

Izvorni naučni rad

Primljen 17.05.2026.

Haris Šunje

Nastavnički fakultet Univerziteta „Džemal Bijedić“ u Mostaru
haris.sunje@unmo.ba

Aldina Leto

Nastavnički fakultet Univerziteta „Džemal Bijedić“ u Mostaru
aldina.letto@unmo.ba

Dijana Ivanišević

Nastavnički fakultet Univerziteta „Džemal Bijedić“ u Mostaru
dijana.ivanisevic@unmo.ba

ZASTUPLJENOST OVISNOSTI O INTERNETU KOD ADOLESCENATA I POVEZANOST S GENERALIZIRANIM PROBLEMATIČNIM KORIŠTENJEM INTERNETA

Sažetak

Cilj istraživanja bio je ispitati virtuelno ponašanje adolescenata i utvrditi zastupljenost ovisnosti o internetu, te istražiti povezanost ovisnosti i generaliziranog problematičnog korištenja interneta. Uzorak se sastoji od 100 adolescenata ($N = 100$) koji su ispunili Samoprocjenski upitnik za ovisnost o internetu, te Skalu generaliziranog problematičnog korištenja interneta 2 (Caplan, 2010). Podaci pokazuju da 28% ispitanika ispunjava kriterije koji ukazuju na poteškoće s ovisnošću o internetu (IADQ). Također, postoji statistički značajna povezanost između ovisnosti o internetu i subskala generaliziranog problematičnog korištenja interneta. Predstavljene su mjere prevencije i sugestije za rad sa mladima u okviru upotrebe i zloupotrebe digitalnih uređaja kroz primarnu prevenciju prije

razvoja problematičnih obrazaca, sekundarnu prije razvoja klinički relevantnih poteškoća, te tercijarnu intervenciju u kontekstu ispitanika sa klinički manifestnim poteškoćama u općoj populaciji.

Ključne riječi: ovisnost o internetu, problematično korištenje interneta, adolescencija, mentalno zdravlje

1. UVOD

Savremeno društvo obilježeno je intenzivnim razvojem digitalnih tehnologija i svakodnevnom upotrebom interneta među djecom i adolescentima. Internet je postao nezaobilazan dio obrazovanja, komunikacije, socijalizacije i zabave, ali njegova prekomjerna i nekontrolisana upotreba može dovesti do različitih psiholoških, socijalnih i emocionalnih poteškoća (Kuss i Lopez-Fernandez, 2016). Posebno osjetljivu grupu predstavljaju adolescenti, zbog razvojnih karakteristika, intenzivne potrebe za socijalnim prihvatanjem i povećane emocionalne osjetljivosti (Spada, 2014).

Ovisnost o internetu Young (1998) definisala je kao obrazac pretjerane upotrebe interneta koji dovodi do poremećaja svakodnevnog funkcionisanja pojedinca. Ovaj fenomen povezuje se s gubitkom kontrole, zanemarivanjem školskih i porodičnih obaveza, socijalnim povlačenjem te emocionalnim poteškoćama (Young, 1998). Istraživanja potvrđuju da prekomjerno korištenje interneta može biti povezano s anksioznošću, depresivnošću, smanjenim školskim uspjehom i poremećajima spavanja kod adolescenata (Kuss i Lopez-Fernandez, 2016).

Pored pojma ovisnosti o internetu, u savremenim istraživanjima značajno mjesto zauzima i koncept generaliziranog problematičnog korištenja interneta. Caplan (2010) definiše ovaj konstrukt kao multidimenzionalni obrazac ponašanja koji uključuje preferenciju online socijalne interakcije, regulaciju raspoloženja putem interneta, kognitivnu preokupaciju, kompulzivno korištenje interneta i negativne posljedice (Caplan, 2010). Caplanov (2010) pristup naglašava da problematično korištenje interneta nije jednostavan i jednodimenzionalni fenomen, nego radije složeni obrazac ponašanja koji zahtijeva multidimenzionalne mjerne

instrumente.

Zbog sve izraženije prisutnosti digitalnih uređaja u svakodnevnom životu adolescenata, istraživanje zastupljenost ovisnosti o internetu i njene povezanosti s generaliziranim problematičnim korištenjem interneta predstavlja veoma bitan do u procjeni i zaštiti mentalnog zdravlja mladih. Pored djece predškolskog uzrasta, adolescenti predstavljaju jednu od najosjetljivijih skupina.

1.1. Klasifikacijski status ovisnosti o internetu

Fenomen ovisnosti o internetu od samog početka prate terminološke i klasifikacijske kontroverze. Young (1998) bila je među prvima koja je sistematski opisala ovaj sindrom, koristeći modificirane DSM-IV kriterije za patološko kockanje kao analogni okvir za konceptualizaciju bihevioralne ovisnosti o internetu. Međutim, ni u Dijagnostičkom i statističkom priručniku za duševne poremećaje (*DSM-5*; Američka Psihijatrijska Udruga, 2014) ni u Međunarodnoj klasifikaciji bolesti (*ICD-11*; World Health Organization, 2024) ovisnost o internetu kao takva nije prepoznata kao zasebna dijagnoza.

DSM-5 jedino u Sekciji III navodi Poremećaj igranja internet igara (eng. *Internet Gaming Disorder*) kao stanje koje zahtijeva dodatna istraživanja prije eventualnog uvrštavanja kao formalne dijagnoze (Američka Psihijatrijska Udruga, 2014). Ovim je naglašena potreba za empirijskim dokazima o specifičnim obrascima, prevalenciji i kliničkim karakteristikama, ali i propuštena prilika za obuhvatanje šireg spektra problematičnog korištenja interneta izvan igara.

ICD-11 (WHO, 2024) uvrstio je Poremećaj igranja (eng. *Gaming Disorder*, šifra 6C51) kao formalnu dijagnozu, no također bez proširenja na opću ovisnost o internetu. Stoga istraživači koji se bave generalnim problematičnim korištenjem interneta rade u uslovima klasifikacijske praznine, oslanjajući se na operacionalne definicije i mjerne instrumente razvijene unutar pojedinih teorijskih modela (Mihajlov i Vejmeka, 2017). Upravo ova praznina čini istraživanja zastupljenosti simptoma ovih poremećaja posebno važnima za razumijevanje stvarnog obima problema na našim prostorima.

1.2. IADQ: Bihevioralni model ovisnosti kao dijagnostička osnova

Odabir mjernih instrumenata u istraživanjima ovisnosti o internetu predstavlja primarno teorijsku, a ne tehničku odluku, budući da svaki instrument pretpostavlja specifičan konceptualni okvir kojim operacionalizira konstrukt koji mjeri (Borsboom et al., 2004). U ovom istraživanju korištena su dva instrumenta teorijski različitih polazišta: Samoprocjenski upitnik za ovisnost o internetu (IADQ), koji počiva na bihevioralnom modelu ovisnosti, te Skala generaliziranog problematičnog korištenja interneta 2 (GPIUS-2; Caplan, 2010), utemeljena na kognitivno-bihevioralnom modelu.

IADQ je teorijski utemeljen u Griffithssovom (2005) komponentnom modelu bihevioralnih ovisnosti, koji definira ovisnost kroz šest operativnih kriterija: istaknutost, modifikaciju raspoloženja, toleranciju, apstinencijsku krizu, konflikt (negativne posljedice) i relaps. Griffiths (2005) argumentira da svako ponašanje koje ispunjava navedene kriterije zadovoljava klinički prag ovisnosti, neovisno o tome uključuje li psihoaktivnu supstancu.

Teorijske korijene specifično za ovisnost o internetu utemeljila je Young (1998), koja je adaptirala DSM-IV kriterije za patološko kockanje na korištenje interneta, time postavivši osnovu za razvoj dijagnostičkih instrumenata skrininga u ovom domenu. Kriteriji problematičnog korištenja interneta koje IADQ/YDQ procjenjuje su: preokupacija (čestica 1), tolerancija, apstinencijska kriza, nedostatak kontrole, nastavak korištenja unatoč problemima, gubitak interesa za druge aktivnosti, korištenje interneta kao bijeg/regulacija raspoloženja, laganje o korištenju te ugrožavanje odnosa, posla ili obrazovanja. IADQ se sastoji od 8 dihotomnih čestica (da/ne), a granični kriterij za indikaciju klinički relevantnih poteškoća iznosi pet ili više potvrdnih odgovora (≥ 5). Dijagnostička logika instrumenta odgovara modelu kategorijalne klasifikacije: ispitanici se razvrstavaju u skupinu s prisutnim ili odsutnim poteškoćama, što čini IADQ posebno prikladnim za istraživanja prevalencije u populacijskim uzorcima (Young, 1998). Ograničenje ovog pristupa ogleda se u tome što instrument ne pruža informaciju o intenzitetu ili profilu problematičnog korištenja unutar kontinuuma, što je eksplicitno metodološki kompenzirano istovremenom primjenom dimenzionalnog instrumenta GPIUS-2.

1.3. GPIUS-2: Kognitivno bihevioralni model kao teorijski temelj

GPIUS-2 (Caplan, 2010) operacionalizira Caplanov kognitivno-bihevioralni model problematičnog korištenja interneta, razvijan kroz niz empirijskih i teorijskih radova (Caplan, 2002, 2003, 2005, 2010). Polazište ovog modela je da problematično korištenje interneta nastaje kao posljedica psihosocijalne ranjivosti, a ponajprije socijalne anksioznosti, depresivnosti i usamljenosti. Ova, ali i različita druga stanja, potkrepljuju razvoj preferencije prema online socijalnom kontaktu (eng. *Preference for Online Social Interaction*, POSI), percipiranom kao manje prijetećem (sigurnijem) komunikacijskom okruženju u usporedbi s interpersonalnom komunikacijom licem u lice (Caplan, 2003). Ova preferencija konceptualizirana je kao antecedentni proces koji kroz lančanu kognitivno-bihevioralnu sekvencu vodi do kulminacije u vidu kompulzivnog korištenja interneta i negativnih posljedica u smislu funkcionalnosti (Caplan, 2010).

GPIUS-2 mjeri ovaj konstrukt putem 15 čestica raspoređenih u pet dimenzija: (1) preferencija online socijalnog kontakta, (2) regulacija raspoloženja, (3) kognitivna preokupacija, (4) kompulzivno korištenje interneta te (5) negativne posljedice. Konfirmatorna faktorska analiza potvrdila je petofaktorsku hijerarhijsku strukturu instrumenta, pri čemu su POSI i regulacija raspoloženja identificirani kao antecedentni faktori koji predviđaju kognitivnu preokupaciju, a ona predviđa kompulzivno korištenje i negativne posljedice (Caplan, 2010).

Uprkos razlikama u psihometrijskoj strukturi instrumenata, IADQ je operacionaliziran kao kategorijalni bihevioralni konstrukt, a GPIUS-2 kao kontinuirani kognitivno-bihevioralni, oba instrumenta dijele zajednički nomološki prostor: oba pretpostavljaju da ovisnost, odnosno problematično korištenje interneta, nužno uključuje gubitak kontrole, psihičku preokupiranost i negativne posljedice u funkcionalnom smislu (Griffiths, 2005; Caplan, 2010).

U skladu s tim, može se očekivati da bi instrumenti trebali konvergirati na uzorcima ispitanika s klinički relevantnim obrascima korištenja interneta.

2. METODOLOGIJA

Istraživanje je kvantitativnog tipa, a u skladu s potrebama istraživanja, od statističkih postupaka da bismo testirali hipoteze koristio se korelacijski postupak.

2.1. *Uzorak istraživanja*

Uzorak ovog istraživanja čini 100 ispitanika ($N=100$), od kojih 35 učesnika i 65 učesnica ljetne škole „5 dana bez ekrana“. Ispitanici su osnovnoškolskog uzrasta prosječne dobi od 13 godina, gdje je najmlađi ispitanik imao 10, a najstariji ispitanik 16 godina ($M=13$; $SD=1.28$). Istraživanje je provedeno na populaciji adolescenata te je, u skladu s etičkim smjernicama za istraživanja s maloljetnicima, prethodno pribavljena informisana saglasnost roditelja. U istraživanje su uključeni učesnici za koje su roditelji potpisali pismene saglasnosti i odobrili korištenje podataka u svrhu istraživanja. Svi roditelji su dobili povratnu informaciju o postignutim rezultatima učesnika istraživanja. Podaci su prikupljeni preko Google Forms online platforme za anketiranje.

2.2. *Mjerni instrumenti*

U nastavku su prikazani mjerni instrumenti koji su korišteni u svrhu istraživanja, kako bi se prikupili odgovarajući podaci za analizu:

- *Upitnik sociodemografskih karakteristika*, koji je konstruisan za potrebe ovog istraživanja i uključuje varijable kao što su spol, dob, broj članova porodice, prosječno vrijeme korištenja mobilnih i sličnih uređaja na dnevnom nivou.
- *Skala generaliziranog problematičnog korištenja interneta 2* (eng. *GPIUS-2*; Caplan, 2010), koja se sastoji od pet subskala s po tri tvrdnje za svaku subskalu. Uz subskale su navedeni indeksi pouzdanosti na ovom uzorku. Prva subskala jest preferencija online interakcije ($\alpha=.888$), a sastoji se od tvrdnji poput „Radije biram online druženje s drugima nego u živo (licem u lice)“. Druga subskala jest regulacija

raspoloženja ($\alpha=.802$), s tvrdnjama poput „Koristim internet kako bih razgovarao/la s drugima kada se osjećam usamljeno“. Treća subskala jest kognitivna preokupacija ($\alpha=.820$), s tvrdnjama poput „Kad nisam online neko vrijeme, postajem zaokupljen/a mislima da odem na internet“. Četvrta subskala jest prekomjerno korištenje interneta ($\alpha=.828$), s tvrdnjama poput „Teško mi je kontrolirati vrijeme koje provedem na internetu“, dok je zadnja subskala negativne posljedice ($\alpha=.765$), s tvrdnjama poput „Korištenje interneta mi otežava upravljanje životom“. Ispitanici odgovaraju na svaku tvrdnju na skali procjene od 5 stepeni pri čemu 1 označava „uopće se ne odnosi na mene“, a 5 „u potpunosti se odnosi na mene“. Ukupni rezultat formira se kao prosječna vrijednost procjena na svakoj pojedinoj subskali, pri čemu viši rezultat govori o izraženijem problematičnom korištenju interneta.

- *Dijagnostički samoprocjenski upitnik ovisnosti o internetu* (IADQ; *Internet Addiction Diagnosis Questionnaire*; Young, 1998) razvila je Young (1998) pod nazivom Young Diagnostic Questionnaire (YDQ), u poznat i kao Samoprocjenski upitnik za ovisnost o internetu (IADQ). Instrument spada među najčešće korištene samoprocjenske mjere problematičnog korištenja interneta, uz IAT (20 čestica), CIAS (26 čestica) i CIUS (14 čestica). Format odgovora je binarni (0 = "ne", 1 = "da"). Granični kriterij za indikaciju klinički relevantnih poteškoća iznosi pet ili više potvrdnih odgovora (≥ 5 ; Young, 1998b).

2.3. Cilj i zadaci istraživanja

Cilj istraživanja bio je ispitati virtualno ponašanje adolescenata i utvrditi prevalenciju ovisnosti o internetu, te istražiti povezanost ovisnosti o internetu i generaliziranog problematičnog korištenja interneta.

Zadaci istraživanja izvedeni iz cilja istraživanja su sljedeći:

- Utvrditi udio ispitanika koji u ovom uzorku ispunjavaju granični kriterij za indikaciju poteškoća s ovisnošću o internetu prema IADQ-u (≥ 5 potvrdnih odgovora), te usporediti dobiveni nalaz s rasponima prevalencije

utvrđenim u srodnim istraživanjima na adolescentskim uzorcima.

- Ispitati da li postoji statistički značajna povezanost između ovisnosti o internetu (IADQ) i subskale preferencije online kontakta (GPIUS-2).
- Ispitati da li postoji statistički značajna povezanost između ovisnosti o internetu (IADQ) i subskale regulacije raspoloženja (GPIUS-2).
- Ispitati da li postoji statistički značajna povezanost između ovisnosti o internetu (IADQ) i subskale kognitivne preokupacije (GPIUS-2).
- Ispitati da li postoji statistički značajna povezanost između ovisnosti o internetu (IADQ) i subskale negativnih posljedica (GPIUS-2).
- Ispitati da li postoji statistički značajna povezanost između ovisnosti o internetu (IADQ) i subskale kompulzivnog/prekomjernog korištenja interneta (GPIUS-2).

2.4. Hipoteze istraživanja

H0. Pretpostavlja se da će udio ispitanika koji ispunjavaju kriterije za poteškoće s ovisnošću o internetu biti viši od globalnog medijana prevalencije utvrđenog u meta-analitičkim studijama na adolescentskim uzorcima (Cheng i Li, 2014; Mihajlov i Vejmelka, 2017).

H1. Pretpostavlja se da postoji statistički značajna povezanost pozitivnog smjera između varijabli ovisnosti o internetu i preferencije online kontakta.

H2. Pretpostavlja se da postoji statistički značajna povezanost pozitivnog smjera između varijabli ovisnosti o internetu i regulacije raspoloženja.

H3. Pretpostavlja se da postoji statistički značajna povezanost pozitivnog smjera između varijabli ovisnosti o internetu i kognitivne preokupacije.

H4. Pretpostavlja se da postoji statistički značajna povezanost pozitivnog smjera između varijabli ovisnosti o internetu i negativnih posljedica (konflikta).

H5. Pretpostavlja se da postoji statistički značajna

povezanost pozitivnog smjera između varijabli ovisnosti o internetu i kompulzivnog/prekomjernog korištenja interneta.

3. REZULTATI

U svrhu utvrđivanja udjela ispitanika koji ispunjavaju granični kriterij za indikaciju poteškoća s ovisnošću o internetu, analizirani su individualni rezultati na IADQ-u. Od ukupno 100 ispitanika ($N = 100$), njih 28 (28.0%) postiglo je rezultat ≥ 5 potvrdnih odgovora, što prema dijagnostičkoj logici instrumenta (Young, 1998) indicira prisustvo klinički relevantnih poteškoća s ovisnošću o internetu. Preostalih 72 ispitanika (72.0%) postiglo je rezultat ispod graničnog kriterija.

Istraživačka hipoteza (H_0) predviđala je da će udio ispitanika koji ispunjavaju kriterije za poteškoće s ovisnošću o internetu biti viši od referentnih vrijednosti prevalencije utvrđenih u meta-analitičkim studijama na adolescentskim uzorcima. Za statističku provjeru istraživačke hipoteze primijenjen je hi-kvadrat test prilagođenosti, koji omogućuje usporedbu opažene distribucije kategorija u uzorku s teorijski ili empirijski utemeljenim očekivanim distribucijama (Field, 2018). Kao referentna vrijednost za izračun očekivanih frekvencija korišten je globalni medijan prevalencije ovisnosti o internetu od 6.0%, koji su Cheng i Li (2014) utvrdili na osnovu meta-analize 80 studija ($N = 89.281$). Prema ovoj referentnoj vrijednosti, na uzorku ovog istraživanja ($N = 100$) očekivane frekvencije iznose 6 ispitanika s poteškoćama i 94 bez poteškoća (Tabela 1).

Tabela 1.

Distribucija ispitanika prema kriterijima IADQ-a

	<i>Opaženo N</i>	<i>Opaženo %</i>	<i>Očekivano N</i>	<i>Razlika</i>
Ispod graničnog kriterija (IADQ <5)	72	72.0%	94.0%	-22.0
Jednako ili iznad graničnog kriterija (IADQ ≥ 5)	28	28.0%	6.0%	+22.0
Ukupno	100	100%	100%	

Rezultati hi-kvadrat testa prilagođenosti pokazuju statistički značajno odstupanje opažene distribucije od očekivane ($\chi^2(1) = 85.816$, $p < .001$). Uz nalaz statističke značajnosti, izračunata je i veličina efekta Cohenovim h koeficijentom za proporcije ($h = .620$) što prema Cohenovim (1988) kriterijima odgovara umjerenm do velikom efektu.

Na osnovu navedenih rezultata, istraživačka hipoteza H_0 je potvrđena: udio ispitanika koji u uzorku ispunjavaju kriterije za poteškoće s ovisnošću o internetu statistički je značajno i uz veliki efekt viši od globalnog medijana prevalencije utvrđenog u meta-analitičkim studijama (Cheng i Li, 2014).

Analizirajući ostale hipoteze istraživanja u nastavku je prikazana matrica korelacija između varijabli koje se povezuju u hipotezama istraživanja. (Tabela 2). Sve postavljene hipoteze (H_1 – H_5) su potvrđene. Ovisnost o internetu, mjerena IADQ-om, statistički je značajno pozitivno povezana sa svim dimenzijama generaliziranog problematičnog korištenja interneta mjerenim GPIUS-2. Intenzitet korelacija raste uzduž Caplanove (2010) hijerarhijske sekvence — od najslabije veze s preferencijom online kontakta kao antecedentnim faktorom ($r = .219$, $p < .05$) prema sve snažnijim vezama s regulacijom raspoloženja ($r = .418$, $p < .01$), kognitivnom preokupacijom ($r = .579$, $p < .001$), negativnim posljedicama ($r = .516$, $p < .001$), do najsnažnije veze s prekomjernim/kompulzivnim korištenjem interneta ($r = .688$, $p < .001$) kao centralnom bihevioralnom manifestacijom ovisnosti.

Tabela 2.

Matrica korelacija varijabli koje se povezuju u hipotezama istraživanja

Varijabla	1.	2.	3.	4.	5.	6.
1. Ovisnost o internetu (IADQ)	-					
2. Preferencija online kontakta (GPIUS-2)	.219*	-				
3. Regulacija raspoloženja (GPIUS-2)	.418***	.524***	-			
4. Kognitivna preokupacija (GPIUS-2)	.579***	.274**	.365***	-		

5. Negativne posljedice (GPIUS-2)	.516***	.154	313.**	.560***	-
6. Prekomjerna upotreba interneta (GPIUS-2)	.688***	.528***	.580***	.594***	.502*** -

*** $p < .001$. ** $p < .01$. * $p < .05$.

4. DISKUSIJA I ZAKLJUČAK

Dobiveni nalaz da 28.0% ispitanika ispunjava granični kriterij za poteškoće s ovisnošću o internetu prema IADQ-u predstavlja rezultat koji zahtijeva odgovarajuću interpretaciju. Ovaj nalaz je u skladu s literaturom koja doslijedno evidentira povišene nivoe problematičnog korištenja interneta u kod adolescenata.

Kuss i Lopez-Fernandez (2016) u sistematskom pregledu pokazuju da stopa problematičnog korištenja interneta kod adolescenata u Evropi varira od 1.2% do 18.7%, pri čemu primarno metodološke razlike objašnjavaju veliki dio ove varijanse, kroz različit instrumentarij i kriterije.

U ovom istraživanju, udio od 28.0% smješten je iznad gornje granice raspona, što pokazuje da ovi podaci zahtijevaju posebnu pažnju i analizu. Naime, uzorak ovog istraživanja nije reprezentativan za opću populaciju adolescenata iz razloga što su ispitanici učesnici ljetnog kampa „5 dana bez ekrana“, što znači da su roditelji ove adolescente prepoznali kao one s problematičnim ili zabrinjavajućim obrascima korištenja digitalnih uređaja. Između ostalog, to je jedan od mogućih razloga zbog kojih su roditelji svjesno uputili djecu na program čija je osnova apstinencija od digitalnih uređaja.

Selekcija ispitanika na ovaj način gotovo garantuje uzorak ispitanika s nadproporcionalnom zastupljenošću problematičnih obrazaca korištenja interneta u usporedbi s općom adolescentskom populacijom (Shadish et al., 2002). Zbog toga, dobiveni nalaz od 28.0% ne može biti interpretiran kao procjena prevalencije u populaciji adolescenata, nego isključivo kao deskriptivni podatak o distribuciji poteškoća unutar ovog specifičnog uzorka.

Ipak, podaci imaju kliničku i praktičnu relevantnost: gotovo svaki treći učesnik kampa "5 dana bez ekrana" ispunjava kriterije

koji prema dijagnostičkoj logici IADQ-a ukazuju na klinički relevantne poteškoće. Nalaz upućuje na to da roditelji koji prepoznaju zabrinjavajuće obrasce korištenja interneta kod svoje djece i usmjeravaju ih na preventivne intervencije imaju objektivnu osnovu za takvu procjenu, što je relevantan i bitan nalaz s aspekta ranog otkrivanja poteškoća i prevencije.

Nadalje, rezultati pokazuju statistički značajnu pozitivnu korelaciju niskog intenziteta između ovisnosti o internetu i preferencije online kontakta ($r = .219, p < .05$), čime je potvrđena prva hipoteza istraživanja. Iako statistički značajna, ova korelacija je najniža u analizi, što je teorijski smisleno i u skladu s Caplanovim (2003) modelom, prema kojemu je preferencija online socijalnog kontakta antecedentni faktor u procesu razvoja problematičnog korištenja interneta. Smatra se da preferencija online kontakta koja jasnijim, manifestnim obrascima problematičnog korištenja, poput kompulzivnog korištenja i negativnih posljedica. Osobe s ovisnošću o internetu doista pokazuju višu preferenciju prema online komunikaciji, no ova povezanost je slabija od povezanosti s kasnijim stadijima problematičnog korištenja jer preferencija online kontakta može biti prisutna i kod korisnika koji još nisu razvili klinički relevantne poteškoće (Caplan, 2010). Fioravanti i sar. (2013) prijavljuju sličan obrazac u adolescentskim uzorcima, naglašavajući da preferencija online kontakta dobiva na kliničkom značaju tek u kombinaciji s regulacijom raspoloženja i kognitivnom preokupacijom u kontekstu korištenja interneta.

Druga hipoteza istraživanja je potvrđena statistički značajnom pozitivnom korelacijom srednjeg intenziteta između ovisnosti o internetu i regulacije raspoloženja ($r = .418, p < .01$). Nalaz je u skladu s Griffithsovim (2005) komponentnim modelom, koji regulaciju raspoloženja identifikuje kao jednu od šest ključnih komponenti bihevioralne ovisnosti. Korisnici koji internet koriste primarno kao mehanizam regulacije negativnih emocionalnih stanja - usamljenosti, anksioznosti ili dosade — razvijaju obrazac u kojem online aktivnost postaje funkcionalna zamjena za neke druge adaptivnije strategije suočavanja s distresom (Caplan, 2003; Davis, 2001).

Rezultati pokazuju statistički značajnu pozitivnu korelaciju srednjeg do visokog intenziteta između ovisnosti o internetu i kognitivne preokupacije ($r = .579, p < .001$), čime je treća hipoteza

istraživanja potvrđena. Kognitivna preokupacija ili tendencija ka intruzivnim mislima o internetu i misaonoj preokupaciji o online aktivnostima, a posebno u periodima kada korisnik nije online - pokazuje jednu od snažnijih veza s IADQ rezultatom u ovom istraživanju.

Ovaj nalaz je u skladu s teorijskim statusom koji kognitivna preokupacija ima u Caplanovom (2010) modelu: ona se konceptualizira kao medijatorski mehanizam koji posreduje između antecedentnih faktora (preferencija online kontakta, regulacija raspoloženja) i manifestnih bihevioralnih ishoda (kompulzivno korištenje, negativne posljedice). S druge strane, visoka korelacija s IADQ-om odražava i sadržajno preklapanje između dva instrumenta na nivou ovog konstrukta, što je ranije naglašeno kroz teorijski pristup.

Četvrta hipoteza istraživanja je potvrđena statistički značajnom pozitivnom korelacijom umjerenog do visokog intenziteta između ovisnosti o internetu i negativnih posljedica korištenja interneta ($r = .516$, $p < .001$). Negativne posljedice manifestirane kroz teškoće u upravljanju svakodnevnim obavezama, interpersonalne konflikte i funkcionalna oštećenja uzrokovana prekomjernim korištenjem interneta predstavljaju krajnji ishod u Caplanovom (2010) hijerarhijskom modelu, smješten na lancu koji počinje preferencijom online kontakta, preko regulacije raspoloženja i kognitivne preokupacije, te kulminira kompulzivnim korištenjem i negativnim posljedicama, odnosno oštećenju u funkcionalnosti korisnika.

Peta hipoteza istraživanja je potvrđena statistički značajnom pozitivnom korelacijom visokog intenziteta između ovisnosti o internetu i prekomjernog korištenja interneta ($r = .688$, $p < .001$). Ovo je najснаžнija korelacija u analizi. Nalaz je teorijski smislen i metodološki indikativan za konvergentnu valjanost između IADQ-a i GPIUS-2. Prekomjerno, kompulzivno korištenje interneta - koje je operacionalizirano kao gubitak kontrole nad vremenom i intenzitetom online aktivnosti - predstavlja bihevioralnu jezgru ovisničkog obrasca kako u komponentnom modelu bihevioralnih ovisnosti (Griffiths, 2005) tako i u kognitivno-bihevioralnom modelu (Caplan, 2010). Činjenica da upravo ova dimenzija pokazuje najveće preklapanje s IADQ sugerіše da oba instrumenta, uprkos teorijskim i psihometrijskim razlikama, dolaze do iste ideje – gubitka

kontrole nad korištenjem interneta. Pontes i sar. (2016) u portugalskom adolescentskom uzorku prijavljuju slične obrasce konvergencije između mjera bihevioralne ovisnosti i GPIUS-2.

Empirijski nalazi ovog istraživanja - visoka zastupljenost poteškoća na uzorku i povezanost ovisnosti s dimenzijama generaliziranog problematičnog korištenja interneta govore u prilog potrebi za sistematičnim i strukturiranim pristupima u prevenciji i kontroli ovog fenomena. U skladu s javnozdravstvenim modelom prevencije (Mihajlov i Vejmelka, 2017), preporuke su strukturirane na tri nivoa: primarna prevencija (opća populacija), sekundarna prevencija (rizične grupe) i tercijarna intervencija (klinički relevantni slučajevi).

Primarna prevencija podrazumijeva intervencije usmjerene na opću adolescentsku populaciju, prije nego što se problematični obrasci razviju. Školski kontekst identificiran je u literaturi kao optimalno okruženje za implementaciju preventivnih programa, jer osigurava pristup velikom broju adolescenata u razvojno osjetljivom periodu (Throuvala i sar., 2019). Programi koji su ciljani prema specifičnim dobnim grupama u kojima problematično korištenje interneta počinje biti manifestirano pokazuju posebnu učinkovitost, pri čemu su sadržaji prilagođeni tipičnim online ponašanjima unutar svake dobne grupe (Lindenberg i sar., 2020).

Sekundarna prevencija cilja adolescente koji pokazuju rane znakove problematičnog korištenja, ali još nisu razvili klinički relevantne poteškoće. Nalaz ovog istraživanja o umjerenoj korelaciji između regulacije raspoloženja i IADQ rezultata ($r = .418$, $p < .001$) upućuje na to da adolescenti koji internet koriste kao primarni mehanizam suočavanja s negativnim emocijama predstavljaju posebno ranjivu grupu koja zahtijeva ciljane intervencije (Caplan, 2003; Davis, 2001).

Tercijarna intervencija odnosi se na 28.0% ispitanika ovog uzorka koji ispunjavaju granični kriterij IADQ-a te na adolescente s klinički manifestnim poteškoćama u općoj populaciji. Na ovom nivou, empirijski najutemeljeniji pristup je kognitivno-bihevioralna terapija (KBT). Analiza istraživanja objavljenih između 2018. i 2022. godine pokazala je da je većina intervencija usmjerenih na digitalnu ovisnost kod djece i adolescenata koristila kognitivno-bihevioralnu terapiju ili metode utemeljene na KBT-u, što je dovelo do poboljšanja anksioznosti, depresivnosti i pratećih simptoma

digitalne ovisnosti (Lindenberg i sar., 2022). PROTECT program — niskointenzivna, postepena KBT intervencija za prevenciju i tretman ovisnosti o internetu kod adolescenata — integriše tehnike poput psihoedukcije, aktivacije ponašanja, kognitivnog restrukturiranja, rješavanja problema i regulacije emocija (Lindenberg i sar., 2020).

5. LITERATURA

- Američka psihijatrijska udruga (2014). *Dijagnostički i statistički priručnik za duševne poremećaje, peto izdanje*. Jastrebarsko: Naklada Slap.
- Borsboom, D., Mellenbergh, G. J., & van Heerden, J. (2004). The concept of validity. *Psychological Review*, 111(4), 1061–1071. <https://doi.org/10.1037/0033-295X.111.4.1061>
- Caplan, S. E. (2002). Problematic Internet use and psychosocial well-being: Development of a theory-based cognitive-behavioral measurement instrument. *Computers in Human Behavior*, 18(5), 553–575. [https://doi.org/10.1016/S0747-5632\(02\)00004-9](https://doi.org/10.1016/S0747-5632(02)00004-9)
- Caplan, S. E. (2003). Preference for online social interaction: A theory of problematic Internet use and psychosocial well-being. *Communication Research*, 30(6), 625–648. <https://doi.org/10.1177/0093650203257842>
- Caplan, S.E. (2005). A Social Skill Account of Problematic Internet Use. *Journal of Communication*, 55: 721–736. <https://doi.org/10.1111/j.1460-2466.2005.tb03019.x>
- Caplan, S. E. (2010). Theory and measurement of generalized problematic Internet use: A two-step approach. *Computers in Human Behavior*, 26(5), 1089–1097. <https://doi.org/10.1016/j.chb.2010.03.012>
- Cheng, C., & Li, A. Y. L. (2014). Internet addiction prevalence and quality of life: A meta-analysis of 31 nations across seven world regions. *Cyberpsychology, Behavior, and Social Networking*, 17(12), 755–760. <https://doi.org/10.1089/cyber.2014.0317>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum.
- Davis, R. A. (2001). A cognitive-behavioral model of pathological Internet use. *Computers in Human Behavior*, 17(2),

- 187–195. [https://doi.org/10.1016/S0747-5632\(00\)00041-8](https://doi.org/10.1016/S0747-5632(00)00041-8)
- Field, A. (2018). *Discovering statistics using IBM SPSS Statistics* (5th ed.). SAGE.
- Fioravanti, G., Dèttore, D., & Casale, S. (2013). Adolescent Internet addiction: Testing the association between self-esteem, the perception of Internet attributes, and preference for online social interactions. *CyberPsychology, Behavior, and Social Networking*, 15(6), 318–323. <https://doi.org/10.1089/cyber.2011.0358>
- Griffiths, M. D. (2005). A “components” model of addiction within a biopsychosocial framework. *Journal of Substance Use*, 10(4), 191–197. <https://doi.org/10.1080/14659890500114359>
- Kuss, D. J., & Lopez-Fernandez, O. (2016). Internet addiction and problematic Internet use: A systematic review of clinical research. *World Journal of Psychiatry*, 6(1), 143–176. <https://doi.org/10.5498/wjp.v6.i1.143>
- Lindenberg, K., Kindt, S., & Szász-Janocha, C. (2020). *Internet addiction in adolescents: The PROTECT program for evidence-based prevention and treatment*. Springer. <https://doi.org/10.1007/978-3-030-43784-8>
- Lindenberg, K., Kindt, S., & Szász-Janocha, C. (2022). Effectiveness of cognitive behavioral therapy-based intervention in preventing gaming disorder and unspecified internet use disorder in adolescents: A cluster randomized clinical trial. *JAMA Network Open*, 5(2), e2148995. <https://doi.org/10.1001/jamanetworkopen.2021.48995>
- Mihajlov, M., & Vejmělka, L. (2017). Internet addiction: A review of the first twenty years. *Psychiatria Danubina*, 29(3), 260–272. <https://doi.org/10.24869/psyd.2017.260>
- Pontes, H. M., Caplan, S. E., & Griffiths, M. D. (2016). Psychometric validation of the Generalized Problematic Internet Use Scale 2 in a Portuguese sample. *Computers in Human Behavior*, 63, 823–833. <https://doi.org/10.1016/j.chb.2016.06.015>
- Shadish, W. R., Cook, T. D., & Campbell, D. T. (2002). *Experimental and quasi-experimental designs for*

- generalized causal inference*. Houghton Mifflin.
- Spada, M. M. (2014). An overview of problematic internet use. *Addictive behaviors*, 39 (1), 3-6.
<https://doi.org/10.1016/j.addbeh.2013.09.007>
- Throuvala, M. A., Griffiths, M. D., Rennoldson, M., & Kuss, D. J. (2019). School-based prevention for adolescent internet addiction: Prevention is the key. A systematic literature review. *Current Neuropharmacology*, 17(6), 507–525.
<https://doi.org/10.2174/1570159X16666180813153806>
- World Health Organization (2024). *International Statistical Classification of Diseases and Related Health Problems (ICD)*.
<https://www.who.int/standards/classifications/frequently-asked-questions/gaming-disorder>
- Young, K. S. (1998). Internet addiction: The emergence of a new clinical disorder. *CyberPsychology & Behavior*, 1(3), 237–244. <https://doi.org/10.1089/cpb.1998.1.237>

Original research article

**THE PREVALENCE OF INTERNET ADDICTION AMONG
ADOLESCENTS AND ITS RELATIONSHIP WITH
GENERALIZED PROBLEMATIC INTERNET USE.**

Summary

The aim of the research was to examine the virtual behavior of adolescents and to determine the prevalence of Internet addiction, and to investigate the connection between Internet addiction and generalized problematic Internet use. The sample consists of 100 adolescents ($N = 100$) who participated in the Summer Camp "5 days without screens". In addition to the sociodemographic characteristics questionnaire, the respondents completed the Internet Addiction Self-Assessment Questionnaire (IADQ) and the Generalized Problematic Internet Use Scale 2 (GPIUS-2; Caplan, 2010). The data show that 28% of the respondents meet the criteria indicating difficulties with Internet addiction (IADQ) according to the criteria of the diagnostic questionnaire. Also, the data show that there is a statistically significant relationship between Internet addiction and online contact preference ($r = .219, p < .05$), mood regulation ($r = .418, p < .001$), cognitive preoccupation ($r = .579, p < .001$), negative consequences of Internet use ($r = .516, p < .001$) and excessive Internet use ($r = .688, p < .001$). The findings show a worrying side of the use of digital devices. Prevention measures and suggestions for working with young people in the context of the use and abuse of digital devices are presented, with a focus on the use of the Internet.

Key words: internet addiction, problematic internet use, adolescence, mental health