odobri sve rezultate, dok analitičar može da vidi samo zadatke koji su njemu dodijeljeni) i vodi korisnika kroz definisane tokove rada (npr., provjera rezultata koja pokreće sljedeći korak procesa).

Modeli podataka: LIMS-i otvorenog koda obično imaju fleksibilne modele podataka, jer laboratorije često imaju potrebu da prate podatke. To je omogućeno samom arhitekturom softvera. Mnogi otvoreni sistemi pružaju konfigurabilna polja za šeme ili metapodatke.

Sistemi otvorenog koda omogućavaju inspekciju arhitekture uređaja, firmvera i softverskih komponenti. Standardizirani interfejsi i otvoreni komunikacijski protokoli mogu poboljšati interoperabilnost, što znači sposobnost uređaja i digitalnih zdravstvenih sistema da razmjenjuju i koriste podatke putem kompatibilnih formata i zajedničkih standarda. Otvoreni dizajni mogu smanjiti zavisnost od pojedinačnih dobavljača [9].

3.4. Primjeri upotrebe LIMS-a otvorenog koda

LIMS sistemi otvorenog koda implementirani su u različitim oblastima zdravstvenog sistema [9, 16-18] i različitim vrstama laboratorija [19, 20]. Oni često pružaju isplativa rješenja u sektorima u kojima bi komercijalni LIMS sistemi bili preskupi ili nefleksibilni. Sektori u kojima se LIMS-i otvorenog koda najčešće primjenjuju obuhvataju: istraživanje i razvoj u biotehnologiji i farmaciji; kliničke i javnozdravstvene laboratorije; laboratorije za ispitivanje životne sredine i vode; laboratorije za hranu i piće; laboratorije u akademskim i istraživačkim institucijama. U svim slučajevima, usvajanje LIMS-ova otvorenog koda vođeno je potrebom za prilagođavanjem, isplativošću i inovacijama. Dok komercijalni LIMS-ovi dominiraju poslovnim okruženjima, LIMS-ovi otvorenog koda dokazuju svoju vrijednost u nacionalnim zdravstvenim programima i proizvodnim laboratorijama.

LIMS-i otvorenog koda uticali su na napredak u kliničkoj dijagnostici, posebno u okruženjima sa ograničenim resursima i zemljama sa niskim nacionalnim dohotkom) [21-23]. Najočigledniji primjer predstavlja platforma OpenELIS Global [16], koji se primjenjuje u nacionalnim mrežama javnozdravstvenih laboratorija (na primjer, u Obali Slonovače koristi se u preko 100 laboratorija). Ove laboratorije koriste OpenELIS za upravljanje uzorcima pacijenata, rezultatima testova i za obezbjeđenje protoka podataka u centralne repozitorije za nadzor bolesti. Njegova priroda otvorenog koda omogućila je lokalno usvajanje uz podršku međunarodnih donatora, izbjegavajući skupe troškove za obezbjeđenje licence. Kako bi se riješili tokove rada uzoraka pacijenta i potrebu za usklađenošću, u nekim bolničkim laboratorijama ili malim zdravstvenim laboratorijama implementiran je Bika Health (varijanta Bika LIMS-a prilagođena zdravstvu). Bika Health je posebno dizajniran za upravljanje kliničkim slučajevima (praćenje pacijenata, testova i rezultata uz neophodnu kontrolu privatnosti) i koristi se u laboratorijama na Karibima i u Aziji [21, 24].

LIMS-ovi otvorenog koda se mogu proširiti u svrhu ispunjenja zahtjeve lokalnih propisa (npr., prilagođavanje nacionalnim formatima ili jezicima izvještavanja), što se može teško postići kod primjene komercijalnih sistema. Pored toga, LIMS-ovi otvorenog koda se mogu konfigurisati za dodavanje novih funkcija: elektronski potpis, revizorski tragovi, korisničke dozvole itd. U tom slučaju laboratorije moraju da osiguraju validiranost dodatih funkcija. Neke zdravstvene laboratorije u SAD-u eksperimentirale su sa primjenom LIMS-om otvorenog koda u oblasti toksikologije ili u istraživačkim laboratorijama orijentiranim za klinička ispitivanja) [25].

3.5. Usklađenost sa propisima u okruženjima LIMS-a otvorenog koda

Laboratorije u regulisanim industrijama (klinička dijagnostika, farmaceutske proizvodi, ispitivanja životne sredine, bezbjednost hrane itd.) moraju da se pridržavaju strogih standarda za

integritet, bezbjednost i sljedivost podataka (npr., CLIA i CAP za kliničke laboratorije [26], ISO/IEC 17025 za laboratorije za ispitivanje i kalibraciju [27], ISO 15189 za medicinske laboratorije [28], Dobre laboratorijske prakse (GLP) [29], te FDA 21 CFR Part 11 (elektronski zapisi i potpisi u farmaceutskim/biotehnoškim laboratorijama) [30]. Upotreba HL7 standarda pomaže u regulatornoj interoperabilnosti (na primjer, izvještavanje agencijama za javno zdravlje). Laboratorije moraju voditi računa o bezbjednosti podataka i privatnosti pacijenata, što se preklapa sa usklađenošću (npr., HIPAA za podatke o pacijentima) [31]. U suštini, usklađen LIMS mora pružiti funkcije integriteta podataka kao što su: jedinstveni korisnički nalozi i dozvole zasnovane na ulogama, revizorski trag koji bilježi sve izmjene podataka, mogućnost elektronskog potpisa za odobrenja, bezbjednost podataka i rezervne kopija.

Proces validacija LIMS-a otvorenog koda je isti kao i kod komercijalnog LIMS-a, s tim da zbog nedostatka dokumentacije za validaciju koju je obezbijedio dobavljač, laboratorija mora da kreira sopstvenu proceduru. Laboratorija je odgovorna za primjenu bezbjedonosnih zakrpa (ne postoji automatsko proslijeđivanje od strane dobavljača), tako da je potreban proces upravljanja kako bi se održala usklađenost sa sajber propisima. Laboratorije trebaju da primjenjuju najbolje prakse (npr., HTTPS enkripcije, politika jakih lozinki i redovna ažuriranja/zakrpe za LIMS).

ISO 17025 i ISO 15189 standardi zahtijevaju od laboratorija da imaju odgovarajuću sljedivost uzoraka, evidenciju validacije metoda, kontrolu kvaliteta i mogućnost revizije. LIMS otvorenog koda može se konfigurisati za provođenje standardnih operativnih postupaka (SOP). Prema potrebi, LIMS se možete konfigurisati tako da se definišu obavezna polja za popunjavanje, te da tokovi rada ne mogu da preskoče korak kalibracije ili korak kontrole kvaliteta.

Fleksibilnost otvorenih sistema omogućava, u slučaju izmjene propisa, da laboratorija može sama ažurirati sistem i da ne mora čekati dobavljača. Sve dok dizajn sistema omogućava verifikaciju i kontrolirani pristup, LIMS otvorenog koda može biti dio sistema kvaliteta koji je usklađen sa propisima.

3.6. Planiranje i analiza uslova za implementaciju LIMS-a otvorenog koda

Kako bi se osigurao uspjeh i dugočna upotreba, implementacija LIMS-a otvorenog koda od strane laboratorije zahtijeva prethodno planiranje i obezbjeđenje resursa. Tom prilikom neophodno je obratiti pažnju na: infrastrukturu i proces implementacije; laboratorijski tok rada; konfiguraciju i mogućnosti za prilagođavanje sistema; procese validacije i testiranja i potrebu za obukom korisnika. Iz vida ne treba izgubiti i analizu potencijalnih procesa upravljanja promjenama, obezbjeđenje podrške kontinuiranom održavanju, način prilagođavanja promjenama. Na kraju, treba razmotriti mogućnosti i pravce dugoročnog razvoja izabranog LIMS-a.

4. ZAKLJUČAK

LIMS-ovi otvorenog koda imaju prednost nad komercijalnim rješenjima zbog isplativosti, prilagodljivosti i izbjegavanja zavisnosti od određenog dobavljača. Izbor LIMS-a često zavisi od specifičnih potreba laboratorije, budžeta i internih mogućnosti. Kako bi u potpunosti ostvarile ove prednosti, medicinske laboratorije moraju biti spremne da ulažu u IT podršku, bezbjednosna poboljšanja i kontinuirano održavanje. Otvoreni kod donosi „isplativu fleksibilnost“, dok komercijalni LIMS-ovi zahtijevaju veće troškove za podršku po principu „ključ u ruke“ i pouzdanost. Standardi usklađenosti (npr., ISO 17025, ISO 15189 i drugi) ne definišu koji LIMS treba koristiti, već samo zahtijevaju da sistem koji se koristi ispunjava kriterijume sljedivosti uzoraka, evidenciju validacije metoda, kontrolu kvaliteta i mogućnost revizije. Pod uslovom da

se laboratorija koja ih koristi pridržava potrebnih praksi, u očima regulatora i kreatora propisa i standarda, rješenja otvorenog koda su ravnopravna sa komercijalnim rješenjima.

REFERENCE

- [1] Kalinowski M. 2025. A Comparative Analysis: Laboratory Information Management Systems (Lab LIMS) vs. Laboratory Information Systems (LIS Systems). Objavljeno 01.09.2025.
<https://www.ligolab.com/post/a-comparative-analysis-laboratory-information-management-systems-lims-vs-laboratory-information-systems-lis>. Dostupno: 15.01.2026.
- [2] Agharezaei Z, Khajouei R, Ahmadian L, Agharezaei L. 2020. Compliance with design principles: a case study of a widely used laboratory information system. *East. Mediterr. Health. J.* 26(12):1456–64. doi:10.26719/emhj.20.029.
- [3] Klatt EC. 2024. Cognitive factors impacting patient understanding of laboratory test information. *J Pathol Inf.* 15:100349. Dostupno: 05.11.2023 <https://doi.org/10.1016/j.jpi.2023.100349>.
- [4] Setiawan B, Prides A, Nuryunarsih D, Roehimat BM, Multazam NA. 2026. Medical Laboratory Technologists' Perceptions of Laboratory Information Systems. *Journal of Computer Information Systems*. <https://doi.org/10.1080/08874417.2026.2707140>
- [5] Edayan JM, Gallemitt AJ, Sacala NE, Palmer X-L, Potter L, Rarugal J, Velasco LC. 2024. Integration technologies in laboratory information systems: A systematic review. *Informatics in Medicine Unlocked* 50: 101566. Dostupno: 02.08.2024. <https://doi.org/10.1016/j.imu.2024.101566>.
- [6] Chen DH, Zhang Y, Qin J, Zhang L, Jiang C, Li F, Zhang X, Ou T. 2025. Development and Implementation of an Internal Quality Control and External Quality Assessment Information System for a Regional Medical Laboratory Center: Pilot Design and Implementation Study. *JMIR Formative Research*. 9: e77043. <https://doi.org/10.2196/77043>
- [7] Singh M, Chopra KK, Sidiq Z, Mehta G, Khatun F, (...), Shikha Dhawan. 2025. Blueprint for scalable laboratory driven quality management systems: Insights from tuberculosis diagnostic pilots in India. *Indian J. Tuberc.* 72 (Dec 2025): S80–S85. <https://doi.org/10.1016/j.ijtb.2025.05.004>.
- [8] Tanpaiboon P, Salazar D, Pan M, Xu L, Sharma R. 2025. Development of an automated quality control and assay performance management system for biochemical genetics laboratory. *Molecular Genetics and Metabolism Reports* 44:101247. <https://doi.org/10.1016/j.ymgmr.2025.101247>
- [9] Oglago Sariyer MR. 2026. Open-source health technologies for epidemiological research and public health surveillance. *Ann. Epidemiol.* 122: 110250. Dostupno: 27.07.2026. doi:10.1016/j.annepidem.2026.110250.
- [10] Guerrero EDR, Carvalho L, Bocklitz T, Popp J, Oliveira JL. 2022. Software tools and platforms in digital pathology: a review for clinicians and computer scientists. *J Pathol Inform.* 13: 100103. Dostupno: 3.06.2022. doi:10.1016/j.jpi.2022.10.0103.
- [11] Plass M, Kargl M, Kiehl T-R, (...), Müller H. 2023. Explainability and causability in digital pathology. *J Pathol Clin Res.* 9(4):251–260. doi:10.1002/cjp.2.322
- [12] Grujić I., Obradović M. 2026. Informacioni sistemi za upravljanje podacima u medicinskim laboratorijama. Međunarodna konferencija SANUS 2026. Zbornik radova
- [13] Mousa HE. 2018. 10 Best Free Open Source Laboratory Management Systems (LIMS) for Windows, Linux, and Mac OS-X. Dostupno na sajtu <https://medevel.com/top-10-foss-lims/> Dostupno. 12.09.2026.
- [14] Mousa HE. 2023. 20 Free and Open-source Laboratory Information Management Systems (LIMS). Dostupno na sajtu <https://medevel.com/20-lims/> Dostupno: 12.09.2026
- [15] Henricks HW. 2016. Laboratory Information Systems. *Clin Lab Med* 36: 1–11. <https://doi.org/10.1016/j.cl.2015.09.002>
- [16] He Y, Iiams-Hauser C, Assoa Paul H, Kouabenan Y-R, Komana P, (...), Perrone A L. 2023. Development and national scale implementation of an open-source electronic laboratory information system (OpenELIS) in Cote d'Ivoire: Sustainability lessons from the first 13 years. *Int. J. Med. Inform.* 170:104977. <https://doi.org/10.1016/j.ijmedinf.2022.104977>
- [17] Farre R, Gozal D, Nguyen V-N, Pearce JM, Dinh-Xuan AT. 2022. Open-source hardware may address the shortage in medical devices for patients with low-income and chronic respiratory diseases in low-resource countries. *J Pers Med.* 12:1498. Accepted 10 September 2022 <https://doi.org/10.3390/jpm12091498>
- [18] Casey E, Souvignat RT. 2020. Digital transformation risk management in forensic science laboratories. *Forensic Sci. Int.* 316 (2020) 110486. <https://doi.org/10.1016/j.forsciint.2020.110486>
- [19] Schwena O, Kiehl T-R, Carvalho R, Zerbe N, Homeyer A. 2023. Digitization of Pathology Labs: A Review of Lessons Learned. *Lab Invest.* 103:100244. Accepted 23 August 2023. <https://doi.org/10.1016/j.labinv.2023.100244>
- [20] Hans L, Cassim N, Sarang S, (...), Stevens W. 2023. HIV Viral Load Testing in the South African Public Health Setting in the Context of Evolving ART Guidelines and Advances in Technology 2013–2022. *Diagnostics*. 13(17). Accepted: 16 August 2023. <https://doi.org/10.3390/diagnostics13172731>

- [21] Landgraf KM, Kakkar R, Meigs M, Jankauskas PT, (...), Bond KB. 2016. Open-source LIMS in Vietnam: the path toward sustainability and host country ownership. *Int J Med Inform.* 93:92-102. doi: 10.1016/j.ijmedinf.2016.06.010
- [22] Mtonga TM, Choonara FE, Espino JU, Kachaje C, Kapundi K, (...), Douglas G. 2019. Design and implementation of a clinical laboratory information system in a low-resource setting. *Afr J Lab Med.* 8(1):841. DOI:10.4102/ajlm.v8i1.841
- [23] Kondaveeti HK, Kumaravelu NK, Vanambathina SD, Mathe SE, Vappangi S. 2021. A systematic literature review on prototyping with Arduino: Applications, challenges, advantages, and limitations. *Comput Sci Rev.* 40:100364. <https://doi.org/10.1016/j.cosrev.2021.100364>.
- [24] Vogus A., Graff K. 2015. PEPFAR transitions to country ownership: review of past donor transitions and application of lessons learned to the Eastern Caribbean, *Glob. Health Sci. Pract.* 3(2):274–286. doi:10.9745/GHSP-D-14-00227.
- [25] Coito T, Fırme B, Martins SEM, Costigliola A, Lucas R, Figueiredo J, Vieira MS, Sousa MCJ. 2022. Integration of industrial IoT architectures for dynamic scheduling. *Comput. Ind. Eng.* 171:108387. <https://doi.org/10.1016/j.cie.2022.108387>
- [26] CLIA. 2026. Clinical Laboratory Improvement Amendments. <https://www.cms.gov/medicare/quality/clinical-laboratory-improvement-amendments> Dostupno 09.02.2026
- [27] ISOa. 2017. ISO/IEC 17025:2017. Opšti zahtjevi za osposobljenost laboratorija za ispitivanje i kalibraciju (*General requirements for the competence of testing and calibration laboratories*). Međunarodna organizacija za standardizaciju, Ženeva.
- [28] ISOb. 2022. ISO 15189:2022. Medicinske laboratorije - posebni zahtjevi za kvalitet i stručnost (*Medical laboratories—particular requirements for quality and Competence*).: Međunarodna organizacija za standardizaciju, Ženeva
- [29] OECD. 1998. OECD series on Principles of Good Laboratory Practice and Compliance Monitoring. No1 OECD Principles of Good Laboratory Practice (as revised in 1997). ENV/MC/CHEM(98)17. Environment Directorate. Organisation for Economic Co-operation and Development. Paris 1998. Available at: https://www.oecd.org/en/publications/oecd-series-on-principles-of-good-laboratory-practice-and-compliance-monitoring_2077785x.html
- [30] USA. 2026. Code of Federal Regulations. Title 21, Chapret I, Part 11. <https://www.ecfr.gov/current/title-21/chapter-I/subchapter-A/part-11> Dostupno 09.02.2026.
- [31] Edemekong PF, Annamaraju P, Afzal M, Haydel J M. 2026. Health Insurance Portability and Accountability Act (HIPAA) Compliance. Last Update: November 24, 2024. <https://www.ncbi.nlm.nih.gov/books/NBK500019/>

OPEN SOURCE LABORATORY INFORMATION MANAGEMENT SYSTEMS (LIMS)

Igor Grujic^{1,2*}, Mira Obradovic^{1,3}

¹College of Health Sciences - Prijedor, Nikole Pasica 4A, 79202 Prijedor, Republic of Srpska, Bosnia and Herzegovina

²Faculty of Information Technology, Paneuropean University Apeiron, Vojvode Pere Krece 13, 78102 Banja Luka, Bosnia and Herzegovina

³Faculty of Medicine of the University of Novi Sad, Hajduk Veljkova 3, Novi Sad, Republic of Serbia

*e-mail: igor.r.grujic@apeiron-edu.eu

Abstract: Laboratory information management systems (LIMS) support and streamline laboratory operations. It provides a digital framework in which laboratory processes are executed and recorded, improving efficiency, reducing errors and providing full visibility of laboratory operations. Owners of medical and related laboratories are in a dilemma as to which LIMS to choose. In this paper, the authors presented the essence of LIMS based on an insight into the scientific literature and their own work during the use of the information system in the laboratory, with a special emphasis on open source LIMS. The characteristics and structure, advantages and disadvantages, and regulatory compliance of open source LIMS compared to commercial platforms are analyzed. Open source LIMS can fully meet the requirements of laboratories, provided that the laboratories adhere to certain requirements.

Keywords: Information systems, Laboratory information management systems, LIMS, medical laboratories, open source systems



XVIII međunarodni naučno-stručni skup
Informacione Tehnologije za elektronsko Obrazovanje
ITEO 2026

Banja Luka, 25 - 26. 9. 2026. godine



DIGITALNE KOMPETENCIJE KAO TEMELJ OBRAZOVNE TRANSFORMACIJE: ANALIZA PRIMJENE DIGCOMP OKVIRA U REPUBLICI SRPSKOJ

Jefto Džino¹, Danijela Injac², Stefan Džino³, Milan Dedić⁴

¹Panevropski Univerzitet Apeiron, Banja Luka, jefto.m.dzino@apeiron-edu.eu

²Ministarstvo za evropske integracije i međunarodnu saradnju Republike Srpske, Banja Luka, d.injac@meoi.vladars.net

³PR Systemfinity, Beograd, Republika Srbija, dzino.stefan93@gmail.com

⁴Panevropski Univerzitet Apeiron, Banja Luka, milan.dedic@apeiron-edu.eu

Apstrakt: Digitalna transformacija društva dovela je do značajnih promjena u načinu sticanja znanja, rada i komunikacije, zbog čega razvoj digitalnih kompetencija postaje jedan od ključnih prioriteta savremenih obrazovnih sistema. Cilj rada je analizirati mogućnosti primjene evropskih okvira DigComp i DigCompEdu u procesu digitalizacije obrazovanja u Republici Srpskoj. Istraživanje je provedeno primjenom kvalitativnog metodološkog pristupa, koristeći metode analize sadržaja, komparativne analize i deskriptivne metode. Analizirani su strateški dokumenti Evropske unije, naučna literatura i dostupni dokumenti obrazovnog sistema Republike Srpske. Rezultati pokazuju da su u Republici Srpskoj ostvareni značajni pomaci u razvoju digitalne infrastrukture i elektronskih obrazovnih servisa, ali da sistemski razvoj digitalnih kompetencija učenika i nastavnika još uvijek nije u potpunosti institucionalizovan. Zaključuje se da DigComp i DigCompEdu predstavljaju pogodan okvir za unapređenje obrazovnih politika i razvoj održivog modela digitalnog obrazovanja usklađenog s evropskim standardima.

Ključne riječi: digitalizacija obrazovanja, digitalne kompetencije, DigComp, DigCompEdu, e-učenje, Republika Srpska.

Abstract: Digital transformation of society has led to significant changes in the way knowledge is acquired, work is performed, and communication takes place, making the development of digital competences one of the key priorities of modern educational systems. The aim of this paper is to analyze the possibilities of applying the European DigComp and DigCompEdu frameworks in the process of educational digitalization in the Republic of Srpska. The research was conducted using a qualitative methodological approach, employing content analysis, comparative analysis, and descriptive methods. Strategic documents of the European Union, scientific literature, and available documents of the educational system of the Republic of Srpska were analyzed. The results indicate that significant progress has been made in the Republic of Srpska in the development of digital infrastructure and electronic educational services; however, the systematic development of digital competences among students and teachers has not yet been fully institutionalized. It is concluded that DigComp and DigCompEdu provide a suitable framework for improving educational policies and developing a sustainable model of digital education aligned with European standards.

Key Words: educational digitalization, digital competences, DigComp, DigCompEdu, e-learning, Republic of Srpska.

1. UVOD

Digitalna transformacija predstavlja jedan od najznačajnijih društvenih procesa 21. vijeka. Razvoj informaciono-komunikacionih tehnologija, interneta, digitalnih platformi i vještačke inteligencije mijenja način na koji pojedinci komuniciraju, rade, uče i pristupaju informacijama [1]. Obrazovni sistemi širom svijeta suočeni su sa izazovom prilagođavanja novim okolnostima i potrebama digitalnog društva.

Savremeno obrazovanje više nije usmjereno isključivo na usvajanje činjenica i reprodukciju znanja. Od učenika se očekuje razvijanje sposobnosti kritičkog mišljenja, pronalaženja i procjene informacija, digitalne komunikacije i saradnje, stvaranja digitalnih sadržaja, zaštite privatnosti i odgovorne upotrebe digitalnih tehnologija. Istovremeno, nastavnici se suočavaju sa zahtjevima za primjenu novih nastavnih metoda, digitalnih alata i inovativnih pristupa učenju.

Evropska unija prepoznala je digitalno obrazovanje kao jedan od ključnih instrumenata razvoja konkurentnog društva znanja. Kroz Akcioni plan za digitalno obrazovanje (2021–2027), DigComp i DigCompEdu okvire definišu se smjernice za razvoj digitalnih kompetencija građana i obrazovnih radnika [1, 8].

Republika Srpska je u prethodnom periodu realizovala niz aktivnosti usmjerenih ka digitalizaciji obrazovnog sistema kroz razvoj elektronskog dnevnika, informacionih sistema i digitalnih servisa. Međutim, ostaje otvoreno pitanje u kojoj mjeri postojeće aktivnosti doprinose razvoju digitalnih kompetencija učenika i nastavnika u skladu sa savremenim evropskim standardima.

2. POSTAVKA PROBLEMA

Proces digitalizacije obrazovanja u Republici Srpskoj uglavnom je bio usmjeren na razvoj tehničke infrastrukture i informacionih sistema. Iako takvi koraci predstavljaju važnu pretpostavku digitalne transformacije, oni sami po sebi nisu dovoljni za ostvarivanje ciljeva savremenog obrazovanja.

Problem istraživanja može se definisati kroz sljedeće pitanje:

U kojoj mjeri postojeći proces digitalizacije obrazovanja u Republici Srpskoj odgovara zahtjevima evropskih okvira DigComp i DigCompEdu kao i na koji način ovi okviri mogu doprinijeti unapređenju obrazovnog sistema?

Iz navedenog problema proizlaze sljedeći ciljevi istraživanja:

- analizirati značaj digitalizacije obrazovanja;
- predstaviti osnovne karakteristike DigComp i DigCompEdu okvira;
- analizirati stanje digitalizacije obrazovanja u Republici Srpskoj;
- identifikovati mogućnosti primjene evropskih okvira digitalnih kompetencija;
- predložiti smjernice za unapređenje digitalnog obrazovanja.

3. TEORIJSKI OKVIR

3.1. Digitalizacija obrazovanja

Digitalizacija obrazovanja podrazumijeva integraciju digitalnih tehnologija u sve segmente obrazovnog sistema. Ona obuhvata primjenu digitalne infrastrukture, obrazovnih platformi,

elektronskih sadržaja, informacionih sistema i komunikacionih kanala sa ciljem unapređenja kvaliteta obrazovanja.

Digitalizacija se najčešće posmatra kroz tri međusobno povezana nivoa:

1. digitalna infrastruktura;
2. digitalni alati i sadržaji;
3. digitalne kompetencije.

Tek istovremeni razvoj sva tri segmenta može rezultirati stvarnom digitalnom transformacijom obrazovanja.

3.2. DigComp okvir

DigComp predstavlja Evropski okvir digitalnih kompetencija građana [2]. Okvir definiše pet područja kompetencija:

1. Informaciona i pismenost u radu sa podacima;
2. Komunikacija i saradnja;
3. Kreiranje digitalnog sadržaja;
4. Sigurnost;
5. Rješavanje problema.

Ove kompetencije omogućavaju pojedincima aktivno i odgovorno učestvovanje u digitalnom društvu.

3.3. DigCompEdu okvir

DigCompEdu predstavlja evropski okvir digitalnih kompetencija obrazovnih radnika [6]. Njegov cilj je unapređenje digitalnih i pedagoških kompetencija nastavnika kroz šest područja djelovanja:

- profesionalni angažman;
- digitalni resursi;
- nastava i učenje;
- vrjednovanje;
- osnaživanje učenika;
- razvoj digitalnih kompetencija učenika.

Primjena ovog okvira omogućava sistemsko planiranje stručnog usavršavanja nastavnika.

3.4. Akcioni plan za digitalno obrazovanje

Akcioni plan za digitalno obrazovanje Evropske unije predstavlja strateški dokument kojim se definišu prioriteti razvoja digitalnog obrazovanja do 2027. godine [1].

Plan je zasnovan na dva osnovna prioriteta:

- razvoj efikasnog digitalnog obrazovnog ekosistema;
- unaprjeđenje digitalnih kompetencija građana.

Poseban značaj dobio je nakon pandemije COVID-19, koja je ukazala na potrebu razvoja fleksibilnih modela obrazovanja i e-učenja [1].

4. METODOLOGIJA ISTRAŽIVANJA

Istraživanje je zasnovano na kvalitativnom metodološkom pristupu.

Primijenjene su sljedeće metode:

Analiza sadržaja

Analizirani su relevantni dokumenti Evropske unije iz oblasti digitalnog obrazovanja, uključujući DigComp, DigCompEdu i Akcioni plan za digitalno obrazovanje.

Deskriptivna metoda

Korištena je za prikaz postojećeg stanja digitalizacije obrazovanja u Republici Srpskoj.

Komparativna analiza

Primijenjena je radi poređenja postojećeg stanja digitalizacije obrazovanja u Republici Srpskoj sa zahtjevima evropskih okvira digitalnih kompetencija.

Osnovna pretpostavka istraživanja jeste da uspješna digitalna transformacija obrazovanja zahtijeva razvoj digitalnih kompetencija učenika i nastavnika, a ne samo razvoj tehničke infrastrukture.

5. REZULTATI ISTRAŽIVANJA

5.1. Stanje digitalizacije obrazovanja u Republici Srpskoj

Analiza pokazuje da je u Republici Srpskoj realizovan značajan broj aktivnosti usmjerenih ka digitalizaciji obrazovanja [5,6].

Najznačajniji rezultati uključuju:

- elektronski dnevnik;
- portal eObrazovanje;
- digitalne komunikacione platforme;
- informacioni sistemi za upravljanje obrazovnim procesima;
- mobilne aplikacije namijenjene učenicima i roditeljima.

Ove aktivnosti doprinijele su većoj transparentnosti rada škola i efikasnijoj komunikaciji između obrazovnih aktera.

5.2. Usklađenost sa DigComp okvirom

Analiza pokazuje djelimičnu usklađenost sa DigComp standardima [9].

Tabela 1. Usklađenost sa DigComp standardima

Element	Stanje u RS	Stepen usklađenosti
Digitalna infrastruktura	razvijena	visoka
Elektronski servisi	razvijeni	visoka
Digitalni sadržaji	srednje razvijeni	srednja

Procjena digitalnih kompetencija nedovoljno razvijena niska		
Standardizacija kompetencija	ograničena	niska

5.3. Usklađenost sa DigCompEdu okvirom

Najveći izazovi uočeni su u oblasti razvoja digitalnih kompetencija nastavnika.

Postojeći oblici stručnog usavršavanja uglavnom su usmjereni na tehničku upotrebu digitalnih alata, dok je manji fokus na razvoju digitalnih pedagoških kompetencija koje predviđa DigCompEdu okvir.

6. DISKUSIJA

Dobijeni rezultati potvrđuju da digitalna transformacija obrazovanja predstavlja znatno širi proces od uvođenja digitalne i IT infrastrukture.

Iako Republika Srpska posjeduje značajnu infrastrukturu i razvijene elektronske servise, razvoj digitalnih kompetencija učenika i nastavnika još nije dostigao nivo sistemskog i standardizovanog pristupa.

Posebno značajnim pokazuje se DigComp okvir, koji omogućava definisanje mjerljivih ishoda učenja i standarda digitalnih kompetencija. Njegova primjena mogla bi doprinijeti integraciji digitalnih vještina u različite nastavne predmete i obrazovne nivoe.

Slično tome, DigCompEdu može predstavljati osnovu za razvoj savremenog sistema stručnog usavršavanja nastavnika. Takav pristup omogućio bi prelazak sa pojedinačnih obuka za korištenje softvera prema razvoju sveobuhvatnih digitalnih i pedagoških kompetencija.

Dodatnu vrijednost predstavlja povezivanje DigComp i GreenComp okvira, čime se razvoj digitalnih kompetencija povezuje sa održivim razvojem, ekološkom odgovornošću i zelenom tranzicijom.

6.1. Primjeri dobre prakse u primjeni digitalnih kompetencija

Analiza evropskih iskustava pokazuje da uspješna digitalna transformacija obrazovanja podrazumijeva istovremeni razvoj infrastrukture, digitalnih sadržaja i kompetencija nastavnika i učenika. Posebno značajni primjeri dobre prakse mogu poslužiti kao smjernice za unapređenje obrazovnog sistema Republike Srpske.

Projekat e-Škole u Republici Hrvatskoj

Jedan od najznačajnijih primjera digitalne transformacije obrazovanja u regionu predstavlja projekat „e-Škole“, koji provodi Hrvatska akademska i istraživačka mreža (CARNET) [10]. Projekat je obuhvatio modernizaciju školske infrastrukture, razvoj digitalnih obrazovnih sadržaja, opremanje učionica informaciono-komunikacionom opremom i obuku nastavnika prema DigCompEdu principima.

Poseban značaj projekta ogleda se u činjenici da razvoj digitalnih kompetencija nije bio ograničen samo na predmete iz područja informatike, već je integrisan u različite nastavne oblasti. Time je omogućeno sistemsko razvijanje digitalnih vještina učenika kroz cjelokupan obrazovni proces.

SELFIE alat Evropske komisije

Evropska komisija razvila je SELFIE alat kao instrument za samoprocjenu digitalne spremnosti škola. Ovaj alat omogućava nastavnicima, učenicima i rukovodstvu škole procjenu nivoa primjene digitalnih tehnologija u nastavi.

Prednost SELFIE alata ogleda se u mogućnosti identifikovanja prednosti i slabosti digitalnog okruženja škole, što omogućava donošenje ciljanih mjera za unapređenje kvaliteta obrazovanja i razvoja digitalnih kompetencija.

EU Academy platforma

Platforma EU Academy predstavlja primjer dobre prakse u oblasti cjeloživotnog učenja i razvoja digitalnih kompetencija. Putem besplatnih online kurseva građanima se omogućava sticanje novih digitalnih znanja i vještina u skladu sa DigComp okvirom.

Ovakav model pokazuje kako digitalno obrazovanje može doprinijeti većoj dostupnosti obrazovanja različitim društvenim grupama, nezavisno od geografskog položaja ili socioekonomskog statusa.

GreenComp projekat u Kantonu Sarajevo

Dobar primjer povezivanja digitalnih kompetencija i održivog razvoja predstavlja projekat „GREENCOMP – Kompetencije za održivi razvoj kroz kroskurikularno planiranje“, koji je realizovan u Kantonu Sarajevo [12].

Kroz ovaj projekat razvijeni su nastavni materijali koji kod učenika istovremeno razvijaju svijest o održivom razvoju, kritičko mišljenje i kompetencije za primjenu digitalnih tehnologija u rješavanju društvenih i ekoloških izazova.

Mogućnosti primjene u Republici Srpskoj

lici Srpskoj

Analizirani primjeri pokazuju da uspješni modeli digitalne transformacije imaju nekoliko zajedničkih karakteristika:

- jasno definisane standarde digitalnih kompetencija;
- kontinuirano stručno usavršavanje nastavnika;
- sistemsko mjerenje postignuća učenika;
- dostupnost kvalitetnih digitalnih obrazovnih sadržaja;
- povezivanje digitalnih kompetencija sa potrebama tržišta rada i održivog razvoja.

Primjena sličnog pristupa u Republici Srpskoj mogla bi doprinijeti prelasku sa digitalizacije pojedinačnih procesa na razvoj cjelovitog digitalno kompetentnog obrazovnog sistema.

6.2. Primjeri dobre prakse iz osnovnih škola

Primjena digitalnih kompetencija najvidljivija je u svakodnevnom nastavnom procesu osnovnih škola, gdje digitalne tehnologije mogu poboljšati kvalitet učenja, povećati motivaciju učenika i razvijati kompetencije potrebne za život i rad u digitalnom društvu.

Primjer 1: Digitalna istraživačka nastava

U nastavi prirode i društva učenici mogu koristiti internet izvore, digitalne enciklopedije i interaktivne mape za prikupljanje podataka o lokalnoj zajednici, kulturno-istorijskom naslijeđu ili prirodnim resursima. Nastavnik pri tome usmjerava učenike da procjenjuju vjerodostojnost informacija i pravilno navode izvore.

Ovakav pristup razvija područje informacione pismenosti u radu i podstiče kritičko mišljenje i samostalno učenje.

Primjer 2: Upotreba digitalnih kvizova u formativnom vrednovanju

Mnoge osnovne škole koriste digitalne alate poput Kahoot-a, Quizizz-a ili Microsoft Forms-a za provjeru znanja učenika. Digitalni kvizovi omogućavaju nastavnicima neposredan uvid u postignuća učenika, dok učenicima pružaju brzu povratnu informaciju o uspjehu.

Takva praksa doprinosi razvoju digitalnih kompetencija učenika i unapređuje proces formativnog praćenja i vrjednovanja znanja. U Republici Srpskoj nastavni predmet Digitalni svijet uveden je kao sistemski odgovor na taj izazov, sa ciljem da učenici od najranijih razreda stiču funkcionalne, kritičke i bezbjedne digitalne vještine [13]

Primjer 3: Projektna nastava i digitalne prezentacije

U okviru projektne nastave učenici mogu samostalno ili timski izrađivati prezentacije, infografike, digitalne postere i kratke video-materijale. Na primjer, tema „Zaštita životne sredine“ može biti obrađena kroz izradu digitalnih kampanja kojima učenici promovišu odgovorno ponašanje prema prirodi. Na ovaj način razvijaju se kompetencije iz područja kreiranja digitalnog sadržaja, saradnje i komunikacije.

Primjer 4: Elektronska komunikacija između škole i roditelja

Primjena elektronskog dnevnika omogućava roditeljima uvid u ocjene, izostanke i druge aktivnosti učenika u realnom vremenu. Time se unapređuje saradnja škole i porodice te povećava transparentnost obrazovnog procesa. Ovakav model predstavlja važan element digitalne transformacije osnovnih škola i doprinosi efikasnijem upravljanju nastavnim procesom.

Primjer 5: Razvoj medijske i informacione pismenosti

U pojedinim osnovnim školama organizuju se radionice o bezbjednosti na internetu, zaštiti ličnih podataka, prepoznavanju dezinformacija i odgovornom korištenju društvenih mreža. Kroz ovakve aktivnosti učenici razvijaju kompetencije povezane sa digitalnom sigurnošću i odgovornim ponašanjem u digitalnom okruženju, što predstavlja jedno od ključnih područja DigComp okvira.

Primjer 6: Korištenje vještačke inteligencije u nastavi

Savremene osnovne škole sve češće uvode aktivnosti koje učenike upoznaju sa osnovnim principima vještačke inteligencije. Primjer dobre prakse predstavlja korištenje obrazovnih AI alata za kreiranje jednostavnih tekstova, ilustracija ili rješavanje problema uz stalni nadzor nastavnika. Cilj ovih aktivnosti nije samo korištenje tehnologije, već razvijanje kritičkog odnosa prema rezultatima koje generišu AI sistemi, razumijevanje njihovih ograničenja i odgovorna primjena u procesu učenja.

Značaj za obrazovni sistem Republike Srpske

Navedeni primjeri pokazuju da razvoj digitalnih kompetencija ne zahtijeva isključivo složenu i skupu infrastrukturu. Mnoge aktivnosti mogu se provoditi korištenjem postojećih računara, projektora, internet veza i elektronskih servisa koji su već prisutni u školama.

Ključ uspjeha nalazi se u kontinuiranom stručnom usavršavanju nastavnika, integraciji digitalnih kompetencija u različite nastavne predmete i stvaranju školskog okruženja koje podstiče aktivno, saradničko i istraživačko učenje. Na taj način osnovne škole postaju nosioci razvoja digitalno kompetentnih učenika koji su spremni za dalje obrazovanje i život u savremenom digitalnom društvu.

7. PREPORUKE

Na osnovu provedenog istraživanja mogu se izdvojiti sljedeće preporuke:

1. Razviti model digitalnih kompetencija učenika zasnovan na DigComp okviru.
2. Koristiti DigCompEdu kao osnovu za stručno usavršavanje nastavnika.
3. Integrirati digitalne kompetencije u sve nastavne predmete.
4. Razviti sistem procjene i praćenja digitalnih kompetencija.
5. Unaprijediti digitalne obrazovne sadržaje.
6. Obezbijediti ravnomjeran pristup digitalnoj infrastrukturi.
7. Jačati sajber-bezbjednost u obrazovnim ustanovama.
8. Definirati smjernice za odgovornu upotrebu vještačke inteligencije u obrazovanju.
9. Podsticati razvoj digitalne i medijske pismenosti.
10. Povezati digitalno obrazovanje sa ciljevima održivog razvoja.

8. ZAKLJUČAK

Digitalizacija obrazovanja predstavlja jedan od ključnih pravaca razvoja savremenih obrazovnih sistema. Analiza pokazuje da Republika Srpska posjeduje značajne infrastrukturne i organizacione pretpostavke za razvoj digitalnog obrazovanja, prvenstveno kroz elektronske servise, informacione sisteme i komunikacione platforme.

Međutim, uspješna digitalna transformacija obrazovanja ne može se zasnivati isključivo na tehnologiji. Ključnu ulogu imaju digitalne kompetencije učenika i nastavnika koje omogućavaju efikasno, kritičko i odgovorno korištenje digitalnih tehnologija.

DigComp i DigCompEdu predstavljaju kvalitetne referentne okvire za razvoj obrazovnih politika i unapređenje digitalnih kompetencija. Njihova prilagođena primjena može doprinijeti stvaranju obrazovnog sistema koji je usklađen sa evropskim standardima i zahtjevima digitalnog društva. Predmet Digitalni svijet pokazuje značajan potencijal u razvoju digitalne pismenosti i kompetencija učenika, predstavljajući stabilan temelj za funkcionalnu, kritičku i bezbjednu upotrebu tehnologije u savremenom obrazovanju.

Takav pristup omogućio bi prelazak sa digitalizacije pojedinačnih procesa na sveobuhvatnu digitalnu transformaciju obrazovanja u Republici Srpskoj.

REFERENCE

- [1] European Commission. (2020). *Digital Education Action Plan 2021-2027: Resetting education and training for the digital age*. Publications Office of the European Union. <https://education.ec.europa.eu/focus-topics/digital-education/action-plan>
- [2] Vuorikari, R., Kluzer, S., & Punie, Y. (2022). *DigComp 2.2: The Digital Competence Framework for Citizens*. Publications Office of the European Union.

- [3] IEA. (2024). *ICILS 2023 International Computer and Information Literacy Study*. International Association for the Evaluation of Educational Achievement.
- [4] Eurostat. (2020). *Digital economy and society statistics – households and individuals*. European Commission.
- [5] Ministarstvo prosvjete i kulture Republike Srpske. (2023). *EDUKOM eDnevnik – mobilna aplikacija za roditelje i učenike*.
- [6] Vlada Republike Srpske. (2024). *Portal eObrazovanje i elektronski dnevnik Republike Srpske*.
- [7] European Commission. (2022). *Council Recommendation on a European approach to micro-credentials for lifelong learning and employability*. Official Journal of the European Union.
- [8] European Commission. (2022). *SELFIE for Teachers: Supporting Digital Capacity in Education*.
- [9] European Commission. (2024). *EU Academy Learning Platform*.
- [10] CARNET. (2023). *e-Škole: Cjelovita informatizacija procesa poslovanja škola i nastavnih procesa u svrhu stvaranja digitalno zrelih škola za 21. stoljeće*.
- [11] UNICEF Bosnia and Herzegovina. (2024). *Digital Learning and Education Support Programmes in Bosnia and Herzegovina*.
- [12] Institut za razvoj preduniverzitetskog obrazovanja Kantona Sarajevo. (2024). *GREENCOMP – Kompetencije za održivi razvoj kroz kroskurikularno planiranje*.
- [13] D. Vasiljević, D. Jorgić, Ž. Dragić i B. Vasiljević (2025). Samoprocjena digitalne pismenosti i kompetencija učenika u kontekstu nastave digitalnog svijeta. *Naša škola*, Vol. XXXI, No. 2, pp. 9 - 27, Jun, 2025.

CIP - Каталогизација у публикацији
Народна и универзитетска библиотека
Републике Српске, Бања Лука

37.018.43:004.738.5(082)(0.034.2)

МЕЂУНАРОДНИ научно-стручни скуп Информационе
технологије за е-Образовање ИТеО (18 ; 2026 ; Бања Лука)

Zbornik radova [Електронски извор] = Proceedings / XVIII
međunarodni naučno-stručni skup Informacione tehnologije za e-
Obrazovanje ИТеО, 25-26.9.2026. Banja Luka ; urednici Dalibor P.
Drljača, Dražen Marinković, Siniša Tomić ; pokrovitelji konferencije
Agencija za informaciono-komunikacione tehnologije Republike
Srpske i Akademija nauka i umjetnosti Republike Srpske. - Onlajn
izd. - Banja Luka : Panevropski univerzitet Apeiron, 2026. - (Edicija
Informacione tehnologije = Information technologies ; knj. br. 43)

Način pristupa (URL): <https://www.iteo.rs.ba/>. - Насл. са
насловног екрана. - Опис извора дана 2.10.2026. - Ел.
публикација у ПДФ формату опсега 146 стр. - Текст ћир. и лат. -
Радови на срп. и енгл. језику. - Библиографија уз сваки рад. -
Abstracts.

ISBN 978-99976-87-76-0

COBISS.RS-ID 144855297

SPONZORI:

