

KORELACIJSKA ANALIZA POKAZATELJA KAKVOĆE VODE JEZERA MOTIČNJAK

doc. dr. sc. Anita Ptiček Siročić
Geotehnički fakultet
Sveučilišta u Zagrebu
Hallerova aleja 7, 42000 Varaždin
anitaps@gf.v.hr

izv. prof. Sanja Kovač
Geotehnički fakultet
Sveučilišta u Zagrebu
Hallerova aleja 7, 42000 Varaždin

Anja Hajdinjak
Geotehnički fakultet
Sveučilišta u Zagrebu
Hallerova aleja 7, 42000 Varaždin

U radu je provedena korelacijska analiza pojedinih pokazatelja kakvoće vode te je pomoću linearнog modela regresije i modela višestruke regresije određena statistička povezanost između fizikalno-kemijskih i mikrobioloških pokazatelja kakvoće vode za kupanje na primjeru jezera Motičnjak. Fizikalno-kemijski i mikrobiološki pokazatelji kakvoće vode određivani su na uzorcima vode tijekom kupališnih sezona na dvije lokacije jezera Motičnjak od 2010. do 2015. godine. Rezultati su pokazali na postojanje povezanosti između pojedinih fizikalno-kemijskih pokazatelja i mikrobioloških pokazatelja *Escherichiae coli* (EC) i crijevnih enterokoka (CE).

Ključne riječi: fizikalno-kemijski pokazatelji, mikrobiološki pokazatelji, kakvoća vode za kupanje, korelacijska analiza, modeli višestruke regresije

1. UVOD

Kakvoća vode određuje se na temelju pojedinih pokazatelja prema preporukama, smjernicama i pravilnicima mjerodavnih ustanova i Zavoda na međudržavnoj i državnoj razini. Monitoring količine i kakvoće voda zakonom je definiran proces te je sastavni dio postupaka upravljanja vodama propisan Okvirnom direktivom o vodama 2000., krovnom zakonu o vodama Europske unije te Zakonom o vodama (NN 153/09, 130/11, 56/13, 14/14) Republike Hrvatske. Poznavanje kemijskih, fizikalno-kemijskih i mikrobioloških pokazatelja kakvoće vode važno je za nadzor i upravljanje svim vodnim resursima te se na temelju tih pokazatelja ocjenjuje ekološko stanje površinskih voda. Monitoring kakvoće vode za kupanje predstavlja posebnu vrstu motrenja kakvoće površinskih voda. Uredbom o kakvoći voda za kupanje (NN 51/14) detaljno je propisan postupak motrenja, klasifikacija voda za kupanje na površinskim vodama, upravljanje kakvoćom voda za kupanje te informiranje javnosti o kakvoći voda za kupanje u svrhu očuvanja, zaštite i poboljšanja kvalitete okoliša i zaštite zdravlja ljudi kao i postupanje u slučaju prekoračenja graničnih vrijednosti, odnosno pojave kratkotrajnog onečišćenja ili izvanrednog pogoršanja kakvoće vode za kupanje. Nadalje, Uredbom se određuje vremensko razdoblje ispitivanja, učestalost ispitivanja (najmanje svakih 15

dana u razdoblju ispitivanja) te način uzimanja uzoraka i analize površinskih voda za kupanje. Uredba se odnosi na monitoring kakvoće voda za kupanje na površinskim vodama na kojima se očekuje veliki broj kupača, a za koje nije izdana trajna zabrana kupanja ni trajna preporuka izbjegavanja kupanja. S obzirom da kupališni dio jezera Motičnjak još uvijek nije proglašen javnom plažom, a tijekom sezone kupanja posjećuje ga nekoliko desetaka tisuća kupača, vrlo je važno zbog zaštite ljudskog zdravlja uspostaviti trajni sustav motrenja kakvoće vode za kupanje. U svrhu određivanja kakvoće vode za kupanje potrebno je analizirati mikrobiološke pokazatelje, odnosno koliformne bakterije tj. *Escherichia coli* (EC) i crijevine enterokoke (CE). Nadalje, fizikalno-kemijski pokazatelji kakvoće vode ne smiju se zanemariti iako oni u potpunosti ne određuju kakvoću i moguću namjenu vode, ali upućuju na moguće prisustvo onečišćenja u vodi. Iz tog razloga, u radu su analizirani fizikalno-kemijski i mikrobiološki pokazatelji te se primjenom višestrukog modela regresije ispitala funkcionalna ovisnost pojedinih pokazatelja kakvoće površinske vode, odnosno vode za kupanje. Određivanjem korelacije između ekoloških pokazatelja kakvoće vode za kupanje moguće je utvrditi funkcionalnu ovisnost te na temelju dobivenih vrijednosti postaviti matematičke modele koji mogu kvantificirati učinkovitost postojećih mjera u svrhu zaštite voda i zdravlja ljudi.

2. STATISTIČKE METODE

2.1. Regresijska analiza

Često se u primjenama pojavljuju dvije ili više varijabli koje su međusobno povezane te je potrebno istražiti vrstu povezanosti među njima. Varijabla (ili više varijabli) koje se lako mogu izmjeriti uzimaju se kao nezavisne varijable, dok se varijabla koja se želi izmjeriti pomoću vrijednosti nezavisnih varijabli, naziva zavisna varijabla. Ponekad je intuitivno jasno postoji li zavisnost među varijablama, no statističkim metodama utvrđuje se funkcionalna zavisnost, koja ukazuje na određenu matematičku zakonitost među promatranim pojavama, te može poslužiti kao model za buduća predviđanja vrijednosti zavisne varijable.

Postoji više vrsta modela, od kojih je najjednostavniji model gdje postoji jedna nezavisna (X) i jedna zavisna varijabla (Y) koje su povezane *linearnim modelom regresije*, tj. izrazom $Y=aX+b$. Isto tako, često se puta u praksi pojavljuju pojave koje je moguće opisati *višestrukoum (multivarijatnom ili multiplom) linearom regresijom*, a to je kada je na raspolažanju više nezavisnih varijabli ($Y=a_1X_1+a_2X_2+\dots+a_nX_n+b$). Naravno, čest je slučaj kada odnosi među zavisnom i nezavisnom varijablom nisu linearni, nego određeni nekom drugom funkcijском vezom, i u tom slučaju govori se o *nelinearoj regresiji* ($Y=f(X)$).

Prije uspostave modela regresije potrebno je proučiti odnos između proučavanih varijabli, odnosno odrediti njihovu korelaciju. Pearsonov koeficijent korelacijske (r) mjeri jačinu i smjer linearne povezanosti (korelacijske) između dviju varijabli X i Y prema jednadžbi (1):

$$r = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad (1)$$

gdje je σ_{xy} kovarijanca između varijabli X i Y, a σ_x i σ_y su standardne devijacije varijabli X i Y.

Vrijednost koeficijenta korelacijske uvijek je između -1 i 1. Ako je r pozitivan govori se o pozitivnoj korelacijskoj, a ako je r negativan korelacija je negativna. Ukoliko je vrijednost r=0, onda korelacija nema, a ako je $|r|=1$, onda se govori o potpunoj korelacijskoj. Kada je $0 < |r| < 0,5$ radi se o slaboj korelacijskoj, za $0,5 \leq |r| < 0,8$ govori se o srednje jakoj korelacijskoj, dok $0,8 \leq |r| < 1$, predstavlja jaku korelacijsku (Paušić, 1993.).

2.2. Metoda višestruke linearne regresije

Kao što je ranije navedeno, često puta je za jednu zavisnu varijablu Y moguće izabrati više nezavisnih varijabli (X_1, \dots, X_n) koje pojedinačno nemaju velik utjecaj na Y, ali u zajedničkoj interakciji daju utjecaj na zavisnu varijablu Y. Važna pretpostavka jest ta da postoji veći broj mjerjenja (y_1, \dots, y_r) i ($x_{11}, \dots, x_{1r}, \dots, x_{n1}, \dots, x_{nr}$) nego koeficijenata koji se moraju odrediti: a_1, \dots, a_n i b. Isto tako, među parametrima X_1, \dots, X_n nema

korelacijske. Nepoznati koeficijenti određuju se pomoću diferencijalnog računa tako da se minimizira funkcija prema jednadžbi (2)

$$a = (a_1, \dots, a_n) \rightarrow \sum_{i=1}^r (y_i - x_{1i}a_1 - \dots - x_{ni}a_n - b)^2 \quad (2)$$

Navedeni izraz zapravo predstavlja zbroj kvadrata odstupanja procijenjene vrijednosti od prave vrijednosti varijable Y.

3. EKSPERIMENTALNI DIO

3.1. Opis lokacije jezera Motičnjak

Jezero Motičnjak (slika 1) nastalo je eksploatacijom aluvijalnih nanosa šljunka, ali danas jezero više nije upisano u registar eksploatacijskih polja šljunka, dok se vodene površine jezera manjim dijelom koriste kao kupalište i/ili za ribolov. Cijeli kompleks, tj. *Sportsko ribolovni centar SRC Aquacity Varaždin*, još se popularno naziva i „Varaždinsko more“. Obuhvaća ribnjak, jezero, uređeni okoliš i mnoge popratne sadržaje koji mu daju sportsko-rekreacijski karakter, a nalazi se u sjeverozapadnom dijelu Hrvatske nedaleko glavnog privrednog središta regije, grada Varaždina, na njegovom sjeveroistočnom rubu, ali teritorijem pripada općini Trnovec Bartolovečki. Udaljenost od državne ceste je svega 1 km, a od centra grada Varaždina 3 km, dok su okolna naselja udaljena oko 1-1,5 km.

Mreža vodoopskrbnih cjevovoda i hidranata izvedena je na većem dijelu općine, a na vodovodnu mrežu priključeno je 95 % stanovništva. Sustav odvodnje i pročišćavanja otpadnih voda na području općine značajan je problem s obzirom na razvijenu vodovodnu mrežu te na činjenicu da se na području općine nalazi i vodocrpilište. Naime, samo 5 % domaćinstava priključeno je na sustav odvodnje. Najzastupljenija grana stočarstva u općini je peradarstvo i svinjogradstvo, a veće farme locirane su unutar treće zone sanitarno zaštite vodocrpilišta. Postojeći uređaj za pročišćavanje komunalnih i industrijskih otpadnih voda (UPOV), slika 2, smješten u blizini jezera Motičnjak, nije dostatan za



Slika 1: Lokacija jezera Motičnjak

kvalitetno pročišćavanje svih otpadnih voda, već se višak otpadnih voda nakon mehaničkog pročišćavanja ispušta u drenažni kanal hidroelektrane Čakovec (Strateški plan razvoja turizma grada Varaždina do 2020.).

Ležište jezera Motičnjak sedimentnog je tipa te je utvrđena uzajamna sedimentacija zbog znatnog sezonskog kolebanja vode te jakog erozijskog djelovanja i čestog mijenjanja korita rijeke tokom geološke prošlosti. U ovisnosti o brzini neotektonskog sruštanja mijenjao se nagib riječnog korita, a time i brzina riječne struje koja je uvjetovala i promjenu granulometrijskog sastava šljunka (Malkoč, 1988.). Debljina šljunčanih naslaga povećava se od rubova bazena prema centralnom dijelu. U području Motičnjaka debljina šljunčanih naslaga iznosi oko 60 metara. Propusnost šljunkovito-pjeskovitih naslaga brzo se mijenja zbog promjena u granulometrijskom sastavu sedimenata, kako vertikalno tako i u horizontalnom smjeru. Koeficijent vodopropusnosti u šljuncima s pijeskom kreće se u granicama od 0.1 do 0.0001 cm/s, ali najčešće od 0.1 do 0.001 cm/s. Šljunčano-pjeskovite naslage napajaju se vodom toka rijeke Drave tijekom čitave godine, kako kod niskih, tako i kod visokih vodostaja, što jezero Motičnjak čini dobro povezanim s tokovima podzemnih voda, čime je smanjena mogućnost kvarenja vode stajačice (Jakopović, 2000.).

Na jezeru Motičnjak, odnosno na njegovom kupališnom dijelu, uzorkovanje je obavljeno na dvije lokacije: Laguna A i Laguna B (slika 2). Mjerenja pojedinih pokazatelja obavljena su „in situ“, odnosno na lokaciji neposredno nakon uzorkovanja. Pri svakom uzorkovanju voda za kupanje prate se i meteorološki uvjeti te eventualno vidljivo onečišćenje.



Slika 2: Mesta uzorkovanja: Laguna A i Laguna B

3.2. Određivanje fizikalno – kemijskih i mikrobioloških pokazatelja

Fizikalno-kemijski i mikrobiološki pokazatelji kakvoće vode određivani su na uzorku vode tijekom ljetnih mjeseci, tj. tijekom kupališne sezone na lokacijama Laguna A i Laguna B, od 2010. do 2015. godine. Od izmjerjenih fizikalno-kemijskih pokazatelja odabrani su pokazatelji koji utječu na životne zajednice u vodi (temperatura, pH vrijednost, otopljeni kisik,

elektrovodljivost, kemijska protrošnja kisika, KPK-a, odnosno utrošak $KMnO_4$ te m-vrijednost kojom se definiraju prisutni hidroksidi, odnosno alkalne tvari, karbonati i hidrogenkarbonati. Mikrobiološka analiza uzorka vode provedena je postupkom membranske filtracije. Membranski filteri za određivanje crijevnih enterokoka stavlju se na Slanetz – Bartley agar (Kvaliteta vode, 2014.), dok se membranski filteri za određivanje *E. coli* stavlju na CC agar (Kakvoća vode, 2000.; Kvaliteta vode, 2014.). Hranjive podloge inkubiraju se na 37 °C, a nakon 24 sata provodi se identifikacija porasta bakterijskih kolonija, dok se potvrđni test provodi nakon 48 sati. Detekcija i broj koliformnih bakterija određena je prema HRN EN ISO 9308-1:2014 (Kvaliteta vode, 2014.) za *Escherichia coli*, dok su crijevni enterokoki određeni prema HRN EN ISO 7899-2:2000 (Kakvoća vode, 2000.).

4. REZULTATI I RASPRAVA

4.1. Ocjena kakvoće vode

S obzirom da nema propisanih maksimalno dozvoljenih koncentracija fizikalno-kemijskih pokazatelja u važećoj Uredbi o kakvoći vode za kupanje (NN 51/14), uzete su mjerodavne vrijednosti iz prethodne Uredbe (NN 89/10), te je potvrđeno da su fizikalno – kemijski pokazatelji unutar dozvoljenih vrijednosti MDK-a, tj. da ne odstupaju od mjerene vrijednosti istih pokazatelja tijekom ranijih godina. Promatrane plaže na jezeru Motičnjak još uvjek nisu proglašene javnim kupalištem, iako su vrlo posjećeno kupalište u Varaždinskoj županiji. Budući da su monitoringom sakupljeni podatci o mikrobiološkim pokazateljima za višegodišnje razdoblje, može se napraviti ocjena kakvoće voda na kraju svake sezone te na kraju trogodišnjeg razdoblja. U tablicama 1 i 2 prikazani su rezultati mikrobioloških pokazatelja na temelju kojih se procjenjuje kakvoća vode za kupanje. Rezultati se temelje na izračunu 95 %-percentila (*) i 90 %-percentila (**). Iz rezultata je vidljivo da su *Escherichia coli* i crijevni enterokoki prisutni u jezeru Motičnjak, ali u vrlo malom broju, pa se na temelju toga može zaključiti da je kakvoća vode izvrsna i/ili zadovoljavajuća, a obzirom na Uredbu o kakvoći vode (NN 51/14), jezero Motičnjak može se preporučiti kao javno kupalište.

Unatoč primjetnim razlikama u vrijednostima, nije vidljiv trend kontinuiranog porasta/pada broja kolonija mikroorganizama koji bi ukazao na potencijalno onečišćenje. Pretpostavlja se da do odstupanja pojedinih vrijednosti mikrobioloških pokazatelja može doći uslijed promjene aerobnih uvjeta, meteoroloških prilika i povećanja broja kupača (López, I. et al., 2013.; Reeves, R. L. et al., 2004.; J.W. Marion, J. W. et al., 2015.). Na temelju ranijih istraživanja (Ptiček Siročić et al., 2016.) rezultati su pokazali da su *Escherichia*

Tablica 1: Izračunate vrijednosti u usporedbi sa standardima za ocjenu kakvoće voda za prethodne tri sezone kupanja – Laguna A

Pokazatelj	Izvrsna		Dobra		Zadovoljavajuća	Nezadovoljavajuća		
Crijevni enterokok (bik/100 ml)	≤200*	99,936	≤400*	99,936	≤330**	66,47	> 330**	66,47
<i>Escherichia coli</i> (bik/100 ml)	≤500*	233,276	≤1000*	233,276	≤900**	147,802	>900**	147,802

bik/100 ml: broj izraslih kolonija u 100 ml; izračun 95 %-percentila (*) i 90 %-percentila (**).

Tablica 2: Izračunate vrijednosti u usporedbi sa standardima za ocjenu kakvoće voda za prethodne tri sezone kupanja – Laguna B

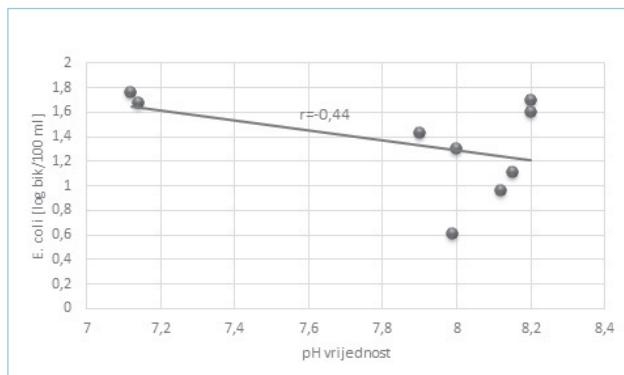
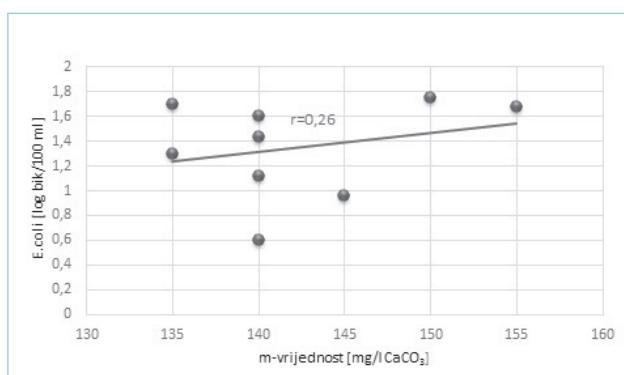
Pokazatelj	Izvrsna		Dobra		Zadovoljavajuća	Nezadovoljavajuća		
Crijevni enterokok (bik/100 ml)	≤200*	46,56	≤400*	46,56	≤330**	32,05	> 330**	32,05
<i>Escherichia coli</i> (bik/100 ml)	≤500*	248,3	≤1000*	248,3	≤900**	134,9	>900**	134,9

bik/100 ml: broj izraslih kolonija u 100 ml; izračun 95 %-percentila (*) i 90 %-percentila (**).

co/i i crijevni enterokoki prisutni u obje lagune, ali je broj bakterija znatno veći u laguni A, nego u laguni B. Razlog tome je manja dubina lagune A, pri čemu je voda znatno toplijia i prisutan je veći broj kupača, što potvrđuje utjecaj broja osoba na mikrobiološku kontaminaciju vode. Nadalje, blizina farme i postojeći uređaj za pročišćavanje otpadnih voda, na kojem velik dio opterećenja potječe iz industrijskih otpadnih voda koje su opterećene suspendiranim tvarima, organskim tvarima, masnoćama i drugim spojevima, zasigurno doprinosi povećanim koncentracijama mikrobioloških pokazatelja u vodi. Također, uslijed nerazvijenosti sustava odvodnje i neadekvatnog pročišćavanja otpadnih voda, tj. nekontroliranog ispuštanja otpadnih voda prisutno je onečišćenje okolnih vodotokova koji mogu utjecati na prisutnost povećanog broja bakterija u vodi.

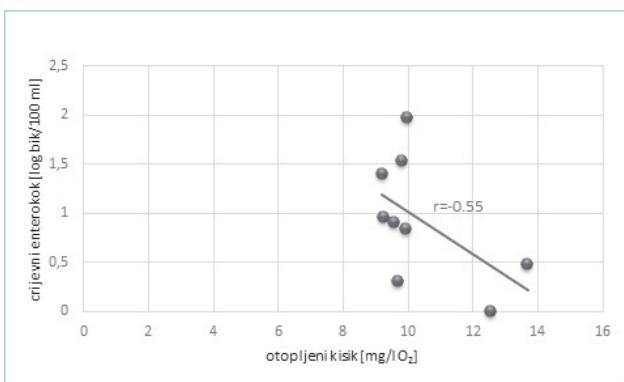
4.2. Uspostava višestrukih modela regresije

Na temelju rezultata fizikalno-kemijskih i mikrobioloških pokazatelja kakvoće vode za razdoblje ljetnih mjeseci od 2010. do 2015. godine, određena je statistička povezanost između navedenih pokazatelja u vodi za kupanje. Drugim riječima, pokušalo se odrediti postoji li povezanost između fizikalno-kemijskih pokazatelja i broja *Escherichiae coli* i crijevnog enterokoka u vodi za kupanje. Na temelju izmjerenih fizikalno-kemijskih pokazatelja odabrani su pokazatelji koji znatnije utječu na količinu mikrobioloških pokazatelja te je definiran matematički model koji može poslužiti u predikciji količine mikrobioloških pokazatelja u narednim godinama. Jednostavnim modelom regresijske tehnike ustanovaljena je ovisnost (korelacija) između pojedinog mikrobiološkog pokazatelja i fizikalno-kemijskog pokazatelja. Dakle, korištena je tehnika određivanja koeficijenta korelacijske

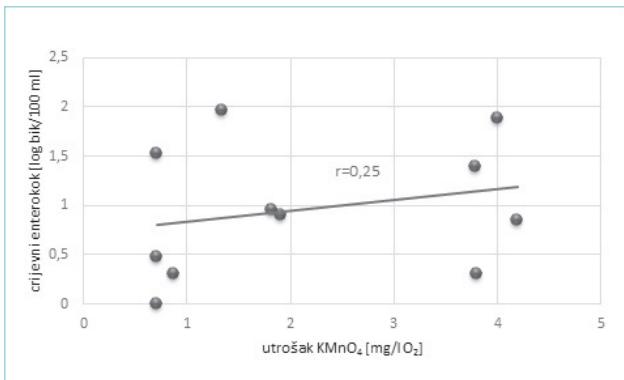
Slika 3: Dijagram raspršenja: pH-vrijednost – *Escherichia coli*Slika 4: Dijagram raspršenja: m-vrijednost – *Escherichia coli*

između dviju veličina, odnosno između mikrobiološkog pokazatelja i fizikalno-kemijskog pokazatelja. Na slikama 3, 4, 5 i 6 nalaze se dijagrami raspršenja za pojedine fizikalno-kemijske pokazatelje i mikrobiološke pokazatelje te je ucrtan pravac regresije s naznačenim izračunatim Pearsonovim koeficijentom korelacijske.

Na slikama 3 i 5 prikazani su dijagrami raspršenja s izračunatim pripadajućim koeficijentima korelacijske



Slika 5: Dijagram raspršenja: otopljeni kisik – crijevni enterokok

Slika 6: Dijagram raspršenja: utrošak KMnO₄ – crijevni enterokok

ucrtanim pravcima regresije koji su padajući. Budući da su u tim slučajevima koeficijenti korelacije negativni, vidljiva je negativna korelacija između mikrobiološkog pokazatelja *E. coli* i fizikalno-kemijskog pokazatelja pH-vrijednosti te crijevnog enterokoka i fizikalno-kemijskog pokazatelja otopljenog kisika. Na slike 4 i 6 prikazani su dijagrami raspršenja s izračunatim pripadajućim koeficijentima korelacije i ucrtnim pravcima regresije koji su u ovom slučaju rastući. Koeficijenti korelacije su pozitivni pa je i korelacija između *E. coli* i fizikalno-kemijskog pokazatelja m-vrijednosti pozitivna kao i korelacija između mikrobiološkog pokazatelja crijevnog enterokoka i fizikalno-kemijskog pokazatelja KPK-a, tj. utroška KMnO₄.

U tablici 3 prikazane su vrijednosti svih korelacijskih koeficijenata između pojedinog mikrobiološkog i fizikalno-kemijskog pokazatelja.

Tablica 3: Korelacijski koeficijenti mikrobioloških i fizikalno-kemijskih pokazatelja

Pokazatelj	pH	Otopljeni kisik	Temperatura	KPK (utrošak KMnO ₄)	Elektrovodljivost	m-vrijednost
<i>Escherichia coli</i> (bik/100 ml)	-0,44	-0,68	0,29	0,10	0,089	0,26
Crijevni enterokok (bik/100 ml)	0,12	-0,55	-0,10	0,25	-0,40	-0,02

bik/100 ml: broj izraslih kolonija u 100 ml.

Budući da su gotovo svi izračunati koeficijenti korelacije po absolutnoj vrijednosti manji od 0,5, u svim međusobnim odnosima mikrobioloških i fizikalno-kemijskih pokazatelja utvrđena je slaba korelacija, osim u odnosu između vrijednosti otopljenog kisika i *E.coli*, odnosno crijevnog enterokoka, gdje se radi o srednje jakoj korelacijskoj. U ovakvoj situaciji uputno je za svaki mikrobiološki pokazatelj izabrati samo one fizikalno-kemijske pokazatelje za koje je $|r| \geq 0,25$, odnosno koji na njih imaju značajniji utjecaj (Tedeschi, 1997.). Iz tog su razloga navedeni pokazatelji uzeti kao nezavisne veličine u višestrukoj regresijskoj analizi.

Za mikrobiološki pokazatelj *Escherichia coli* značajniji utjecaj imaju fizikalno-kemijski pokazatelji: pH vrijednosti ($r = -0,44$), otopljeni kisik ($r = -0,68$), temperatura ($r = 0,29$) i m-vrijednost ($r = 0,26$), a za mikrobiološki pokazatelj crijevni enterokok, fizikalno-kemijski pokazatelji koji imaju značajniji utjecaj prema korelacijskoj analizi su elektrovodljivost ($r = -0,40$), otopljeni kisik ($r = -0,55$) i utrošak KMnO₄ ($r = 0,25$).

Općenito, nastojalo se formulirati model višestruke linearne regresije oblika prema jednadžbi (3)

$$y = a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (3)$$

gdje je y mikrobiološki pokazatelj, x_1, \dots, x_n su izabrane nezavisne varijable (fizikalno-kemijski pokazatelji koji imaju značajniji utjecaj na mikrobiološki pokazatelj). Mikrobiološki pokazatelji označeni su sljedećim oznakama: pokazatelj *Escherichia coli* (B1) i crijevni enterokok (B2).

Za mikrobiološki pokazatelj *Escherichiae coli* dobiven je sljedeći model višestruke regresije, jednadžba (4):

$$B1 = 2,84pH - 0,07x + 0,14y + 0,002z - 24,35 \quad (4)$$

gdje je pH vrijednost fizikalno-kemijskog pokazatelja pH vrijednost, x vrijednost fizikalno-kemijskog pokazatelja otopljeni kisik, y vrijednost fizikalno-kemijskog pokazatelja temperatura, a z vrijednost fizikalno-kemijskog pokazatelja m-vrijednost. Koeficijent korelacije ovog modela iznosi 0,94.

Iz ovog je modela vidljivo da je vrijednost mikrobiološkog pokazatelja B1 obrnuto proporcionalna vrijednostima fizikalno-kemijskog pokazatelja x te proporcionalna vrijednosti fizikalno-kemijskih

pokazatelja pH, y i z. To znači, da što je veća količina otopljenog kisika, to će biti manja količina *Escherichiae coli* u vodi za kupanje. Suprotno tome, što je veća vrijednost pH vrijednosti vode za kupanje, temperaturre i m-vrijednosti, to će biti veća količina *Escherichiae coli* u vodi za kupanje. Navedeno potvrđuju negativnu predznaci ispred pokazatelja otopljenog kisika te pozitivne vrijednosti ispred pokazatelja veličina pH, y i z. *Escherichia coli* ovisna je o promjeni kisika u pridnenom sloju vodnog sustava, dok su enterokoki sposobni dulje preživjeti, posebice u jezerskim staništima uslijed anaerobnih prilika, te su kao takvi prikladniji pokazatelj fekalnog onečišćenja vode, prema Zakonu o vodama (NN 153/09, 130/11, 56/13, 14/14).

Za mikrobiološki pokazatelj crijevni enterokok dobiven je sljedeći model višestruke regresije, jednadžba (5):

$$\beta_2 = -0,02E - 0,12x + 0,06w + 7,15 \quad (5)$$

gdje je w = vrijednost fizikalno-kemijskog pokazatelja utrošak KMnO₄, a E = vrijednost fizikalno-kemijskog pokazatelja elektrovodljivost. Koeficijent korelacije ovog modela iznosi 0,82. Iz ovog je modela vidljiva proporcionalna ovisnost vrijednosti fizikalno-kemijskog pokazatelja B2 o fizikalno-kemijskom pokazatelju utrošak KMnO₄, a obrnuto proporcionalna vrijednosti fizikalno-kemijskog pokazatelja elektrovodljivosti i otopljenog kisika. To znači, da što je manja vrijednost elektrovodljivosti i otopljenog kisika, te veća vrijednost utroška KMnO₄ u uzorku vode, to se očekuje manja količina crijevnog enterokoka u vodi za kupanje.

Matematički model prikazan jednadžbom (4) može se koristiti kao model za predikciju vrijednosti količine *Escherichiae coli* iz izmjerene vrijednosti fizikalno-kemijskih pokazatelja: pH vrijednost, količina otopljenog kisika, temperatura i m-vrijednost. Slično, model prikazan jednadžbom (5) može se koristiti kao model za predikciju vrijednosti količine crijevnog enterokoka iz izmjerene vrijednosti fizikalno-kemijskih

pokazatelja: otopljenog kisika, utroška KMnO₄ i elektrovodljivosti. Modeli višestruke linearne regresije opisani jednadžbama (4) i (5) u ovom su slučaju potpuniji odabir od modela jednostavne linearne regresije, zato što se višestrukom linearnom regresijom uzima u obzir ne samo ovisnost mikrobiološkog pokazatelja o fizikalno-kemijskim pokazateljima, već i međusobna ovisnost dvaju ili više fizikalno-kemijskih pokazatelja, a što potvrđuju i visoki koeficijenti korelacije za opisane modele (oba koeficijenta su preko 80 %).

5. ZAKLJUČAK

Bez provođenja monitoringa i ocjenjivanja kakvoće vode za kupanje te bez uvida javnosti u dobivene podatke, kupači mogu biti izloženi brojnim zarazama. Informiranost javnosti ključan je parametar za sprečavanje štetnih utjecaja potencijalnog onečišćenja, čime se doprinosi zaštiti zdravlja kupača. Primjenom korelacijske analize i uspostavom matematičkih modela moguće je utvrditi statističku povezanost između pojedinih fizikalno-kemijskih i mikrobioloških pokazatelja kakvoće vode za kupanje. Rezultati ukazuju na povezanost koliformnih bakterija *Escherichia coli* i crijevnih enterokoka s pH vrijednosti, temperaturom, koncentracijom otopljenog kisika, elektrovodljivosti, KPK-a i m-vrijednosti te je na temelju dobivenih matematičkih modela moguće predvidjeti ponašanje i utjecaj bakterija na zdravlje ljudi tijekom budućeg razdoblja. S obzirom na učestalu promjenu klimatskih uvjeta i promjenu stanja ekosustava na pojedinim lokacijama, potrebno je uzeti u obzir dulji vremenski period kako bi se sa sigurnošću mogao utvrditi matematički model koji bi dao što precizniju predikciju ovisnosti mikrobioloških pokazatelja o fizikalno-kemijskim, kao i ostalim pokazateljima kakvoće vode. U sklopu budućih istraživanja u okvirima dane problematike bilo bi korisno ispitati korelacijske odnose pokazatelja kakvoće vode koristeći i druge metodologije, odnosno statističke analize, genetske algoritme, ekspertne sisteme, neuralne mreže i drugo. ■

LITERATURA

- Imamović, A.; Trožić-Borovac, S.; Škrijelj, R. (2015.): Međuzavisnosti ekoloških determinanti kakvoće voda na rijeci Bosni. *Hrvatske vode*, 23, 1-10.
- Jakopović E. (2000.): Proizvodnja šljunčanih agregata u šljunčari Motičnjak; Sveučilište u Zagrebu, Geotehnički fakultet Varaždin.
- Kakvoća vode – Detekcija i brojenje crijevnih enterokoka, 2. dio: Metoda membranske filtracije (HRN EN ISO 7899-2:2000).
- Kvaliteta vode – Brojenje *Escherichia coli* i koliformnih bakterija, 1. dio: Metoda membranske filtracije za vode s niskom pozadinom bakterijske flore (HRN EN ISO 9308-1:2014).
- López, I.; Álvarez, C.; Gi Luis, J.; García, A.; Bárcena, J.F.; Revilla, J.A. (2013.) Method for the source apportionment in bathing waters through the modeling of wastewater discharges: development of an indicator and application to an urban beach in Santander (Northern Spain). *Ecological Indicators*, 24, 334–343.
- Malkoč B. (1988.): Prikaz rada separacije šljunka Motičnjak kraj Varaždina; RGN Fakultet Sveučilišta u Zagrebu, Viša geotehnička škola Varaždin.
- Marion, J.W.; Burrowes, V.; Lee, C.S., Lee, L. (2015.) Changes in microbial water quality associated with an extreme recreational water event in Ohio, United States. *Water Quality, Exposure and Health*, 7 (4), 491–501.
- Okvirna direktiva o vodama (2000.), 2000/60/EZ Europski parlament i Vijeće.
- Pauše Ž. (1993.): *Uvod u matematičku statistiku*. Školska knjiga, Zagreb.
- Ptiček Siročić A.; Loborec J.; Hajdinjak A. (2016.): Water quality management – monitoring of bathing water on lake Motičnjak, Croatia. *Book of Proceedings of 4th International Symposium on Environmental Management – Towards Circular Economy*, (ur. Katančić Z et al.), 80-87, University of Zagreb, Faculty of Chemical Engineering and Technology.
- Reeves, R.L.; Grant, S.B.; Mrse, R.D.; Sanders, B.F.; Boehm, A.B. (2004.). Scaling and management of fecal indicator bacteria in runoff from a coastal urban watershed in Southern California, *Environmental Science & Technology* 38 (9), 2637–2648.
- Strateški plan razvoja turizma grada Varaždina do 2020.
- Tedeschi, S. (1997.): *Zaštita voda*. Hrvatsko društvo građevinskih inženjera, Sveučilišna tiskara Zagreb.
- Uredba o kakvoći voda za kupanje (NN 89/10)
- Uredba o kakvoći voda za kupanje (NN 51/14)
- Zakon o vodama (NN 153/09, 130/11, 56/13, 14/14)

Correlation analysis of water quality indicators for Lake Motičnjak

Abstract. The paper contains a correlation analysis of individual water quality indicators. A linear regression model and multiple regression model were used for determining a statistical connection between the physico-chemical indicators and microbiological indicators of bathing water quality exemplified by Lake Motičnjak. The physico-chemical indicators and microbiological indicators of water quality were determined on the water samples during bathing seasons in two locations at Lake Motičnjak in the period from 2010 to 2015. The results indicated that there was a connection between individual physico-chemical indicators and microbiological indicators of *Escherichia coli* (E.coli) and *intestinal enterococci* (IE).

Key words: physico-chemical indicators, microbiological indicators, bathing water quality, correlation analysis, multiple regression models

Die Korrelationsanalyse von Indikatoren für die Wasserqualität im See Motičnjak

Zusammenfassung. In der Arbeit wird die Korrelationsanalyse einzelner Indikatoren für die Wasserqualität durchgeführt. Anhand eines linearen Regressionsmodels und eines mehrfachen Regressionsmodels wurde am Beispiel des Sees Motičnjak statistischer Zusammenhang zwischen physikalischen und chemischen einerseits und mikrobiologischen Indikatoren für die Badewasserqualität andererseits festgestellt. Die physikalischen, chemischen und mikrobiologischen Indikatoren wurden bei den Wasserproben an zwei Lokalitäten am See Motičnjak im Laufe der Badesaisonen zwischen 2010 und 2015 bestimmt. Die Ergebnisse zeigten, dass ein Zusammenhang zwischen einzelner physikalischen und chemischen Indikatoren einerseits und mikrobiologischen Indikatoren *Escherichia coli* und *Enterokokken* andererseits besteht.

Schlüsselwörter: Ophysikalische und chemische Indikatoren, mikrobiologische Indikatoren, Badewasserqualität, Korrelationsanalyse, mehrfache Regressionsmodelle