Media, Culture and Public Relations Vol.17, 1

INFO - 199 UDK 004.8:316.77:001.81

https://doi.org/10.63191/mcpr.17.1.1 ORIGINALNI ZNANSTVENI RAD / ORIGINAL SCIENTIFIC PAPER

EPISTEMOLOGIJA ALGORITAMSKE POSLUŠNOSTI: BIBLIOMETRIJSKA ANALIZA IMAGINARIJA SIGURNOSTI U DIGITALNOJ KOMUNIKACIJI

pukovnica Marija Gombar, mag. cin.
Glavni stožer Oružanih snaga Republike Hrvatske
Sarajevska 7, 10000 Zagreb
magombar@unin.hr

SAŽETAK: Ovaj rad bibliometrijski mapira načine na koje se u suvremenoj znanstvenoj literaturi konceptualiziraju sigurnost, transparentnost, povjerenje i autonomija u algoritamski posredovanoj digitalnoj komunikaciji. Polazeći od teorijskog koncepta epistemološke poslušnosti, rad sigurnost promatra ne samo kao tehnički i regulatorni zahtjev, nego i kao diskurzivni okvir unutar kojega se oblikuju pitanja vidljivosti, kontrole znanja i korisničke autonomije. Analiza je provedena na korpusu od 517 znanstvenih radova indeksiranih u bazi Scopus i objavljenih u razdoblju od 2015. do 2026. godine, primjenom analize suučestalosti ključnih riječi, bibliografske povezanosti dokumenata i obrazaca suautorstva u alatu VOSviewer. Rezultati pokazuju središnju poziciju tema umjetne inteligencije, transparentnosti, povjerenja i algoritamskog upravljanja te izraženu povezanost regulatorno-etičkih i sigurnosnih pristupa. Istodobno, koncepti autonomije, participacije i otpora pojavljuju se manje istaknuto i pretežno u perifernim ili novijim tematskim smjerovima. Vremenska distribucija pojmova upućuje na postupno jačanje interesa za društvene i epistemološke implikacije algoritamskih sustava. Nalazi ne dokazuju učinke algoritamskih sustava na ponašanje korisnika, nego identificiraju obrasce znanstvenog diskursa koji omogućuju teorijsko razmatranje epistemološke poslušnosti. Rad zaključuje da bibliometrijski mapirani obrasci otvaraju prostor za daljnja empirijska istraživanja odnosa između digitalne sigurnosti, transparentnosti i korisničke autonomije.

KLJUČNE RIJEČI: algoritamska transparentnost, algoritamsko upravljanje, digitalna komunikacija, epistemološka poslušnost, sigurnosni imaginarij

UVOD

U suvremenom digitalnom okruženju, sigurnost više nije puki tehnički parametar, već društveno i komunikacijski konstruiran imaginarij koji prožima sve aspekte algoritamski posredovane komunikacije. Umjesto da djeluju kao neutralni tehnološki alati, algoritamski sustavi sve češće preuzimaju normativnu ulogu — odlučuju o relevantnosti, istinitosti i vidljivosti informacija, usmjeravaju pažnju korisnika i oblikuju društvenu stvarnost prema pravilima koja ostaju skrivena od javnosti (Beer, 2017; Burrell, 2016; Gillespie, 2014; Seaver, 2017). Upravo ta nevidljiva struktura upravljanja informacijama postaje središnja točka ovog rada. Polazna pretpostavka jest da se imaginarij sigurnosti u digitalnoj komunikaciji oblikuje na tri razine: diskurzivnoj, regulatornoj i algoritamskoj, a da je zajednički nazivnik tih razina epistemološki obrazac unutar kojega se u relevantnoj literaturi problematizira mogućnost da korisnici budu pozicionirani kao pasivniji primatelji algoritamski posredovanih informacija, uz ograničene mogućnosti uvida i kritičkog propitivanja (Ananny, 2016; Mittelstadt i sur.,2016; Binns i Veale, 2021).

Kako bi se ovaj fenomen precizno istražio, rad se oslanja na koncept epistemološke poslušnosti, razvijen u prethodnom teorijskom radu autora (Gombar, 2025a), koji podrazumijeva stanje u kojem korisnici prihvaćaju algoritamski posredovano znanje kao legitimno, iako nemaju pristup kriterijima njegove proizvodnje niti mogućnost nadzora (Ghasemaghaei i Kordzadeh, 2024; Burrell, 2016). U teorijskom okviru rada epistemološka poslušnost razmatra se kao moguća posljedica tehnološke opacitete, normativne ambivalentnosti i kognitivne prenatrpanosti korisnika; bibliometrijska analiza pritom ne omogućuje njezinu neposrednu empirijsku potvrdu (Floridi, 2023; Dencik i sur., 2019; Goodman i Flaxman, 2017).

U teorijskom smislu, koncept epistemološke poslušnosti, zajedno s povezanim pojmovima poput algoritamske epistemologije, algoritamskog upravljanja i kognitivne autonomije, ušao je u znanstvenu raspravu tek unazad desetak godina, ponajviše kroz kritičku literaturu o transparentnosti, UI regulaciji i digitalnom nadzoru (Floridi, 2023; Mittelstadt i sur., 2016; Rouvroy i Berns, 2013). Prije 2015. godine rijetki su radovi koji ove teme povezuju u širem komunikacijskom okviru, dok nakon te godine dolazi do naglog porasta relevantne literature, posebno u Scopus bazi. Taj teorijski pomak — od tehničke prema epistemološkoj analizi algoritama — predstavlja i osnovu za odabir vremenskog raspona bibliometrijske analize (2015–2026), kojim se obuhvaća aktualna znanstvena produkcija u razdoblju snažne konceptualne konsolidacije i institucionalizacije tih tema.

Zato se rad temelji na sljedećim istraživačkim pretpostavkama:

H1: U analiziranoj znanstvenoj literaturi teme algoritamskog upravljanja, transparentnosti, sigurnosti i odgovornosti zauzimaju istaknutije mjesto od tema korisničke autonomije, participacije i otpora.

H2: Pojmovi povezani s povjerenjem, transparentnošću, nadzorom, etikom umjetne inteligencije i algoritamskim upravljanjem oblikuju međusobno povezane tematske klastere unutar kojih se može teorijski razmatrati koncept epistemološke poslušnosti.

H3: Vremenska distribucija pojmova u analiziranom korpusu pokazuje pomicanje istraživačke pozornosti od pretežno tehničkih i sigurnosnih tema prema društvenim, etičkim i epistemološkim implikacijama algoritamskih sustava.

U metodološkom smislu bibliometrijska analiza koristi se za identifikaciju tematske fragmentiranosti, konceptualnih poveznica i normativne ambivalentnosti u znanstvenim pristupima sigurnosti, autonomiji, povjerenju i transparentnosti u digitalnoj komunikaciji. Budući da je predmet analize znanstvena produkcija, a ne neposredna iskustva ili ponašanja korisnika, nalazi se tumače kao pokazatelji načina na koje se u literaturi oblikuje diskurs o odnosu algoritamskog upravljanja, znanja i korisničke autonomije.

Polazeći od navedenih pretpostavki, primarni cilj ovog rada jest bibliometrijski istražiti kako se imaginarij sigurnosti gradi i stabilizira u znanstvenom diskursu o digitalnoj komunikaciji, pri čemu se osobita pažnja usmjerava na tematske odnose između sigurnosti, transparentnosti, povjerenja, nadzora i autonomije. U tom se okviru analizira kako suvremena literatura konceptualizira otpornost, autonomiju i transparentnost u odnosu na algo-

ritamsko upravljanje informacijama i digitalne odnose moći (Acquisti i sur., 2015; Eubanks, 2018; Tufekci, 2016).

Drugi važan cilj rada jest teorijski razmotriti okvir epistemološke poslušnosti, razvijen u prethodnom teorijskom radu autora (Gombar, 2025a), u odnosu na bibliometrijski identificirane tematske klastere. U ovom se radu epistemološka poslušnost ne tretira kao empirijski potvrđena karakteristika ponašanja korisnika, nego kao interpretativni koncept kojim se mogu povezati znanstveni diskursi o algoritamskim opacitetima, nadzoru, digitalnoj regulaciji i ograničenjima korisničke autonomije (Beer, 2017; Birhane, 2021; Rouvroy i Berns, 2013).

Treći cilj odnosi se na bibliometrijsku analizu znanstvene produkcije u području digitalne sigurnosti, transparentnosti, otpornosti i algoritamskog upravljanja. Cilj je mapirati tematska žarišta, konceptualne poveznice i epistemološke praznine u analiziranoj literaturi te utvrditi u kojoj mjeri suvremeni istraživački diskurs otvara prostor daljnjim empirijskim istraživanjima digitalne autonomije i epistemoloških posljedica algoritamski posredovane komunikacije (Rahwan i sur., 2019; Mittelstadt, 2019; Jungherr i Rauchfleisch, 2025).

Konačno, rad ima i proaktivnu dimenziju jer bibliometrijski identificirani obrasci pružaju teorijsku osnovu za razmatranje okvira „otpornosti kroz dizajn". Takav se okvir u ovom radu ne predstavlja kao empirijski potvrđen model, nego kao smjer daljnjeg teorijskog i empirijskog razvoja digitalnih okruženja koja bi mogla poduprijeti veću kognitivnu autonomiju korisnika i smanjiti njihovu izloženost manipulativnim algoritamskim praksama (Floridi, 2023; Moreno-Sánchez, Del Ser, van Gils, Hernesniemi, 2026).

Pitanje tko ima moć definiranja sigurnosti u digitalnom okruženju danas nadilazi tehničke i pravne domene – ono postaje epistemološko pitanje koje oblikuje granice znanja, participacije i otpora. Nove tehnologije, osobito algoritamski sustavi za preporuku, moderaciju i detekciju, sve češće preuzimaju ulogu nevidljivih regulatora komunikacije, oblikujući što jest, a što nije prihvatljivo, istinito ili relevantno (Gillespie, 2014; Goodman i Flaxman, 2017; Kellogg i sur., 2020). Iako se načela transparentnosti i odgovornosti često deklariraju u strateškim dokumentima i normativnim okruženjima (European Commission, 2022; UNESCO, 2018), njihova primjena ostaje fragmentirana, a u relevantnoj se literaturi problematizira mogućnost da korisnici budu pozicionirani kao pasivniji recipijenti algoritamski posredovanih informacija (Burrell, 2016; Glikson i Woolley, 2020).

Stoga se ovim istraživanjem odgovara na nedostatak integriranog pristupa koji bi povezao regulatorni tehnološki i komunikacijski aspekt imaginarija sigurnosti, ali i pružio teorijsko-metodološki alat za kritičku analizu epistemoloških učinaka algoritamskih sustava. Dok su prethodna istraživanja često usmjerena na pojedinačne učinke (npr. privatnost, pristranost, automatizacija), u ovom se radu pokušava sintetizirati složenija slika odnosa između moći, znanja i algoritamske kontrole (Ananny, 2016; Lyon, 2018; Zuboff, 2023).

Rad je strukturiran u četiri temeljna dijela. Prvo se razlaže teorijski okvir epistemološke poslušnosti, razvijen u ranijem teorijskom radu autora (Gombar, 2025a) te se prikazuje njegova primjena i relevantnost u kontekstu digitalne komunikacije. Drugo, prikazuju se metodološki pristupi, s naglaskom na bibliometrijsku analizu i tematsko mapiranje u Scopus bazi. Treće, predstavljaju se rezultati analize i rasprava o tematskim klasterima imaginarija sigurnosti koji vizualno mapiraju diskurzivne obrasce relevantne za teorijsko razmatranje epistemološke poslušnosti. Konačno, u četvrtom dijelu iznose se teorijske i praktične implikacije, uključujući i prijedlog modela otpornosti kroz dizajn.

METODOLOGIJA BIBLIOMETRIJSKE ANALIZE

Za potrebe ovog rada primijenjen je bibliometrijski pristup kao metoda za mapiranje konceptualnih, tematskih i regulatornih konfiguracija imaginarija sigurnosti u digitalnoj komunikaciji. Ova metoda omogućuje sustavno kvantificiranje i vizualizaciju obrazaca u znanstvenoj produkciji te identificiranje ključnih autora, pojmova, teorijskih pozicija i normativnih napetosti unutar kompleksnog i višedimenzionalnog područja koje uključuje sigurnost, transparentnost, algoritamsko upravljanje i digitalnu otpornost.

Bibliometrijska analiza osobito je pogodna kada se želi istražiti razvoj diskursa u specifičnom znanstvenom području kroz vrijeme, otkriti tematske klastere te detektirati strukture citiranja koje ukazuju na epistemološke

autoritete ili normativne tendencije (Ananny, 2016; Glikson i Woolley, 2020; Mittelstadt i sur.,2016). U kontekstu suvremene digitalne komunikacije, bibliometrijske metode mogu pomoći u razumijevanju kako se sigurnost konceptualizira, kojim narativima se privilegira nadzor ili autonomiju korisnika te kako algoritamski sustavi postaju normativni alati (Beer, 2017; Rahwan i sur.,2019).

Analiza je provedena na korpusu znanstvenih publikacija prikupljenih iz baze Scopus. Baza Scopus odabrana je zbog svoje multidisciplinarne pokrivenosti i primjenjivosti u bibliometrijskom mapiranju literature iz područja komunikologije, društvenih znanosti i studija digitalnih tehnologija. Odabir korpusa proveden je pretragom naslova, sažetaka i ključnih riječi publikacija u polju TITLE-ABS-KEY, uporabom pojmova koji proizlaze iz istraživačkog problema rada: „algorithmic governance", „automated decision-making", „algorithmic transparency", „AI ethics", „surveillance", „digital security", „trust", „epistemology" i „digital autonomy". Navedeni pojmovi odabrani su jer obuhvaćaju regulatornu, sigurnosnu, komunikacijsku i epistemološku dimenziju algoritamski posredovanih digitalnih okruženja koje rad istražuje.

Pretraga je ograničena na publikacije objavljene na engleskom jeziku te na vrste dokumenata „article" i „conference paper", odnosno znanstvene članke i konferencijske radove. Iz analize su time isključene publikacije na drugim jezicima te druge vrste dokumenata, poput knjiga, poglavlja u knjigama i uredničkih priloga. Vremenski raspon analize ograničen je na razdoblje od 2015. do 2026. godine. Početna godina odabrana je s obzirom na intenziviranje znanstvene produkcije o algoritamskoj transparentnosti, etici umjetne inteligencije, algoritamskom upravljanju i digitalnoj autonomiji nakon 2015. godine, odnosno na razdoblje u kojem se navedene teme sve izraženije povezuju u širem komunikacijskom i epistemološkom okviru.

Podaci su preuzeti 2. siječnja 2026. godine, a u analizu su uključene i publikacije iz 2026. godine koje je Scopus do datuma izvoza već evidentirao u bazi. Stoga raspon 2015. – 2026. ne označava cjelokupnu znanstvenu produkciju tijekom 2026. godine, nego korpus dostupan u bazi na dan preuzimanja podataka. Primjenom navedenih kriterija pretraživanja i uključivanja dobiven je konačni korpus od 517 dokumenata, koji čini osnovu bibliometrijskih analiza provedenih u radu. Radi analitičke konzistentnosti i semantičke usporedivosti pojmova, u obradi ključnih riječi primijenjen je standardizirani skup terminoloških zamjena (thesaurus) u programu VOSviewer. Svrha thesaurusa bila je objediniti izraze koji označavaju isti ili neposredno usporediv analitički koncept, uz očuvanje razlika između teorijski relevantnih kategorija. Tako su izrazi „algorithmic governance" i „algorithmic control" objedinjeni pod kategoriju „Algorithmic governance"; „automated decision-making", „automated decisions" i „algorithmic decision-making" pod kategoriju „Automated decision-making"; „algorithmic transparency", „AI transparency" i „transparency of algorithms" pod kategoriju „Algorithmic transparency"; a „trust", „user trust", „trust in AI" i „trust in algorithms" pod kategoriju „Trust".

Na isti su način izrazi „digital security", „cybersecurity" i „information security" objedinjeni pod kategoriju „Digital security"; „digital autonomy", „user autonomy" i „human autonomy" pod kategoriju „Digital autonomy"; „surveillance", „algorithmic surveillance" i „data surveillance" pod kategoriju „Surveillance"; „algorithmic systems", „AI systems" i „machine learning" pod kategoriju „Algorithmic systems"; dok su izrazi „human-AI interaction", „human–AI collaboration" i „human computer interaction" objedinjeni pod kategoriju „Human–AI interaction". Posebno su zadržane kategorije „Epistemology" i „AI ethics", kako bi se u mrežnoj analizi mogla pratiti njihova povezanost s pitanjima transparentnosti, sigurnosti, povjerenja i autonomije.

Primjena thesaurusa nije služila proširivanju korpusa niti selekciji publikacija, nego isključivo semantičkoj normalizaciji ključnih riječi u analizama suučestalosti. Time je smanjena terminološka raspršenost pojmova i omogućena konzistentnija interpretacija tematskih odnosa u analiziranoj znanstvenoj produkciji.

U drugoj fazi analize korišten je VOSviewer kao alat za bibliometrijsku vizualizaciju i mrežnu analizu. Provedene su analize suučestalosti svih ključnih riječi, suučestalosti autorovih ključnih riječi, suučestalosti indeksiranih ključnih riječi, suautorstva među državama te bibliografske povezanosti dokumenata i država. Pragovi uključivanja prikazani su uz pojedine vizualizacije u poglavlju Rezultati. Tako dobivene mreže omogućuju mapiranje tematskih struktura, vremenskih pomaka i bibliografskih poveznica unutar analizirane znanstvene produkcije.

Uz mrežne analize, provedena je i deskriptivna analiza citiranosti dokumenata uključenih u korpus, pri čemu je Tablica 1. izrađena rangiranjem publikacija prema vrijednostima u stupcu „Cited by" u pohranjenom izvozu rezultata iz baze Scopus. Za razliku od Tablice 1., koja prikazuje citiranost pojedinih dokumenata unutar analiziranog korpusa, Slika 5. prikazuje njihovu bibliografsku povezanost na temelju zajedničkih referenci.

Na temelju tih mreža generirane su tematske razdiobe koje omogućuju identifikaciju dominantnih diskurzivnih okvira, teorijskih žarišta i normativnih tenzija u literaturi o digitalnoj sigurnosti, transparentnosti i algoritamskoj komunikaciji. Kao ključne jedinice analize promatrani su pojmovi digitalna otpornost, algoritamska transparentnost, imaginarij sigurnosti, epistemološka poslušnost i interakcija čovjeka i algoritma, koji su prethodno identificirani kao temeljni teorijski koncepti u suvremenim analizama algoritamske komunikacije (Ghasemaghaei i Kordzadeh, 2024; Binns i Veale, 2021; Seaver, 2017). Svrha ovakvog metodološkog pristupa jest izgradnja analitičkog temelja za interpretaciju normativnih proturječja unutar znanstvenog diskursa o algoritamski strukturiranim okruženjima. U tom smislu, bibliometrija se koristi za mapiranje konceptualnih obrazaca u literaturi, dok se epistemološka poslušnost razmatra kao teorijski interpretativni okvir, a ne kao empirijski potvrđen učinak na korisnike.

REZULTATI

Dobiveni rezultati bibliometrijske analize omogućuju višerazinsko mapiranje znanstvene produkcije u području algoritamske sigurnosti, pri čemu se otkrivaju semantičke osovine, diskurzivni klasteri i teorijske orijentacije koje strukturiraju suvremenu raspravu. U fokusu analize nalaze se obrasci učestalosti i povezanosti pojmova te bibliografske strukture koje omogućuju opreznu teorijsku interpretaciju načina na koji se u analiziranoj literaturi povezuju pitanja moći, znanja i normativne kontrole u digitalnim okruženjima. Svaka od prikazanih vizualizacija (Slike 1.–6.) te Tablica 1. pridonosi toj slici iz različite analitičke perspektive — od tematske suučestalosti ključnih pojmova, preko dinamike autorskih intencija, do globalnih obrazaca znanstvene suradnje i teorijskog ukotvljenja. Kroz tu višedimenzionalnu analizu razmatraju se početne hipoteze rada: zastupljenost regulatorno-sigurnosnih u odnosu na autonomijske i participativne teme (H1), povezanost tematskih klastera relevantnih za teorijsko razmatranje epistemološke poslušnosti (H2) te vremenski pomak prema društvenim, etičkim i epistemološkim implikacijama algoritamskih sustava (H3).

Ova razina analize posebno je relevantna za razmatranje hipoteze H1 o izraženijoj zastupljenosti regulatorno-sigurnosnih tema u odnosu na teme autonomije, participacije i otpora.

Prva vizualizacija proizlazi iz suučestalosti svih ključnih riječi i omogućuje uvid u semantičke osovine koje strukturiraju znanstvenu produkciju u ovom polju.

Slika 1. Vizualizacija ključnih pojmova prema učestalosti (Co-occurrence – All keywords, min. 4, N=233)

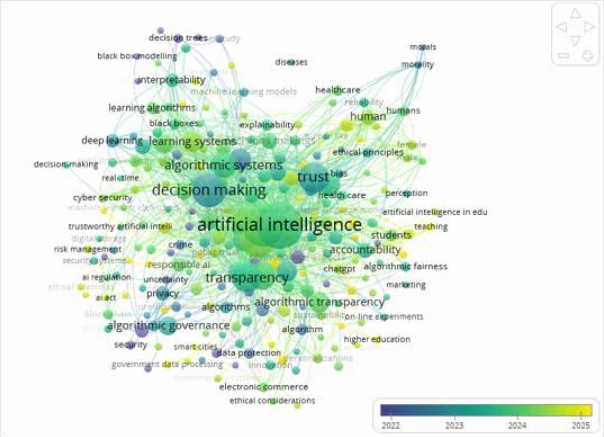

Slika 1. prikazuje mrežu tematskih klastera generiranu bibliometrijskom metodom suučestalosti ključnih riječi (co-occurrence), pri čemu su analizirani svi autorovi i indeksirani pojmovi iz korpusa od 517 znanstvenih radova, uz prag minimalne pojavnosti od četiri (N=233). Vizualizacija je prikazana u vremenskoj dimenziji (overlay visualization), što omogućuje praćenje promjene tematskih žarišta kroz razdoblje od 2015. do 2026. godine. U središtu mreže dominira pojam „artificial intelligence", koji funkcionira kao semantička osovina oko koje se granaju tri prepoznatljiva klastera. Prvi tehnološko-sistemski klaster, obuhvaća pojmove poput „algorithmic systems", „learning algorithms", „deep learning", „explainability" i „machine learning models", čime se označava tehnički okvir razvoja algoritamske infrastrukture i modela odlučivanja. Drugi, normativno-regulacijski klaster, strukturiran je oko pojmova poput „algorithmic governance", „transparency", „data protection", „privacy", „security" i „accountability" te označava imaginarij u kojem se algoritamsko upravljanje razmatra kroz etičke, pravne i političke dimenzije. Treći klaster, usmjeren na

korisničke i epistemološke aspekte, uključuje pojmove „trust“, „epistemology“, „autonomy“, „human“ i „ethical principles“ te tematizira odnos povjerenja, pouzdanosti i spoznajnih ograničenja u interakciji čovjeka s algoritamskim sustavima. Zanimljivo je primijetiti da pojam “artificial intelligence” ne funkcionira samo kao tematski označitelj, već i kao diskurzivni most između tehničkih i epistemoloških tema, što upućuje na sve veću integraciju tehno-etičkih diskursa u znanstvenom polju.

Temporalna distribucija pojmova u mreži upućuje na vremenski pomak istraživačke pozornosti: dok su raniji radovi (2017–2020) koncentrirani oko tehničkih i sigurnosnih aspekata, noviji radovi (2022–2025) sve više ističu dimenzije autonomije, epistemologije i etike. Takav obrazac upućuje na H3, odnosno na pomicanje istraživačkog fokusa prema društvenim, etičkim i epistemološkim implikacijama algoritamskih sustava. Istodobno, razdvajanje tehnoloških, regulatornih i epistemoloških tematskih smjerova pruža osnovu za daljnje teorijsko razmatranje imaginarija sigurnosti. Kako bi se dodatno osnažila interpretacija semantičkih smjerova, analizirani su i isključivo autorski definirani ključni pojmovi, koji često reflektiraju subjektivne intencije istraživača i aktualne istraživačke trendove.

Slika 2. Vizualizacija autorovih ključnih pojmova prema suučestalosti (Co-occurrence – Author keywords, min. 2, N = 266)

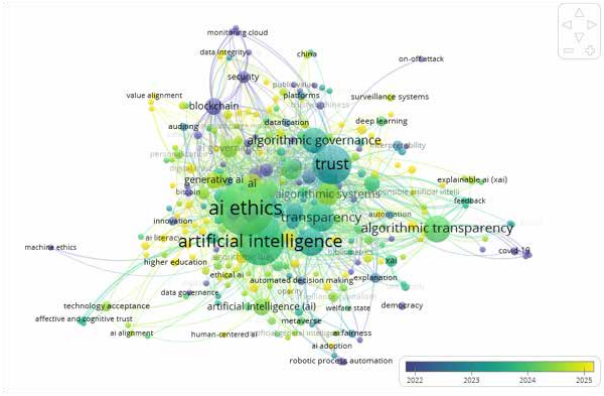

Slika prikazuje mrežnu vizualizaciju temeljenu na analizi suučestalosti autorovih ključnih riječi u korpusu od 517 radova, uz prag minimalne pojavnosti od dva pojavljivanja (N = 266). Vizualizacija je prikazana u vremenskom sloju (overlay visualization), pri čemu boja označava prosječnu godinu objave za svaki pojam. U središtu mreže ističu se pojmovi „artificial intelligence“, „AI ethics“, „trust“, „algorithmic governance“, „transparency“ i „algorithmic transparency“, koji čine jezgru tematskog polja. Njihova međusobna povezanost ukazuje na snažnu normativnu orijentaciju recentnih istraživanja, u kojima se etika umjetne inteligencije, povjerenje korisnika i regulacija algoritamskih sustava nalaze u žarištu znanstvenog interesa. Pojam „algorithmic governance“ povezuje se s izrazima poput „datafication“, „public value“, „platforms“, „data governance“ i „policy“, što ukazuje na stabilnu regulatornu osovinu unutar imaginarija sigurnosti. U bliskoj povezanosti pojavljuju se i pojmovi „responsible artificial intelligence“, „algorithmic bias“ i „accountability“, što upućuje na rastuću zabrinutost za etičke standarde i odgovornost u digitalnim sustavima odlučivanja. Temporalna komponenta karte pokazuje da se najnoviji istraživački interesi (žuto) kreću prema temama poput „generative AI“, „value alignment“, „AI adoption“, „affective and cognitive trust“, kao i prema pojavama poput „metaverse“, „surveillance systems“ i „COVID-19“, čime se potvrđuje dinamika pomicanja istraživačkog fokusa od tehničkih prema društvenim i epistemološkim aspektima.

Pojavljivanje izraza poput „cognitive trust“, „AI literacy“ i „explainable AI (XAI)“ upućuje na to da se u recentnoj literaturi pitanja povjerenja, razumljivosti sustava i korisničke autonomije sve češće povezuju s etičkim i regulatornim raspravama o algoritamskim sustavima. Takva tematska povezanost podupire H2, prema kojoj se koncept epistemološke poslušnosti može teorijski razmatrati unutar klastera oblikovanih oko povjerenja, transparentnosti, etike umjetne inteligencije i algoritamskog upravljanja.

Slika 3. Vizualizacija indeksiranih ključnih pojmova (Co-occurrence – Indexed keywords, min. 3, N = 280)

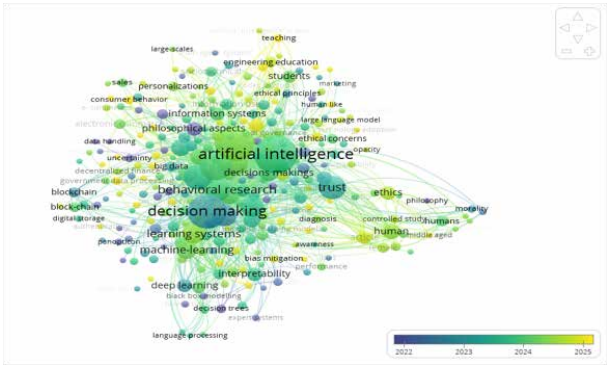

Slika prikazuje semantičku mrežu indeksiranih ključnih pojmova generiranu analizom suučestalosti (co-occurrence) u alatu VOSviewer, uz minimalni prag od tri pojavljivanja i ukupno 280 odabranih pojmova. U središtu karte ističu se izrazi „artificial intelligence“, „decision making“, „behavioral research“, „trust“ i „ethics“, koji

zajedno oblikuju diskurzivni temelj suvremenog znanstvenog polja na sjecištu umjetne inteligencije, odlučivanja i normativnih napetosti. Vizualizacija jasno strukturira tri dominantna tematska klastera: tehnološko-analitički (lijevi dio mreže), normativno-etički (desni dio mreže) i primijenjeno-bihevioralni (centralni dio). Posebno je indikativna koncentracija pojmova „morality", „philosophy", „humans" i „awareness" u perifernom klasteru, koji otvara prostor za interpretaciju epistemološke i etičke ranjivosti korisnika unutar algoritamski strukturiranih okruženja. Temporalna gradacija pokazuje pomak prema temama „engineering education", „value alignment", „ai ethics" i „large language model", što ukazuje na aktualizaciju pitanja odgovornosti i razumljivosti UI sustava.

Ova vizualizacija dopunjuje prethodne analize autorovih ključnih pojmova i omogućuje uvid u to kako znanstvena baza (npr. Scopus) konceptualno strukturira diskurs o umjetnoj inteligenciji, odlučivanju i sigurnosno-etičkim izazovima. Analiza suautorstava među državama dodatno omogućuje uvid u međunarodnu distribuciju istraživačke suradnje unutar analiziranog korpusa. Premda pojam „epistemological obedience" nije izravno prisutan kao ključna riječ, povezani izrazi u periferiji mreže, poput „morality", „awareness" i „AI ethics", ukazuju na konceptualnu prisutnost etičkih i epistemoloških pitanja u analiziranoj literaturi te dodatno podupiru teorijsko razmatranje H2.

Slika 4. Vizualizacija međunarodne znanstvene suradnje (Co-authorship – Countries, min. 1, N = 66)

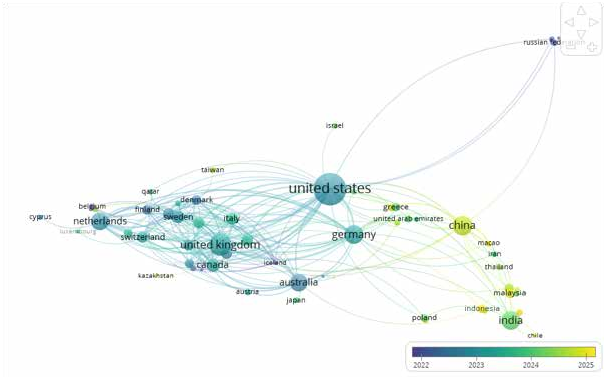

Slika prikazuje mrežu znanstvene suradnje između država u analiziranom korpusu temeljenu na metodi suautorstava (co-authorship) s minimalno jednom pojavom po zemlji (N = 66). Veličina čvora proporcionalna je broju publikacija, dok debljina veze označava intenzitet međudržavne znanstvene suradnje. Boja čvora odgovara prosječnoj godini publikacije, što omogućuje uvid u temporalnu dinamiku istraživačke aktivnosti. U središtu mreže ističu se Sjedinjene Američke Države, Ujedinjeno Kraljevstvo, Njemačka, Kanada i Nizozemska kao glavni nositelji znanstvene produkcije i transnacionalne suradnje u području algoritamske regulacije, umjetne inteligencije i digitalne sigurnosti. Vidljiva je jaka povezanost unutar tzv. "transatlantske jezgre" (SAD–UK–Njemačka–Nizozemska–Kanada), koja u analiziranom korpusu pokazuje visoku razinu međusobne istraživačke povezanosti. Pojavljuju se i periferni, ali rastući klasteri država s recentnijom aktivnošću, poput Indije, Kine, Malezije i Irana, što ukazuje na sve veću globalizaciju diskursa i ulazak novih aktera u znanstvenu produkciju povezanu s digitalnim nadzorom, etikom umjetne inteligencije i tehnološkim imaginarijima. Temporalna komponenta pokazuje recentniju zastupljenost pojedinih azijskih i bliskoistočnih država u analiziranom korpusu, bez izvođenja zaključaka o širim uzrocima ili posljedicama toga obrasca. Dok prethodne vizualizacije ukazuju na tematske i diskurzivne obrasce, analiza bibliografske povezanosti omogućuje mapiranje dubljih teorijskih linija koje povezuju ključne autore i koncepte.

Slika 5. Vizualizacija dokumenata prema bibliografskoj povezanosti (Bibliographic coupling – Documents, min. 1, N = 312)

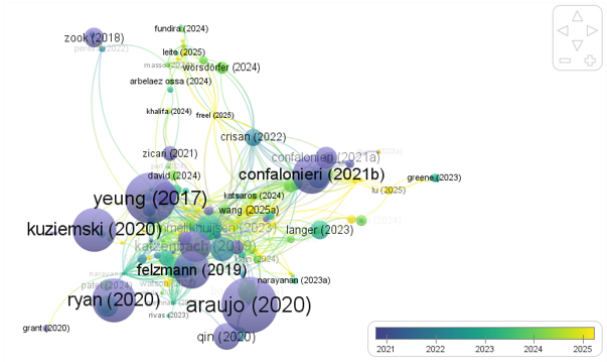

Vizualizacija prikazuje strukturu međusobno povezanih znanstvenih radova temeljem metode bibliografske povezanosti, pri čemu su radovi povezani kada dijele zajedničke izvore citiranja. U mrežu je uključeno ukupno 312 dokumenata s najmanje jednom poveznicom. Pomoću ove analize moguće je identificirati klastere koji dijele slične teorijske temelje i epistemološke pretpostavke, neovisno o tome jesu li autori međusobno povezani izravnim citiranjem. U središtu mreže ističu se radovi Yeunga (2017), Kuziemskog (2020), Arauja (2020), Felzmanna (2019), Ryana (2020), ali i Confalonierija i sur. (2021), koji svi zajedno čine jezgru znanstvene produk-

cije u području regulacije algoritamskog odlučivanja, povjerenja i transparentnosti. Ovi dokumenti čine glavne oslonce bibliografske povezanosti, što upućuje na snažnu koncentraciju normativne i etičke literature. Povezanost između radova koji analiziraju ljudsku autonomiju, nadzor i regulatorne napetosti potvrđena je i prisutnošću referenci koje su identificirane kao teorijska sidra, poput Anannyja (2016), Beera (2017), Mittelstadta i sur. (2016), Burrella (2016), Ghasemaghaeija i Kordzadeha (2024), Dencika i sur. (2019) te Binnsa i Vealea (2021). Na mreži se također prepoznaje pozicija autora koji tematiziraju algoritamsku poslušnost, epistemološke učinke nadzora i normativne modele transparentnosti, poput Rahwana i sur. (2019), Zuboff (2023), Eubanks (2018), Acquistija i sur. (2015) te Rudina (2019). Pojavljivanje recentnijih radova, kao što su Bankins i Formosa (2023), Jungherr i Rauchfleisch (2025) ili Moreno-Sánchez i sur. (2026), upućuje na intenziviranje istraživačke dinamike u razdoblju 2022–2025, s tendencijom proširivanja epistemološkog okvira prema etici rada, deliberativnoj nejednakosti i operativnim modelima povjerenja. Bibliografska mreža time prikazuje strukture citatne sličnosti među dokumentima te omogućuje teorijsku interpretaciju tematskih i normativnih obrazaca prisutnih u analiziranoj literaturi o algoritamskoj sigurnosti, transparentnosti i povjerenju.

Tablica 1. Deset najcitiranijih dokumenata u analiziranom korpusu prema podacima baze Scopus

Br.	Autori	Naslov	Godina	Broj citata	Izvor
1	Araujo, T., Helberger, N., Kruikemeier, S., & de Vreese, C. H.	*In AI we trust? Perceptions about automated decision-making by artificial intelligence*	2020	693	AI & Society, 35(3), 611–623
2	Yeung, K.	*'Hypernudge': Big Data as a mode of regulation by design*	2017	558	Information, communication and
3	Kuziemski, M., & Misuraca, G.	*AI governance in the public sector: Three tales from the frontiers of automated decision-making in democratic settings*	2020	424	Telecommunications Policy, 44(6), 101976
4	Ryan, M.	*In AI We Trust: Ethics, Artificial Intelligence, and Reliability*	2020	417	Science and Engineering Ethics, 26(5), 2749–2767
5	Confalonieri, R., Coba, L., Wagner, B., & Besold, T. R.	*A historical perspective of explainable Artificial Intelligence*	2021	323	Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 11(1), e1391

6	Felzmann, H., Fosch-Villaronga, E. F., Lutz, C., & Tamò-Larrieux, A.	*Transparency you can trust: Transparency requirements for artificial intelligence between legal norms and contextual concerns*	2019	301	Big Data & Society, 6(1)
7	Katzenbach, C., & Ulbricht, L.	*Algorithmic governance*	2019	215	Internet Policy Review, 8(4)
8	Qin, F., Li, K., & Yan, J.	*Understanding user trust in artificial intelligence-based educational systems: Evidence from China*	2020	155	British Journal of Educational Technology, 51(5), 1693–1710
9	Grimmelikhuijsen, S. G.	*Explaining Why the Computer Says No: Algorithmic Transparency Affects the Perceived Trustworthiness of Automated Decision-Making*	2023	134	Public Administration Review, 83(2), 241–262
10	Angerschmid, A., Zhou, J., Theuermann, K., Chen, F., & Holzinger, A.	*Fairness and Explanation in AI-Informed Decision Making*	2022	132	Machine Learning and Knowledge Extraction, 4(2), 556–579

Tablica 1. prikazuje deset najcitiranijih dokumenata iz analiziranog korpusa od 517 publikacija, prema podacima sadržanima u izvozu rezultata iz baze Scopus. Najcitiraniji dokumenti u korpusu usmjereni su na povjerenje u umjetnu inteligenciju i automatizirano odlučivanje, algoritamsko upravljanje, transparentnost, objašnjivost te etičku i institucionalnu odgovornost algoritamskih sustava. Najveći broj citata ostvaruje rad Arauja i sur. (2020), koji istražuje percepcije automatiziranog odlučivanja i povjerenja u umjetnu inteligenciju, nakon čega slijede Yeung (2017), s analizom algoritamskog usmjeravanja kao oblika regulacije, te Kuziemski i Misuraca (2020), koji tematiziraju upravljanje umjetnom inteligencijom u javnom sektoru.

Među najcitiranijim dokumentima ističu se i radovi koji povezuju pouzdanost, transparentnost i etiku umjetne inteligencije: Ryan (2020) razmatra odnos povjerenja, etike i pouzdanosti UI sustava, Confalonieri i sur. (2021) problematiziraju razvoj objašnjive umjetne inteligencije, dok Felzmann i sur. (2019) analiziraju zahtjeve transparentnosti između pravnih normi i kontekstualnih očekivanja. U istom se tematskom prostoru nalaze radovi Katzenbacha i Ulbrichta (2019) o algoritamskom upravljanju, Qina i sur. (2020) o povjerenju korisnika u sustave utemeljene na umjetnoj inteligenciji, Grimmelikhuijsena (2023) o odnosu algoritamske transparentnosti i percipirane vjerodostojnosti automatiziranog odlučivanja te Angerschmida i sur. (2022) o pravednosti i objašnjenjima u odlučivanju potpomognutom umjetnom inteligencijom.

Struktura najcitiranijih dokumenata pokazuje da su povjerenje, transparentnost, objašnjivost, odgovornost i algoritamsko upravljanje središnje teme analizirane znanstvene produkcije. Taj bibliometrijski nalaz korespondira s teorijskim okvirom rada, u kojem se algoritamski opaciteti i transparentnost razmatraju kroz radove Burrell

(2016) i Rudin (2019), etičke i regulatorne implikacije algoritamskog odlučivanja kroz Mittelstadt i sur. (2016) te Goodman i Flaxman (2017), a širi odnosi nadzora, nejednakosti i algoritamske moći kroz Eubanks (2018), Zuboff (2023), Rahwan i sur. (2019) te Lyon (2018). Navedeni teorijski izvori ne predstavljaju dokumente rangirane u Tablici 1., nego služe kao interpretativna uporišta za razumijevanje tematskih obrazaca utvrđenih bibliometrijskom analizom.

Pri tome citiranost dokumenata u analiziranom korpusu ne dokazuje neposredne učinke algoritamskih sustava na ponašanje korisnika niti empirijski potvrđuje koncept epistemološke poslušnosti. Ona pokazuje koje su istraživačke teme i teorijski problemi unutar analizirane znanstvene produkcije ostvarili najveću vidljivost i utjecaj. U tom smislu, Tablica 1. pruža empirijsku osnovu za interpretaciju dominantnih istraživačkih usmjerenja u literaturi, dok se epistemološka poslušnost u ovom radu razmatra kao teorijski okvir za povezivanje rasprava o povjerenju, transparentnosti, sigurnosti, nadzoru i autonomiji.

Na temelju bibliografske povezanosti među dokumentima prikazane na Slici 5. moguće je dodatno razmotriti teorijske orijentacije koje strukturiraju znanstvenu produkciju o algoritamskom odlučivanju, etici umjetne inteligencije i digitalnoj sigurnosti. Za razliku od Tablice 1., koja prikazuje najcitiranije dokumente u korpusu, Slika 5. prikazuje mrežnu povezanost dokumenata na temelju zajedničkih referenci. Te se dvije analitičke perspektive međusobno dopunjuju: citiranost upućuje na vidljivost pojedinih dokumenata, dok bibliografska povezanost omogućuje identifikaciju tematskih i teorijskih skupina unutar analizirane literature. U mreži se izdvajaju četiri teorijska klastera, od kojih svaki odražava specifičan pristup analizi moći, znanja i normativnosti u digitalno strukturiranim komunikacijskim okruženjima:

Teorijski klasteri u bibliografskoj mreži

Identifikacija ovih teorijskih klastera omogućuje ne samo analizu tematskih interesa, već i dublje razumijevanje kako se konstruira normativni okvir znanja u algoritamskim sustavima — što je središnje pitanje epistemološke poslušnosti.

Na temelju bibliografske povezanosti i teorijske interpretacije mreže izdvojena su četiri tematsko-teorijska klastera:

Klaster 1 – Normativno-regulacijski okvir algoritama

Obuhvaća radove koji se bave pravnim, političkim i regulatornim aspektima algoritamskog odlučivanja i upravljanja. Dominantne reference uključuju: Binns i Veale (2021), Goodman i Flaxman (2017), Kamara i Kosta (2016), European Commission (2022) te Ghasemaghaei i Kordzadeh (2024). Ovaj klaster otkriva pokušaje konceptualnog mapiranja pravne odgovornosti i institucionalne kontrole algoritama.

Klaster 2 – Epistemologija povjerenja i ljudske autonomije

U fokusu su pojmovi poput povjerenja, autonomije i korisničke ranjivosti u odnosu na algoritamske sustave. U ovaj klaster ulaze radovi Gliksona i Woolleya (2020), Dietvorsta i sur. (2015), Mittelstadta i sur. (2016), Floridija (2023) i Acquistija i sur. (2015). Ovaj se klaster temelji na interdisciplinarnom uvidu u granice spoznaje, donošenja odluka i percepcije pouzdanosti umjetne inteligencije.

Klaster 3 – Algoritamska nepravda, automatizacija i etika odlučivanja

Središnji autori i radovi u ovom klasteru su Birhane (2021), Eubanks (2018), Rudin (2019), Bankins i Formosa (2023) te Zuboff (2023). Ovdje se promatraju nejednakosti, strukturne posljedice algoritamske kontrole i etički izazovi u kontekstu rada, nadzora i prediktivnih tehnologija.

Klaster 4 – Infrastruktura nadzora i imaginarij sigurnosti

Ovaj klaster okuplja literaturu koja razmatra kulturne i komunikacijske posljedice digitalnog nadzora, kao i medijske konstrukcije sigurnosti. Obuhvaća autore kao što su Ananny (2016), Beer (2017), Bigo (2002), Lyon (2001, 2018), Hall (1982), Tufekci (2016) i Rouvroy i Berns (2013). U ovom klasteru dominira pristup imaginariju sigurnosti kroz prizmu epistemološke poslušnosti i algoritamske moći.

Slika 6. Vizualizacija država prema bibliografskoj povezanosti (Bibliographic coupling – Countries, min. 1, N = 66)

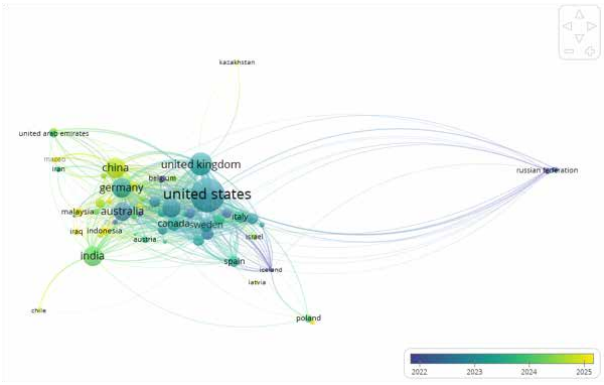

Vizualizacija prikazuje znanstvenu povezanost država temeljem bibliografske povezanosti (bibliographic coupling), pri čemu su države povezane ako njihovi znanstvenici citiraju slične izvore. U analizu je uključeno 66 zemalja s najmanje jednom poveznicom, a mreža je prikazana s vremenskom dimenzijom koja pokazuje prosječnu godinu objave. Središte mreže čini tzv. „transatlantski klaster“ (SAD–UK–Njemačka–Kanada–Australija), unutar kojeg je prisutna gusta mreža međusobne povezanosti temeljene na zajedničkoj znanstvenoj infrastrukturi i teorijskim orijentacijama. Klaster obuhvaća i većinu europskih zemalja, uključujući Švedsku, Belgiju, Italiju i Nizozemsku, koje dijele dominantne autore i izvore iz područja etike umjetne inteligencije, algoritamskog upravljanja i digitalne sigurnosti. Međutim, u vizualizaciji se Ruska Federacija pojavljuje izvan središnje mreže, s ograničenim brojem poveznica prema transatlantskom klasteru. Takav položaj upućuje na nižu bibliografsku povezanost s dominantnim korpusom analizirane literature, ali sam po sebi ne omogućuje zaključivanje o uzrocima toga obrasca. Moguća objašnjenja, poput geopolitičkih okolnosti, jezičnih barijera ili različitih publikacijskih strategija, zahtijevala bi dodatnu analizu izvan dosega ovog rada. Nalaz stoga pokazuje postojanje različitih obrazaca bibliografske povezanosti među državama u istraživačkom polju digitalne sigurnosti i algoritamskog upravljanja.

Sinteza četiriju teorijskih klastera pruža višedimenzionalni uvid u normativne, epistemološke i regulatorne napetosti koje se u analiziranoj literaturi povezuju s imaginarijem sigurnosti. Time se dodatno podupire H2, odnosno mogućnost teorijskog razmatranja epistemološke poslušnosti na temelju povezanosti diskursa o povjerenju, transparentnosti, nadzoru, etici umjetne inteligencije i algoritamskom upravljanju.

RASPRAVA

Bibliometrijski nalazi pokazuju da se u analiziranoj literaturi sigurnost povezuje s transparentnošću, povjerenjem, nadzorom, autonomijom i algoritamskim upravljanjem. Takva struktura diskursa omogućuje teorijsko razmatranje sigurnosti kao sociotehničkog i epistemološkog pitanja, a ne samo kao tehničke zaštite sustava. U tom je smislu relevantan Foucaultov (2007) uvid da se sigurnost uspostavlja kroz diskurse i prakse nadzora koje legitimiraju intervenciju, kao i Baumanovo (2000) razumijevanje sigurnosti kao nestabilne i trajno pregovarane vrijednosti. U digitalnim okruženjima algoritamski se sustavi u tom interpretativnom okviru mogu promatrati kao mehanizmi koji strukturiraju vidljivost i dostupnost informacija. Ovaj se teorijski pravac nadovezuje na pojam algoritamske volje (Gombar, 2025b), ali rezultati rada ne dokazuju njezine učinke na korisnike.

U odnosu na H2, povezanost pojmova povjerenja, transparentnosti, objašnjivosti i algoritamskog upravljanja podupire teorijsko razmatranje epistemološke poslušnosti kao pitanja ograničene razumljivosti posredovanoga znanja. Mittelstadt (2019) pokazuje da etička načela bez institucionalne provedbe i ugradnje u dizajn mogu ostati simbolička. Važnost transparentnosti i odgovornosti za procjenu algoritamskog odlučivanja ističu i Mittelstadt i sur. (2016). U širem komunikacijskom smislu, Blumler i Gurevitch (1995) upozoravali su na asimetrije javne komunikacije i prije digitalnih platformi. Ti uvidi služe interpretaciji bibliometrijskih klastera, a ne tvrdnji da su korisnici empirijski pokazali epistemološku poslušnost.

Praktična implikacija takve interpretacije odnosi se na digitalnu pismenost i „otpornost kroz dizajn”. Nacionalna razvojna strategija Republike Hrvatske do 2030. godine (2021) naglašava digitalnu transformaciju i sigurnost, dok pitanje epistemološke autonomije otvara potrebu za dodatnim istraživanjima. Moreno-Sánchez i sur. (2026) pouzdanu umjetnu inteligenciju povezuju s objašnjivošću, transparentnošću i mogućnošću korisničke intervencije. U ovom se radu te perspektive ne predstavljaju kao empirijski potvrđen model, nego kao smjer budućih istraživanja.

Hrvatski kontekst omogućuje dodatnu teorijsku kontekstualizaciju utvrđenih obrazaca. Bilić (2012) pokazuje da su procesi digitalizacije i institucionalne kontrole djelovali unutar medijskog sustava i prije recentnih algoritamskih sustava, dok Peruško (2003) upozorava na odnos medijske koncentracije i ograničenog pluralizma. Thompson (2000) naglašava važnost vidljivosti i normativnih očekivanja publike u medijski posredovanom javnom prostoru. Ti izvori omogućuju interpretaciju odnosa transparentnosti, povjerenja i algoritamskog upravljanja, ali ne i zaključak o ponašanju korisnika u hrvatskom digitalnom prostoru.

Povijesno-institucionalni okvir dodatno se razmatra kroz potvrđene izvore o pluralizmu, medijskoj koncentraciji i institucionalnim promjenama hrvatskog medijskog sustava (Bilić, 2012; Peruško, 2003; 2006). Europski regulatorni okvir, osobito Direktiva 2007/65/EZ (European Parliament and Council, 2007), dokumenti Vijeća za elektroničke medije (2008) te izvješća Europske komisije (2006), relevantni su za razumijevanje normativnog okruženja u kojem se pitanja pluralizma, odgovornosti i sigurnosti artikuliraju. Zgrabljić Rotar (2003) te Skoko i Bajs (2007) upućuju na ranije probleme manipulacije i ograničavanja pluralističke debate, dok Bebić (2023) analizira domaće diskurse o umjetnoj inteligenciji i percepciji njezine neutralnosti. UNESCO-ov (2008) okvir razvoja medija pritom naglašava sposobnost građana da preispituju dostupne izvore znanja. Navedeni izvori pružaju lokalni teorijski kontekst bibliometrijskim nalazima, a ne dokaz algoritamski proizvedene pasivizacije.

U cjelini, H1 se razmatra na temelju izraženije zastupljenosti regulatorno-sigurnosnih tema u odnosu na teme autonomije, participacije i otpora, dok se H2 odnosi na povezanost klastera povjerenja, transparentnosti, etike i algoritamskog upravljanja. U tom je smislu relevantna Zuboffina (2023) interpretacija podatkovnih i prediktivnih tehnologija kao izvora asimetrije moći i znanja. Međutim, bibliometrijski rezultati ne potvrđuju modifikaciju ponašanja korisnika ni epistemološku poslušnost kao empirijsku činjenicu. Oni pokazuju da analizirana znanstvena literatura oblikuje tematski prostor unutar kojega se takav koncept može teorijski razmatrati te upućuju na potrebu daljnjih empirijskih istraživanja korisničkih iskustava, percepcije transparentnosti i mogućnosti kritičkog osporavanja algoritamski posredovanih informacija.

ZAKLJUČAK

Ovaj rad polazi od pretpostavke da se sigurnost u digitalnoj komunikaciji ne može razmatrati isključivo kao tehnički ili regulatorni zahtjev, nego i kao diskurzivni okvir povezan s pitanjima povjerenja, transparentnosti, autonomije i algoritamskog upravljanja. Bibliometrijska analiza korpusa od 517 znanstvenih radova pokazala je izraženu zastupljenost regulatorno-sigurnosnih i etičkih tema, njihovu međusobnu povezanost s pojmovima povjerenja i transparentnosti te vremenski pomak istraživačke pozornosti prema društvenim i epistemološkim implikacijama algoritamskih sustava.

Na temelju navedenih nalaza, koncept epistemološke poslušnosti u ovom se radu predlaže kao teorijski okvir za interpretaciju znanstvenih diskursa o odnosu algoritamskih sustava, znanja i korisničke autonomije. Rezultati ne omogućuju zaključivanje da su korisnici empirijski epistemološki poslušni niti da takva poslušnost predstavlja standard njihova ponašanja. Oni, međutim, pokazuju da analizirana literatura oblikuje konceptualni prostor unutar kojega se mogu kritički razmatrati ograničenja transparentnosti, asimetrije znanja i mogućnosti autonomnog djelovanja u algoritamski posredovanoj komunikaciji.

Bibliometrijski nalazi upućuju na potrebu da se digitalna otpornost u komunikacijskim istraživanjima ne promatra samo kao tehničko svojstvo sustava, nego i kao pitanje transparentnosti, povjerenja i mogućnosti autonomnog djelovanja. U tom smislu, koncept epistemološke poslušnosti može poslužiti kao teorijski okvir za buduća istraživanja načina na koje korisnici razumiju, prihvaćaju ili osporavaju algoritamski posredovane informacije.

Doprinos ovog rada stoga nije u empirijskom dokazivanju epistemološke poslušnosti korisnika, nego u bibliometrijskom mapiranju diskursa unutar kojega se taj koncept može dalje razvijati i empirijski provjeravati. Buduća istraživanja trebala bi povezati bibliometrijske nalaze s istraživanjima korisničkih iskustava, percepcije transparentnosti, digitalne pismenosti i mogućnosti kritičkog djelovanja u algoritamski posredovanim komunikacijskim okruženjima.

Ograničenje ovog istraživanja proizlazi iz prirode bibliometrijske metode i odabranog korpusa. Analiza radova

indeksiranih u bazi Scopus omogućuje mapiranje dominantnih pojmova, tematskih klastera, bibliografskih poveznica i vremenskih tendencija u znanstvenoj literaturi, ali ne omogućuje neposredno zaključivanje o stavovima, iskustvima ili ponašanjima korisnika digitalnih platformi. Također, rezultati ovise o odabranoj bazi, pretraživačkim pojmovima, vremenskom rasponu i postupku semantičke normalizacije ključnih riječi. Stoga se epistemološka poslušnost u ovom radu razmatra kao teorijski interpretativni okvir utemeljen na obrascima znanstvenog diskursa, dok njezina empirijska provjera na razini korisnika ostaje zadatak budućih istraživanja.

LITERATURA

Acquisti, A., Brandimarte, L., & Loewenstein, G. (2015). Privacy and human behaviour in the age of information. Science, 347(6221), 509–514. https://doi.org/10.1126/science.aaa1465

Ananny, M. (2016). Toward an ethics of algorithms: Convening, observation, probability, and timeliness. Science Technology, & Human Values, 41(1), 93–117. https://doi.org/10.1177/0162243915606523

Angerschmid, A., Zhou, J., Theuermann, K., Chen, F., & Holzinger, A. (2022). Fairness and explanation in AI-informed decision making. Machine Learning and Knowledge Extraction, 4(2), 556–579. https://doi.org/10.3390/make4020026

Araujo, T., Helberger, N., Kruikemeier, S., & de Vreese, C. H. (2020). In AI we trust? Perceptions about automated decision-making by artificial intelligence. AI & Society, 35(3), 611–623. https://doi.org/10.1007/s00146-019-00931-w

Bankins, S., Formosa, P. (2023). The ethical implications of artificial intelligence for meaningful work. Journal of Business Ethics, 185, 725–740. https://doi.org/10.1007/s10551-023-05339-7

Bauman, Z. (2000). Liquid modernity. Polity Press.

Bebić, D. (2023). Uloga umjetne inteligencije u stvaranju medijskog sadržaja. Suvremene teme: međunarodni časopis za društvene i humanističke znanosti, 14(1), 47–59. https://doi.org/10.46917/st.14.1.3

Beer, D. (2017). The social power of algorithms. Information, Communication & Society, 20(1), 1–13. https://doi.org/10.1080/1369118X.2016.1216147

Bigo, D. (2002). Security and immigration: Toward a critique of the governmentality of unease. Alternatives: Global, Local, Political, 27(1), 63–92.

Bilić, P. (2012). Hrvatski medijski sustav između refleksivne modernizacije i medijatizacije: Societalna i institucionalna analiza. Društvena istraživanja, 21(4), 821–842. https://doi.org/10.5559/di.21.4.01

Binns, R., & Veale, M. (2021). Is that your final decision? Multi-stage profiling, selective effects, and Article 22 of the GDPR. International Data Privacy Law, 11(4), 319–332. https://doi.org/10.1093/idpl/ipab020

Birhane, A. (2021). Algorithmic injustice: A relational ethics approach. Patterns, 2(2), 100205. https://doi.org/10.1016/j.patter.2021.100205

Blumler, J. G., & Gurevitch, M. (1995). The crisis of public communication. Routledge.

Burrell, J. (2016). How the machine 'thinks': Understanding opacity in machine learning algorithms. Big Data & Society, 3(1), 1–12. https://doi.org/10.1177/2053951715622512

Confalonieri, R., Coba, L., Wagner, B., & Besold, T. R. (2021). A historical perspective of explainable Artificial Intelligence. WIREs Data Mining and Knowledge Discovery, 11(1), e1391. https://doi.org/10.1002/widm.1391

Dencik, L., Hintz, A., Redden, J., & Treré, E. (2019). Exploring data justice: Conceptions, applications and directions. Information, Communication & Society, 22(7), 873–881. https://doi.org/10.1080/1369118X.2019.1606268

Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. Journal of Experimental Psychology: General, 144(1), 114–126. https://doi.org/10.1037/xge0000033

Eubanks, V. (2018). Automating inequality: How high-tech tools profile, police, and punish the poor. Macmillan+ORM.

European Commission. (2006). Commission Staff Working Document: Croatia 2006 Progress Report. European Commission.

European Commission. (2022). Proposal for a regulation of the European Parliament and of the Council establishing a common framework for media services in the internal market (European Media Freedom Act) and amending Directive 2010/13/EU (COM(2022) 457 final).

European Parliament and Council. (2007). Directive 2007/65/EC amending Council Directive 89/552/EEC on the coordination of television broadcasting activities. Official Journal of the European Union, L332, 18 December 2007.

Felzmann, H., Fosch-Villaronga, E., Lutz, C., & Tamò-Larrieux, A. (2019). Transparency you can trust: Transparency requirements for artificial intelligence between legal norms and contextual concerns. Big Data & Society, 6(1), 1–14. https://doi.org/10.1177/2053951719860542

Floridi, L. (2023). The ethics of artificial intelligence. Oxford University Press.

Foucault, M. (2007). Security territory, population: Lectures at the Collège de France 1977–1978. Palgrave Macmillan.

Ghasemaghaei, M., & Kordzadeh, N. (2024). Understanding how algorithmic injustice leads to making discriminatory decisions: An obedience to authority perspective. Information & Management, 61(3), 103872. https://doi.org/10.1016/j.im.2024.103872

Gillespie, T. (2014). The relevance of algorithms. In T. Gillespie, P. J. Boczkowski, & K. A. Foot (Eds.), Media technologies: Essays on communication, materiality, and society (pp. 167–194). MIT Press.

Glikson, E., & Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. Academy of Management Annals, 14(2), 627–660. https://doi.org/10.5465/annals.2018.0057

Grimmelikhuijsen, S. G. (2023). Explaining why the computer says no: Algorithmic transparency affects the perceived trustworthiness of automated decision-making. Public Administration Review, 83(2), 241–262. https://doi.org/10.1111/puar.13483

Gombar, M. (2025a). Epistemology of obedience: The user's will in the age of algorithmic grace. Proud Pen. https://doi.org/10.51432/978-1-914266-17-1

Gombar, M. (2025b). Analiza i kritika digitalnoga odlučivanja: Paradoks algoritamske svijesti i pojam algoritamske volje. Obnovljeni Život: časopis za filozofiju i religijske znanosti, 80(4), 425–439. https://doi.org/10.31337/oz.80.4.1

Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a "right to explanation." AI Magazine, 38(3), 50–57. https://doi.org/10.1609/aimag.v38i3.2741

Hall, S. (1982). The rediscovery of ideology: Return of the repressed in media studies. In M. Gurevitch, T. Bennett, J. Curran, & J. Woollacott (Eds.), Culture, society and the media (pp. 56–90). Routledge.

Jungherr, A., & Rauchfleisch, A. (2025). Artificial Intelligence in deliberation: The AI penalty and the emergence of a new deliberative divide. Government Information Quarterly, 42(4), 102079. https://doi.org/10.1016/j.giq.2025.102079

Kamara, I., & Kosta, E. (2016). Do Not Track initiatives: Regaining the lost user control. International Data Privacy Law, 6(4), 276–290. https://doi.org/10.1093/idpl/ipw019

Katzenbach, C., & Ulbricht, L. (2019). Algorithmic governance. Internet Policy Review, 8(4), 1–18. https://doi.org/10.14763/2019.4.1424

Kellogg, K. C., Valentine, M. A., & Christin, A. (2020). Algorithms at work: The new contested terrain of control. Academy of Management Annals, 14(1), 366–410. https://doi.org/10.5465/annals.2018.0174

Kuziemski, M., & Misuraca, G. (2020). AI governance in the public sector: Three tales from the frontiers of automated decision-making in democratic settings. Telecommunications Policy, 44(6), 101976. https://doi.org/10.1016/j.telpol.2020.101976

Lyon, D. (2001). Surveillance society: Monitoring everyday life. Open University Press.

Lyon, D. (2018). The Culture of Surveillance: Watching as a Way of Life. John Wiley & Sons.

Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. Big Data & Society, 3(2), 1–21. https://doi.org/10.1177/2053951716679679

Mittelstadt, B. D. (2019). Principles alone cannot guarantee ethical AI. Nature Machine Intelligence, 1, 501–507. https://doi.org/10.1038/s42256-019-0114-4

Moreno-Sánchez, P. A., Del Ser, J., van Gils, M., & Hernesniemi, J. (2026). A design framework for operationalizing trustworthy artificial intelligence in healthcare. Information Fusion, 127, 103812. https://doi.org/10.1016/j.inffus.2025.103812

Peruško, Z. (2003). Medijska koncentracija: izazov pluralizmu medija u Srednjoj i Istočnoj Europi. Medijska istraživanja, 9(1), 39–58.

Peruško, Z. (2004). Medijska transformacija u Hrvatskoj: između tranzicije i europske integracije. Politička misao, 41(5), 5–28.

Peruško, Z. (2006). Mediji i civilno društvo. In S. P. Ramet & D. Matić (Eds.), Demokratska tranzicija. Alinea.

Qin, F., Li, K., & Yan, J. (2020). Understanding user trust in artificial intelligence-based educational systems: Evidence from China. British Journal of Educational Technology, 51(5), 1693–1710. https://doi.org/10.1111/bjet.12994

Rahwan, I., Cebrian, M., Obradovich, N., Bongard, J., Bonnefon, J.-F., Breazeal, C., Crandall, J. W., Christakis, N. A., Couzin, I. D., Jackson, M. O., Jennings, N. R., Kamar, E., Kloumann, I. M., Larochelle, H., Lazer, D., McElreath, R., Mislove, A., Parkes, D. C., Pentland, A. S., Roberts, M. E., Shariff, A., Tenenbaum, J. B., & Wellman, M. (2019). Machine behaviour. Nature, 568(7753), 477–486. https://doi.org/10.1038/s41586-019-1138-y

Nacionalna razvojna strategija Republike Hrvatske do 2030. godine. (2021). Narodne novine, 13/2021.

Rouvroy, A., & Berns, T. (2013). Algorithmic governmentality and prospects of emancipation: Disparateness as a precondition for individuation through relationships? Réseaux, 177(1), 163–196. https://doi.org/10.3917/res.177.0163

Rudin, C. (2019). Stop explaining black-box machine learning models for high-stakes decisions and use interpretable models instead. Nature Machine Intelligence, 1(5), 206–215. https://doi.org/10.1038/s42256-019-0048-x

Ryan, M. (2020). In AI we trust: Ethics, artificial intelligence, and reliability. Science and Engineering Ethics, 26(5), 2749–2767. https://doi.org/10.1007/s11948-020-00228-y

Seaver, N. (2017). Algorithms as culture: Some tactics for the ethnography of algorithmic systems. Big Data & Society, 4(2), 1–12. https://doi.org/10.1177/2053951717738104

Skoko, B., & Bajs, D. (2007). Objavljivanje neistina i manipuliranje činjenicama u hrvatskim medijima i mogućnosti zaštite privatnosti, časti i ugleda. Politička misao, 44(1), 93–116.

Thompson, J. B. (2000). Political scandal: Power and visibility in the media age. Polity Press.

Tufekci, Z. (2016). Algorithmic harms beyond Facebook and social media. Nature, 538, 171–172. https://doi.org/10.1038/538171a

UNESCO. (2008). Media development indicators: A framework for assessing media development. UNESCO.

UNESCO. (2018). Internet universality indicators: A framework for assessing internet development. UNESCO.

Vijeće za elektroničke medije. (2008). Izvješće Hrvatskom saboru o radu VEM-a i Agencije za elektroničke medije za 2008. godinu.

Yeung, K. (2017). 'Hypernudge': Big data as a mode of regulation by design. Information, Communication & Society, 20(1), 118–136. https://doi.org/10.1080/1369118X.2016.1186713

Zgrabljić Rotar, N. (2003). Hrvatska medijska politika i javni mediji. Medijska istraživanja, 9(1), 59–77.

Zuboff, S. (2023). The age of surveillance capitalism. In W. Longhofer & D. Winchester (Eds.), Social theory re-wired: New connections to classical and contemporary perspectives (3rd ed., pp. 203–213). Routledge. https://doi.org/10.4324/9781003320609-27

Media, Culture and Public Relations Vol.17, 1

INFO - 199

https://doi.org/10.63191/mcpr.17.1.1

EPISTEMOLOGY OF ALGORITHMIC OBEDIENCE: A BIBLIOMETRIC ANALYSIS OF THE SECURITY IMAGINARY IN DIGITAL COMMUNICATION

Marija Gombar

ABSTRACT: This paper uses bibliometric analysis to map how contemporary scholarly literature conceptualizes security, transparency, trust, and autonomy in algorithmically mediated digital communication. Drawing on the theoretical concept of epistemological obedience, the paper approaches security not only as a technical and regulatory requirement, but also as a discursive framework within which questions of visibility, knowledge control, and user autonomy are articulated. The analysis was conducted on a corpus of 517 scholarly publications indexed in Scopus and published between 2015 and 2026, using keyword co-occurrence analysis, bibliographic coupling of documents, and co-authorship analysis in VOSviewer. The results indicate the central position of themes related to artificial intelligence, transparency, trust, and algorithmic governance, as well as a pronounced interconnection between regulatory-ethical and security-oriented approaches. At the same time, concepts related to autonomy, participation, and resistance appear less prominently and mainly in peripheral or more recent thematic directions. The temporal distribution of concepts points to a gradual strengthening of scholarly interest in the social and epistemological implications of algorithmic systems. The findings do not demonstrate the effects of algorithmic systems on user behaviour; rather, they identify patterns of scholarly discourse that enable a theoretical consideration of epistemological obedience. The paper concludes that the bibliometrically mapped patterns open space for further empirical research on the relationship between digital security, transparency, and user autonomy.

KEYWORDS: algorithmic transparency, algorithmic governance, digital communication, epistemological obedience, security imaginary