

PRISTUP MODELIRANJU PRIRODNE KONVEKCIJE U AKUMULACIJSKIM JEZERIMA: PRIMJER AKUMULACIJE BUTONIGA

Luka Zaharija, mag. ing. aedif.

Građevinski fakultet Sveučilišta u Rijeci
Radmile Matejčić 3, 51000 Rijeka
luka.zaharija@student.uniri.hr

Davor Stipanić, mag. ing. aedif.

Hidromodeling d.o.o.
Mrkopaljska 7, 51000 Rijeka

Vanja Rački, dipl. ing. građ.

Hrvatske vode,
VGO za slivove sjevernog Jadrana
Đure Šporera 3, 51000 Rijeka

doc. dr. sc. Maja Oštrić, dipl. ing. geol.

Hrvatske vode,
VGO za slivove sjevernog Jadrana
Đure Šporera 3, 51000 Rijeka

**izv. prof. dr. sc. Vanja Travaš,
dipl. ing. građ.**

Građevinski fakultet Sveučilišta u Rijeci
Radmile Matejčić 3, 51000 Rijeka

U kontekstu gospodarenja umjetnim akumulacijskim jezerima, prirodna konvekcija, tj. protok mase vode koji nastaje kao posljedica temperaturnog gradijenta, je posebno važan fizikalni proces koji može značajno utjecati na proces odlučivanja i na model upravljanja akumulacijom. Navedeno će se u ovom radu ilustrirati na primjeru akumulacijskog jezera Butoniga gdje prirodna konvekcija ima posebno važan značaj. U ljetnom se periodu u akumulaciji Butoniga formira termoklina te se u donjem pridenom sloju induciraju anoksični uvjeti koji uz prisustvo mulja na dnu jezera i putem bioloških i kemijskih procesa značajno narušavaju kakvoću vode u tom području. Sve dok postoji uravnotežena temperaturna stratifikacija, spriječeno je miješanje ovakvog anoksičnog sloja s preostalom vodom. Međutim, putem progresivnog pada srednje vrijednosti temperature zraka u ranojesenskom periodu se i gornji sloj vode hladi i započinje značajno vertikalno strujanje koje može putem prirodne konvekcije prouzročiti miješanje anoksičnog sloja i ugroziti kakvoću preostale vode u akumulaciji. Iz tog je razloga potrebno preduhitriti trenutak aktivacije vertikalnih strujanja i provesti pražnjenje akumulacije iz pridenog sloja. Donošenje odluke o trenutku pražnjenja akumulacije je vrlo složen proces koji iziskuje utemeljenje u prethodno provedenim terenskim mjerenjima i vrlo kompleksnim računalnim simulacijama. Nakon utvrđivanja najprikladnijeg vremena pražnjenja, što iziskuje opsežnu parametarsku analizu, pažnja se predaje utvrđivanju najučinkovitije dinamike pražnjenja, što je i tema ovog rada.

Ključne riječi: jezero Butoniga, ranojesensko ispuštanje, numerički model, OpenFOAM

1. UVOD

Prirodna konvekcija je fizikalni proces koji dovodi do protoka mase fluida uzrokovanim gradijentom temperature. Razlika u polju temperature unutar kontinuirane i homogene mase fluida utječe na izmjenu gustoće vode te tako nastaje strujanje kao posljedica

uzgonskih sila. Ovakvi oblici strujanja nisu rijetkost u akumulacijskim jezerima, a istovremeno imaju izuzetan značaj u kontekstu osiguravanja potrebne kakvoće vode. Naime, procesom prirodne konvekcije se najčešće formiraju vertikalna strujanja kod kojih polje brzine

uzrokuje premještanje suspendiranih tvari s donjeg sloja u gornje slojeve akumulacija, i obrnuto. Drugim riječima, prirodna konvekcija uzrokuje miješanje vode u akumulaciji i time utječe na procese odlučivanja koji imaju za zadatak osigurati zadani standard kakvoće vode. Ovo je naročito izraženo u ljetnim mjesecima kada se formira termoklina uz prisustvo mulja na dnu jezera. Naime, u tom periodu jasno artikulirana termoklina dovodi do mobiliziranja pridnenog sloja vode, koji zbog veće gustoće od ostale vode zauzima dno jezera unutar kojeg se tijekom vremena formiraju anoksični uvjeti. U ovakvim okolnostima biološki i kemijski procesi na dnu jezera prekrivenim muljem dovode do oslobađanja sumporovodika, dušičnih spojeva, željeza, mangana, fosfora itd.. Posljedično, pridnenom sloju vode opada kakvoća te u ovakvim okolnostima prirodna konvekcija postaje prijetnja koja može putem miješanja ugroziti kvalitetu preostale vode u akumulacijskom jezeru.

Sprječavanje miješanja vode u gore navedenim okolnostima nije moguće izbjeći, ali je moguće kroz temeljni ispušt ispuštiti vodu iz pridnenog sloja i tako spriječiti miješanje anoksičnog sloja s preostalom vodom. Pritom, definiranje najprikladnijeg trenutka za ispuštanje vode nije jednostavan zadatak, a ujedno ni tema ovog rada. Pritom je prikladno kratko se osvrnuti na ovakav inženjerski zadatak. Naime, postupak ispuštanja vode mora preduhitriti prirodnu konvekciju koja će se sigurno dogoditi u narednom vremenskom periodu kada u ranu jesen počinje opadati srednja vrijednost temperature zraka koja će hladiti gornje slojeve vode. Ohlađenoj vodi će porasti gustoća te će se formirati vertikalna strujanja putem kojih će voda iz anoksičnog sloja prenijeti suspendirane tvari u gornje dijelove akumulacije. S druge strane, ranije ispuštanje vode, koje se može činiti kao prikladno rješenje, isto tako nije prihvatljivo, jer se u tom slučaju ostavlja vremenski prostor do ranojesenskog perioda unutar kojeg se putem istih biološki i kemijskih procesa pridneni sloj vode opet opterećuje suspendiranim tvarima. U ovom je slučaju redukcija kakvoće vode manje izražena, radi manjeg vremena izlaganja anoksičnim uvjetima, ali još uvijek neprihvatljivo. Dakle, ispuštanje vode mora biti itekako dobro tempirano kako bi se pridneni anoksični sloj ispuštio točno u vremenu kada započinje proces prirodne konvekcije. U takvim okolnostima vertikalnim miješanjima bi se razmjenjivala voda nenarušene kakvoće. Jednom kada je utvrđeno vrijeme iniciranja pražnjenja, pristupa se problemu maksimizacije učinkovitosti pražnjenja, odnosno utvrđivanju najprikladnije dinamike pražnjenja. Ovim se radom daje doprinos upravo u segmentu postizanja najučinkovitije dinamike pražnjenja, dok tematika utvrđivanja najprikladnijeg trenutka pražnjenja nije direktno obuhvaćena. Ovakva analiza zahtjeva opsežnu parametarsku studiju koja prelazi granice ovog rada.

U svrhu analiziranja ranojesenskog ispuštanja na akumulaciji Butoniga, napravljen je numerički model koristeći programski paket OpenFOAM (OpenCFD, 2016.).

Model uključuje trodimenzionalnu analizu turbulentnog strujanja vode, energetska jednadžbu u svrhu definiranja vertikalnih strujanja induciranih gradijentom temperature (prirodna konvekcija) te transport pasivnog skalara. Numerički model se koristio u svrhu sagledavanja različitih scenarija pražnjenja akumulacije s posebnim osvrtom na učinkovitost ispuštanja nepoželjnih tvari iz pridnenog anoksičnog sloja. Naime, dosad su u ovakvim slučajevima trenutak ispuštanja vode i protok na temeljnom ispustu određivali prvenstveno iskustveno. Za slučaj akumulacijskog jezera Butoniga, ispuštanje vode se u proteklim godinama provodilo sve dok se razina vode u jezeru ne spusti za 1 m. Do 2016. godine protoci na temeljnom ispustu iznosili su od 10 do 16 m³/s. Ranijim analizama je utvrđeno da se primjenom manjih protoka ispusti veća količina vode iz pridnenog sloja, 2016. godine je protok na temeljnom ispustu bio 3 m³/s. Iste godine su provodila svakodnevna uzorkovanja vode za potrebe mjerenja fizikalnih veličina poput temperature vode i masene koncentracije mangana, željeza, fosfata te ostalih kemijskih spojeva (Mihelčić et al., 2017.). Točke na kojima su se provodila uzorkovanja prikazane su na slici 1. Podatci prikupljeni terenskim mjerenjima iz 2016. godine će se koristiti u svrhu kalibracije numeričkog modela. Kalibrirani numerički model će se potom koristiti u svrhu analiziranja utjecaja različitih protoka na učinkovitost ispuštanja štetnih spojeva iz pridnenog sloja.



Slika 1: Položaji mjernih položaja na kojima su se 2016. g. vršila uzorkovanja vode u svrhu mjerenja temperature vode i koncentracije različitih suspendiranih tvari. U svrhu kalibracije numeričkog modela su se koristili podatci prikupljeni za točku B1 (kao najreprezentativniju točku za vertikalni raspored temperature vode i masene koncentracije mangana)

Treba svakako spomenuti da je akumulacijsko jezero Butoniga u nekoliko navrata i ranije bilo predmet numeričkih modeliranja. Neke ranije analize su pronos suspendirane tvari opisivale Lagrangeovom metodom

diskretnih čestica. Za razliku od spomenutog pristupa, u ovom se radu pronos tvari definirao rješavajući jednadžbu polja masene koncentracije tvari koja opisuje pronos pasivnog skalara, uključujući utjecaj turbulentne difuzije. Osim navedenoga, po prvi je puta uz opisivanje prostornog rasporeda temperature, koje je u jednom od ranijih pristupa sprovedeno rješavajući difuzivnu jednadžbu s nejednolikim koeficijentom turbulentne toplinske difuzije (Lozzi-Kožar, 2012.) unijeta i dinamika toka vode uvažavajući turbulentnu energetska kaskadu uvođenjem prikladnog turbulentnog modela.

2. TEORIJSKI MODEL TOKA

Teorijski model toka mora oformiti sustav jednadžbi putem kojeg će se opisati prirodna i prisilna konvekcija tijekom ranojesenskog ispuštanja vode te pronos masene koncentracije suspendiranih tvari koje ugrožavaju kakvoće vode u pojedinim dijelovima akumulacije. Za proračun toka vode u rijekama, jezerima i morima najčešće se rješavaju jednadžbe plitkih voda (Kim et al., 2005.; Shen et al., 2002.; Simons, 1974.). Pritom, kako je za njihovu primjenu ključno da je pretpostavka hidrostatskog rasporeda tlaka opravdana, pad tlaka uzrokovan otvaranjem temeljnog ispusta sprječava njihovu primjenu u slučaju ranojesenskog ispuštanja iz akumulacije. Iz tog razloga, kao i u nekim drugim radovima (Abbasi et al., 2016.), pristupa se rješavanju proračunski mnogo zahtjevnijih Navier-Stokesovih jednadžbi. Koristeći indeksni zapis vektorskih veličina, sustav jednadžbi napisan za jedinični volumen fluida je definiran skalarnom jednadžbom očuvanja mase, koja za nekompresibilni fluid poprima oblik

$$\frac{\partial}{\partial x_i}(u_i) = 0 \quad (1)$$

i vektorskim jednadžbama očuvanja količine gibanja

$$\frac{\partial}{\partial t}(u_i) + u_j \frac{\partial}{\partial x_j}(u_i) = -\frac{1}{\rho} \frac{\partial p}{\partial x_i} + \nu \frac{\partial^2}{\partial x_j \partial x_j}(u_i) + \frac{1}{\rho} f_i \quad (2)$$

gdje u_i označava vektor brzine toka [L^1T^{-1}], indeks i označava prostorne koordinate vektorske veličine, p označava tlak [$M^1L^{-1}T^{-2}$], ρ označava gustoću fluida [M^1L^{-3}], ν označava kinematičku viskoznost fluida [L^2T^{-1}], f_i vektor volumnih sila [$M^1L^{-1}T^{-2}$] te x_i označava vektor prostorne koordinate i [L^1], a t označava vremensku koordinatu [T^1]. Modeliranje prirodne konvekcije se provodi na temelju Bossinesqove aproksimacije (Wang, 2000.). Tako ako se za gravitacijsku silu f_i (reduciranu na jedinični volumen) usvoji iznos ρg_i , gdje je g_i vektor ubrzanje sile teže [L^1T^{-2}], tada se gustoća fluida ρ može aditivno rastaviti na konstantni dio ρ_σ koji se odnosi na referentnu temperaturu T [Θ^1] od koje započinje numerička simulacija, i dio koje se linearno dovodi u vezu

s temperaturnom promjenom ΔT . Matematički model gustoće ρ se tako može formulirati u obliku

$$\rho = \rho_0 - \alpha \rho_0 \Delta T \quad (3)$$

gdje α predstavlja koeficijent termalne ekspanzije fluida [Θ^{-1}]. Koristeći matematički model gustoće 3, jed. 2 poprima oblik

$$\frac{\partial}{\partial t}(u_i) + u_j \frac{\partial}{\partial x_j}(u_i) = -\frac{1}{\rho} \frac{\partial p}{\partial x_i} + \nu \frac{\partial^2}{\partial x_j \partial x_j}(u_i) + g_i \alpha \Delta T \quad (4)$$

Na ovaj je način omogućeno da se utjecaj izmjene gustoće fluida odrazi samo na kvantifikaciju uzgonske sile, tj. na posljednji član jed. 4, dok se u preostalim članovima gustoća usvaja konstantnom. Drugim riječima, izmjena gustoće uslijed izmjene temperature se uključuje prikladnom kvantifikacijom uzgonske sile. Istraživanja su pokazala da je za provedbu numeričkih simulacija od praktičnog značenja ova aproksimacija opravdana za slučaj u kojem se temperatura vode kreće u rasponu od 7°C i 23°C (Ferziger et al., 2002.).

2.1. Izbor turbulentnog modela

Ako se samo točnost proračuna usvoji kao kriterij za izbor prikladnog turbulentnog modela, onda treba u prvom redu primijetiti da veličina prostorne domene toka u akumulacijskim jezerima ne ide u prilog primjeni sofisticiranijim modelima turbulencija kao što su oni temeljeni na LES paradigmi (Large Eddy Simulation). Istovremeno, niti veličina vremenske domene ne idu u prilog ovakvom izboru, i to iz razloga jer ispuštanje vode iz akumulacijskih jezera u svrhu snižavanja razine za samo jedan metar može trajati i više dana (kao što je i za slučaj jezera Butoniga). Iz tog je razloga potrebno unijeti kompromisno rješenje putem kojeg će se s jedne strane omogućiti korištenje rentabilne diskretizacije prostora, koja neće prekomjerno opteretiti raspoložive računalne resurse i omogućiti modeliranje fizikalnih procesa kroz duži vremenski period, te s druge strane istovremeno uključiti opis turbulentne energetske kaskade koji će dovesti do rezultata od praktičnog značaja. Navedeno uvjetuje da se manje prostorne i vremenske skale turbulentnih fluktuacija moraju opisati uvodeći dodatne konstitutivne jednadžbe. Ovakav pristup je moguć unutar RANS paradigme (Reynolds averaged Navier–Stokes) u kojoj se putem *Reynoldsove dekompozicije* sudjelujućih fizikalnih polja provodi osrednjavanje osnovnih jednadžbi toka. Dakle, ako se unutar vremenskog perioda ΔT_s između vremena t_0 i $t_0 + \Delta T_s$ srednja vrijednost \bar{q} neke fizikalne veličine q definira na naredni način

$$\bar{q} = \lim_{\Delta T_s \rightarrow \infty} \frac{1}{\Delta T_s} \int_{t_0}^{t_0 + \Delta T_s} q(t) dt \quad (5)$$

vektor brzine toka u_i u turbulentnom režimu strujanja je tada moguće zapisati u obliku zbroja njegove srednje

vrijednost \bar{u}_i i karakterističnog odstupanja δu_i u vremenu osrednjavanja ΔT_s . Postupak Reynoldsove dekompozicije se može primijeniti za sva sudjelujuća fizikalna polja (tlaka, brzine, temperature i masene koncentracije). Koristeći ovakav zapis polja brzine u_j vremensko osrednjavanje jednadžbe očuvanja mase (1) će dovesti do jednadžbe

$$\frac{\partial \bar{u}_i}{\partial x_i} = 0 \quad (6)$$

te ako se na isti način provede zapis skalarnog polja tlaka p , postupak vremenskog osrednjavanja će jed. 2 pretvoriti u oblik (Pope, 2000.)

$$\frac{\partial}{\partial t}(\bar{u}_i) + \bar{u}_j \frac{\partial}{\partial x_j}(\bar{u}_i) = -\frac{1}{\rho} \frac{\partial \bar{p}}{\partial x_i} + \nu \frac{\partial^2}{\partial x_j \partial x_j}(\bar{u}_i) + \frac{1}{\rho} f_i - \frac{\partial(\overline{\delta u_i \delta u_j})}{\partial x_j} \quad (7)$$

u kojoj posljednji član s desne strane uključuje prisustvo turbulentnih fluktuacija i time uvodi utjecaj turbulencije u matematički opis strujanja. Ukoliko se jed. 7 pomnoži s gustoćom fluida ρ , izraz $-\rho \delta u_i \delta u_j$ u posljednjem članu predstavlja *Reynoldsov tenzor turbulentnih napreznja* i kvantifikacija njegovih komponenti se temelji na Bossinesqovoj hipotezi koja pretpostavlja da se turbulentna napreznja mogu tretirati analogno viskoznom napreznjama u laminarnom toku fluida. Na taj se način komponente Reynoldsovog tenzora napreznja dovode u proporcionalni odnos s komponentama lokalnog tenzora brzine deformacije S_{ij}

$$S_{ij} = \frac{1}{2} \left(\frac{\partial u_j}{\partial x_i} + \frac{\partial u_i}{\partial x_j} \right) \quad (8)$$

putem konstitutivne jednadžbe

$$-\rho \overline{\delta u_i \delta u_j} = 2\mu_t S_{ij} - \frac{2}{3} \rho k \delta_{ij} \quad (9)$$

u kojoj δ_{ij} predstavlja Kronecker delta, a k predstavlja lokalnu turbulentnu kinetičku energiju [$M^2 T^{-2}$] definiranu u obliku

$$k = \frac{1}{2} \left(\overline{\delta u_1 \delta u_1} + \overline{\delta u_2 \delta u_2} + \overline{\delta u_3 \delta u_3} \right) \quad (10)$$

a veličina μ_t definira skalarno svojstvo toka koje se naziva *dodana dinamička turbulentna viskoznost* [$M^1 L^{-1} T^{-1}$]. Ova veličina zavisi o karakteristikama toka, a ne o karakteristikama fluida, te se za slučaj takozvanih dvoparametarskih turbulentnih modela može kvantificirati u obliku

$$\mu_t = \rho C_\mu \frac{k^2}{\varepsilon} \quad (11)$$

gdje ε definira lokalnu brzinu disipacije turbulentne kinetičke energije [$L^2 T^{-3}$], a C_μ konstanta proporcionalnosti

koja je posebno važna u kontekstu ovog rada. Naime, u okviru razmatrane kategorije turbulentnih modela većina njih se bazira na pretpostavci da je C_μ konstantna veličina, a pokazalo se da je za slučaj recirkulirajućih strujanja, kod kojih postoji značajna razlika u prostornom rasporedu turbulentnih karakteristika, ovaj parametar potrebno adekvatno prilagođavati (Reynolds, 1987.). Iako postoji veliki broj modela turbulencije koji se u RANS paradigmi primjenjuju u svrhu modeliranja turbulentnih Reynoldsovih napreznja, dobar dio njih nije prikladan za analize strujanja vode u akumulacijskim jezerima. Naime, izbor turbulentnog modela je istovremeno i uvjetovan zahtjevom za očuvanjem numeričke stabilnosti računalne simulacije. Štoviše, za složene slučajeve toka, kao što je ovaj u razmatranju, osiguranje numeričke stabilnosti može biti itekako izraženi problem, i to naročito ako se vremenska domena analize proteže kroz više dana. Naime, raspon Reynoldsovih brojeva u akumulacijskih jezera je u vremenu ispuštanja vode izrazito velik te samim time i otežava generalizirani pristup opisivanju turbulentnog toka te iziskuje prostornu varijabilnost parametra C_μ .

Iz navedenih razloga standardni $k-\varepsilon$ model turbulencije (Launder i Sharma, 1974.), koji ima veliku popularnost u praktičnoj primjeni, nije dobar kandidat za modeliranje razmatranih strujanja i to prvenstveno iz razloga što je parametarski kalibriran za slučajeve potpuno razvijene turbulencije. Pokušaj primjene ovog modela će rezultirati numeričkom nestabilnosti. Međutim, njegova kasnija adaptacija (Shih et al., 1995.), koja je u literaturi poznata pod nazivom *realizable $k-\varepsilon$* model turbulencije je mnogo pogodniji za navedene svrhe i to iz razloga jer uvodi varijabilni parametar C_μ za kvantificiranje dodane turbulentne viskoznosti μ_t (11).

U svrhu zatvaranja sustava jednadžbi nedostaje jednadžba transporta turbulentne kinetičke energije k , i jednadžba za disipaciju turbulentne kinetičke energije ε . Za razliku od standardnog $k-\varepsilon$ modela turbulencije, u ovom slučaju prva od navedenih poprima oblik

$$\frac{\partial}{\partial t}(\rho k) + \frac{\partial}{\partial x_j}(\rho k u_j) = \frac{\partial}{\partial x_j} \left(\left(\mu + \frac{\mu_t}{\sigma_k} \right) \frac{\partial k}{\partial x_j} \right) + P_k + P_b - \rho \varepsilon \quad (12)$$

u kojem konstanta modela σ_k ima vrijednost 1.0, član P_k kvantificira produkciju turbulentne kinetičke energije uslijed gradijenta srednje brzine toka (proračunate kao i u slučaju standardnog $k-\varepsilon$ modela turbulencije) te član P_b kvantificira produkciju turbulentne kinetičke energije uslijed uzgonskih djelovanja i Prandtlovog broja Pr koji predstavlja odnos difuzije impulsa i toplinske difuzije (za vodu pri 20°C Pr ima vrijednost 7 te se ta vrijednost koristila i u svrhu izrade numeričkih primjera).

Jednadžba za definiranje disipacije turbulentne kinetičke energije ε se značajno razlikuje od one korištene u standardnom $k-\varepsilon$ modelu gdje se izvodi koristeći princip analogije s jednadžbom za turbulentnu kinetičku energiju. U ovom se slučaju ona bazira na dinamičkoj

jednadžbi napisanoj za fluktuirajuću komponentu vrtložnosti (Shih et al., 1995.) i u konačnici poprima oblik

$$\frac{\partial}{\partial t}(\rho\varepsilon) + \frac{\partial}{\partial x_j}(\rho\varepsilon u_j) = \frac{\partial}{\partial x_j} \left(\left(\mu + \frac{\mu_t}{\sigma_\varepsilon} \right) \frac{\partial \varepsilon}{\partial x_j} \right) + \rho C_1 \sqrt{2S_{ij}S_{ij}} \varepsilon - \rho C_2 \frac{\varepsilon^2}{k + \sqrt{v\varepsilon}} + C_{1c} \frac{\varepsilon}{k} C_{3c} P_b \quad (13)$$

u kojem konstanta modela σ_ε ima vrijednost 1.2, konstanta C_1 poprima vrijednost u skladu s uvjetom

$$C_1 = \max \left(0.43, \frac{\eta}{\eta + 5} \right) \quad (14)$$

gdje je

$$\eta = \sqrt{2S_{ij}S_{ij}} \frac{k}{\varepsilon} \quad (15)$$

konstanta C_2 ima vrijednost 1.9, konstanta C_{1c} ima vrijednost 1.44, dok konstanta C_{3c} definira intenzitet utjecaja uzgonskih sila na iznos brzine disipacije turbulentne kinetičke energije. Posljednja konstanta se zadaje ovisno o karakteristikama fizikalnog procesa koji se modelira i to putem jednakosti

$$C_{3c} = \tanh \left| \frac{u_v}{u_h} \right| \quad (16)$$

u kojoj je u_v komponenta brzine toka paralelna s vektorom gravitacijskog ubrzanja, a u_h komponenta brzine toka okomita na taj vektor. Lako je prepoznati važnost ovakvog turbulentnog modela u kontekstu modeliranja prirodne konvekcije u akumulacijskim jezerima.

2.2. Energetska jednadžba

Kako je gradijent temperature $\partial T / \partial x_i$ „pokretač“ prirodne konvekcije, potrebno je sustav Navier-Stokesovih jednadžbi (jed. 6 i jed. 7) nadopuniti jednadžbom za definiranje skalarnog polja temperature $T(x, y, z, t)$. Tako se ovaj sustav nadopunjuje klasičnom energetskom jednadžbom bez izvornog člana danom u obliku

$$\frac{\partial T}{\partial t} + u_i \frac{\partial T}{\partial x_i} = \kappa \frac{\partial^2 T}{\partial x_i^2} \quad (17)$$

u kojem κ označava efektivni koeficijent toplinske difuzivnosti vode [L^2T^{-1}] koji se može aditivno dekomponirati u obliku (Simpson et al., 1970.)

$$\kappa = \frac{\nu}{Pr} + \frac{\nu_t}{Pr_t} \quad (18)$$

u kojem ν označava kinematičku viskoznost fluida, Pr označava Prandtllov broj definiran samo svojstvima fluida, ν_t označava dodanu kinematičku viskoznost koja

slijedi iz usvojenog turbulentnog modela (11) te Pr_t predstavlja turbulentni Prandtllov broj koji za razliku od prethodnog nije konstantna veličina te su eksperimenti pokazali da se ovisno o broju Pr kreće u rasponu od 0.7 do 0.9 (Weinan i Vanden-Eijnden, 2001.).

Definiranje konstantnog turbulentnog Prandtllov broja Pr_t uvodi simplifikaciju sudjelujućih fizikalnih procesa koja nerijetko dovodi i do pogrešnih zaključaka. Naime, u najgorem slučaju ovakva pretpostavka može dovesti do rezultata numeričkog proračuna provedenog bez ugrožavanja numeričke stabilnosti, odnosno bez najava da bi dobiveni rezultati mogli biti nefizikalni. Ovo su najgori slučajevi jer mogu modelara navesti na krive zaključke. Tako se pokazalo i u provedenim numeričkim simulacijama, jer je konstantna vrijednost broja Pr_t dovela do nefizikalnog miješanja slojeva vode u akumulacijskom jezeru Butoniga, što je utvrđeno naknadnom komparacijom izračunatih i izmjerenih podataka. Razlog tomu su precijenjene vrijednosti turbulentne toplinske difuzije između slojeva vode različite temperature (drugog člana desne strane jed. 18). Naime, u slučaju termokline gdje su slojevi vode različite gustoće odvojeni jasnom granicom, proces razmjene čestica vode je otežan radi razlike u uzgonskoj sili između slojeva. Iz tog je razloga potrebno turbulentni Prandtllov broj Pr_t dovesti u funkcijsku zavisnost s Richardsonovim brojem Ri koji kvantificira odnos uzgonske sile i posmične sile između slojeva. Veza između turbulentnog Prandtllovog broja Pr_t i Richardsonovog broja Ri je preuzeta iz literature (Sukoriansky et al., 2005.). Na ovaj se način kvantifikacija turbulentne difuzivnosti prilagodila lokalnom utjecaju gravitacijskih sila naspram posmičnih sila između slojeva te se tako omogućilo da se utjecaj turbulentne toplinske difuzivnosti reducira na dodiru slojeva različite gustoće i time izbjegne nefizikalno miješanje slojeva. Sve navedeno upućuje na potrebu da se za svaki zasebni slučaj mora provoditi kalibracija numeričkog modela temeljena na komparaciji numeričkih rezultata i provedenih terenskih mjerenja.

2.3. Pronos pasivnog skalara

Kako bi analiza ispuštanja vode iz akumulacije uključila pronos suspendiranih tvari, uz ranije definiran sustav jednadžbi se u svakom vremenskom koraku rješava i jednadžba pronosa pasivnog skalara, odnosno pronos masene koncentracije c [M^1L^{-3}] neke tvari koja u dodiru s vodom ne mijenja mehaničke karakteristike vode. Ovaj se proces opisuje klasičnom konvektivnom-difuznom jednadžbom pronosa

$$\frac{\partial c}{\partial t} + u_i \frac{\partial c}{\partial x_i} = \frac{\partial}{\partial x_i} \left((D_{dif} + D_{tur}) \frac{\partial c}{\partial x_i} \right) \quad (19)$$

u kojoj D_{dif} označava koeficijent molekularne difuzije [L^2T^{-1}], D_{tur} označava koeficijent turbulentne difuzije [L^2T^{-1}]. Pritom, kako je za razmatrane slučajeve utjecaj molekularne difuzije zanemarivo mali u odnosu na

utjecaj turbulentne difuzije, molekularnu difuziju je opravdano zanemariti te koeficijent turbulentne difuzije D_{tur} kvantificirati koristeći turbulentni Schmidov broj Sc_t koji se dovodi u vezu s brojem Ri (Huq i Stewart, 2008.). Za potrebe ovog rada analiza pronosa masene koncentracije tvari se provela samo za jednu suspendiranu tvar te je u te svrhe odabrano praćenje prostorne promjene polja masene koncentracije mangana c_M .

3. NUMERIČKI MODEL TOKA U JEZERU BUTONIGA

Ranije navedeni teorijski model će se koristiti u svrhu izrade numeričkog modela koji će se u svrhu izrade numeričkih primjera primijeniti na akumulacijsko jezero Butoniga. Akumulacijsko jezero Butoniga nastalo je 1987. godine izgradnjom zemljane brane u dolini rijeke Butonige u središnjoj Istri. Jezero Butoniga ima dvostruku funkciju: a) obranu od poplava te b) vodoopskrbu koja s provodi u suradnji s neposredno izgrađenim uređajem za kondicioniranje vode. Branom upravljaju Hrvatske vode, dok je za vodoopskrbu zadužen Istarski vodovod koji upravlja i sa spomenutim obližnjim postrojenjem za kondicioniranje vode (Hrvatske vode, 2017.).


Numerička aproksimacija teorijskog modela za zadane početne i rubne uvjete je dobivena putem metode konačnih volumena koristeći *open-source* programski paket OpenFOAM (OpenCFD, 2016.). OpenFOAM se sastoji od nekoliko desetaka proračunskih algoritama koji se razlikuju po jednačbama koje rješavaju i metodama koje koriste za proračun određenih fizikalnih procesa (Greenshields, 2017.). Za proračun raniojesenskog ispuštanja koristila se kombinacija *buoyantBoussinesqPimpleFoam* i *scalarTransportFoam* algoritama te se tako postiglo modeliranje prirodne i prisilne konvekcije korištenjem Boussinesqove aproksimacije i rješavanje jednačbe za pronos pasivnog skalara.

Treba primijetiti da modeliranje dvofaznog strujanja, odnosno istovremenog strujanja i vode i zraka iznad površine jezera zahtijeva cjelovito i zasebno razmatranje te prelazi okvire ovog rada. Naime, u tom je slučaju posebnu pažnju potrebno predati redukciji numeričke difuzije koja je u tim slučajevima značajna (i najčešće ugrožava numeričku stabilnost), a naročito ako se razmatraju primjeri u kojima je karakteristična dimenzija površine dodira fluida (duljina ili širina dodirne površine) veća u odnosu na druge dimenzije modela (kao što je slučaj modeliranja toka u jezeru gdje je dužina i širina površine jezera mnogo veća od njegove dubine).

3.1. Prostorna diskretizacija

U svrhu generiranja prostorne diskretizacije akumulacije Butoniga, izradio se digitalni model jezera koristeći podatke terenskih mjerenja provedenih u svrhu definiranja batimetrije jezera. Geometrijski model jezera se zatim aproksimirao prostornom mrežom heksaedarskih konačnih volumena. Za generiranje

mreže konačnih volumena korišten je OpenFOAM alat *snappyHexMesh* koji je omogućio prilagodbu mreže u svrhu detaljnije aproksimacije geometrije jezera (naročito u blizini temeljnog ispusta). Mreža je strukturirana, a sastoji se od ukupno 57054 heksaedra dimenzija 15 m × 15 m × 1 m. Geometrijski model jezera, aproksimacija geometrije jezera metodom konačnih volumena te karakteristični konačni volumen izdvojen iz mreže su prikazani na slici 2.



Slika 2: Na slici je prikazan digitalni model domene proračuna definiran dnom jezera i vodnim licem, aproksimacija proračunske domene dobivena metodom konačnih volumena (koristeći alat *snappyHexMesh*) te dimenzija karakterističnog konačnog volumena. Kako bi se postigla bolja preglednost, vertikalna dimenzija domene je na slici povećana 10 puta

Treba napomenuti da navedena dimenzija heksaedarskih konačnih volumena nije proizvoljno odabrana, već je rezultat opsežne parametarske analize unutar koje je bilo potrebno odrediti utjecaj veličine heksaedarskih konačnih volumena na rezultate proračuna, ali i na vrijeme trajanja proračuna. Izbor prikladne dimenzije konačnog volumena se u konačnici temelji na kriteriju točnosti rezultata, tj. dimenzija konačnog volumena se odabrala putem analize utjecaja veličine volumena na rezultate modela. Tako se u konačnici odabrala ona dimenzija elementa nakon koje daljnja redukcija veličine istog nije značajno utjecala na porast točnosti rezultata. S druge strane, problem vremena trajanja proračuna, koji se posljedično pojavio radi relativno velikog broja konačnih volumena, se tretirao koristeći paralelnu implementaciju proračunskog algoritma.

3.2. Vremenska diskretizacija

U svrhu verifikacije prikazanog numeričkog modela, prikladno je bilo modelirati ispuštanje vode iz jezera

koje je praćeno opsežnim terenskim mjerenjima. Najrecentniji takav slučaj je ispuštanje vode iz jezera koje se dogodilo 21. rujna 2016. godine kada se tijekom 5 dana ispuštala vode kroz temeljni ispust sve dok se razina vode nije smanjila za 1 m. Ovaj je slučaj odabran u svrhu komparacije izmjerenih i izračunatih podataka. Iz toga je razloga bilo potrebno modelirati sve relevantne fizikalne procese u vremenskom periodu definiranog između 12:00 sati dana 21. rujna 2016. godine pa sve do 12:00 sati dana 26. rujna 2016. godine kada su završena terenska mjerenja. Za vremensku domenu koja se proteže kroz 5 dana, najprikladniji je izbor varijabilnog vremenskog koraka, tj. vremenskog koraka Δt koji se progresivno prilagođavao s uvjetom da Courantov broj unutar svakog vremenskog koraka bude manji od 1. Za svaki konačni volumen e se Courantov broj c_e definirao u obliku (OpenCFD, 2016.)

$$c_e = \frac{1}{2} \frac{\sum \phi \Delta t}{\Delta V} \quad (20)$$


gdje $\sum \phi$ predstavlja zbroj volumnih protoka kroz površine konačnog volumena e [L^3T^{-1}], Δt predstavlja vremenski korak [T], a ΔV je volumen konačnog volumena e [L^3].

3.3. Zadavanje rubnih uvjeta

Kako bi se omogućila komparacija izmjerenih i izračunatih veličina, posebno je važno bilo definirati realne rubne uvjete koji se zadaju za polje tlaka, polje brzine, polje temperature i polje masene koncentracije mangana. Rubni uvjeti su se zadavali za tri površine geometrije modela: vodno lice, dno akumulacije i otvor temeljnog ispusta. U tablici 1 je izložen sažet prikaz svih rubnih uvjeta gdje $f(t)$ ukazuje na nestacionarni Dirichletov rubni uvjet, Q/A ukazuje na Dirichletov rubni uvjet zadane brzine (putem omjera zadanog protoka Q i protočne površine koja se za razmatrani slučaj odnosi na površinu vodnog lica A_{vl} ili protočnu površinu temeljnog ispusta A_{vi}), a $\partial q / \partial n_i$ ukazuje na Neumannov rubni uvjet koji se za bilo koju veličinu q zadaje kao gradijent po normali n_i na površinu rubnog uvjeta.

Rubni uvjet temperature na površini jezera je morao pratiti izmjenu temperature zraka koja se u navedenom periodu događala prilikom izmjene noći i dana. Tako se ovaj nestacionarni rubni uvjet zadao koristeći maksimalne

vrijednosti temperature dobivene terenskim mjerenjima u 12:00 sati (Mihelčić et al., 2017.), a kako za minimalne vrijednosti nisu provedena mjerenja, minimalne temperature zraka su se koristile kao kalibracijski faktor i bile su zadane koristeći podatke prosječne temperature zraka za taj period godine (slika 3).



Slika 3: Aproximacija nestacionarnog rubnog uvjeta temperature vode na površini jezera Butoniga za vrijeme trajanja ranojesenskog ispuštanja provedenog u 2016. godini. Radi nedostatka podataka usvojila se linearna izmjena minimalnih i maksimalnih temperatura između noći i dana

U svrhu prikladnog modeliranja slobodne turbulencije, koristio se ranije navedeni turbulentni model. Međutim, u svrhu modeliranja zidne turbulencije na dodiru vode i čvrste granice modela (dno jezera), koristilo se zadavanje standardnih zidnih funkcija (Pope, 2000.) u kojima su parametri korišteni u svrhu reguliranja otpora trenja i generiranja turbulencije.

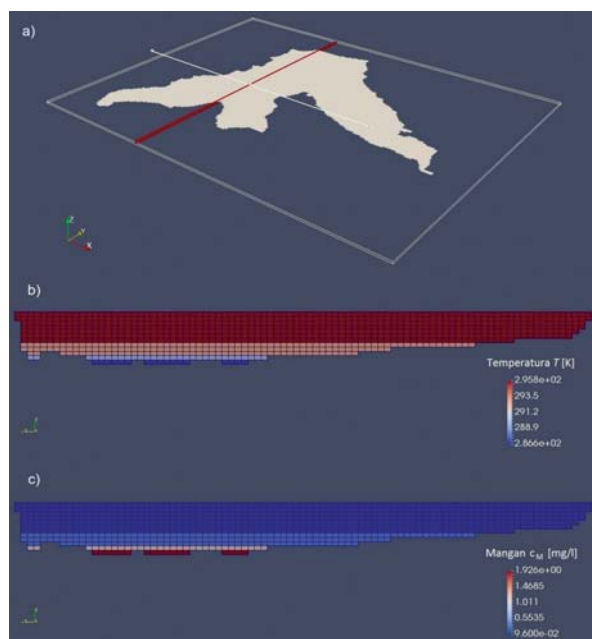
3.4. Zadavanje početnih uvjeta

Osim prikladno zadanih rubnih uvjeta, neophodno je i početne uvjete zadati istovjetno fizikalnim veličinama izmjerenim 21. rujna 2016. godine u 12:00 sati. Kako je prikazano na slici 1, mjerenja karakterističnih veličina su vršena na mjestu vodozahvata, temeljnog ispusta i u točki B1 koja se ujedno usvojila kao mjerodavnom radi njenog centralnog ili reprezentativnog položaja za veći dio domene toka. Na taj je način vertikalni raspored temperature vode i masene koncentracije mangana u prvom vremenskom koraku zadana sukladno izmjerenom vertikalnom rasporedu u točki B1, uz pretpostavku da se usvojena vertikalna izmjena ovih veličina jednako pojavljuje i u drugim točkama domene toka. Slika 4 a prikazuje presjek akumulacije kroz

Tablica 1: Sistematizacija zadanih rubnih uvjeta po površinama geometrije numeričkog modela

Fizikalna veličina	Vodno lice	Dno akumulacije	Temeljni ispust
tlak p_k	$= f(u)$	$= 0$	$= f(u)$
brzina vode u_i	$= Q/A_{vl}$	$= 0$	$= Q/A_{vi}$
temperatura vode T	$= f(t)$	$\partial q / \partial n_i = 0$	$\partial q / \partial n_i = 0$
masena koncentracija mangana c_m	$\partial q / \partial n_i = 0$	$\partial q / \partial n_i = 0$	$\partial q / \partial n_i = 0$

temeljni ispus, te vertikalni raspored temperature vode (slika 4 b) i suspendirane masene koncentracije mangana na početku numeričke simulacije (slika 4 c). Vektor brzine toka je u prvom vremenskom koraku u svakoj točki domene bio jednak *nul*-vektoru, a tlak na površini jezera je bio jednak atmosferskom.



Slika 4: a) Položaj presjeka kroz temeljni ispus označenom crvenom linijom, b) prostorni raspored temperature vode na početku numeričke analize u presjeku kroz temeljni ispus, c) prostorni raspored masene koncentracije mangana na početku numeričke analize u presjeku kroz temeljni ispus. Kako bi se postigla bolja preglednost, vertikalna dimenzija domene na slici je povećana 10 puta

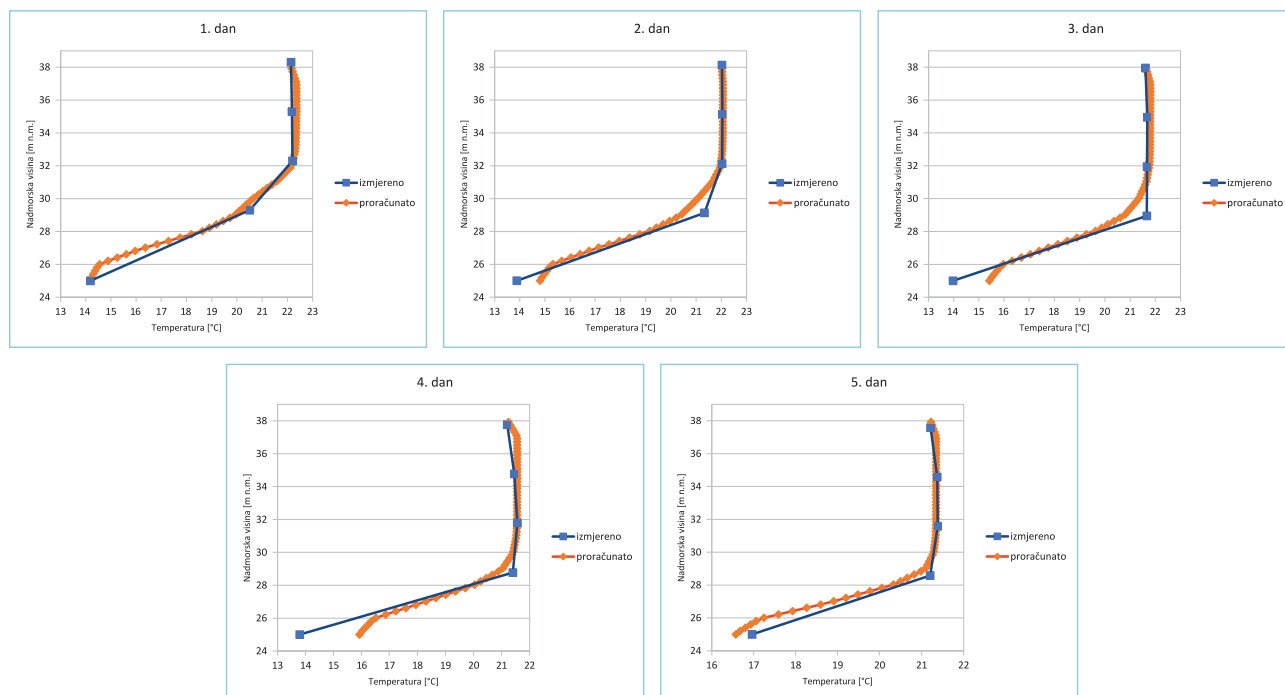
4. KALIBRACIJA NUMERIČKOG MODELA

Kalibracija numeričkog modela je provedena komparacijom izmjerenog rasporeda vertikalne temperature vode i masene koncentracije mangana te izračunatog rasporeda istih veličina u točki B1. Svako narednoj komparativnoj analizi je prethodila kalibracija numeričkih parametara. Izbor konačnih parametara numeričkog modela je onaj koji je doveo do rezultata prikazanih na slici 5, gdje je prikazana usporedba izmjerenog rasporeda temperature vode i izračunatog rasporeda temperature vode (u svakom danu ispuštanja), i slici 6 gdje je prikazana usporedba izmjerene i izračunate vertikalne raspodjele masene koncentracije mangana. U svrhu vrednovanja ovih rezultata može se priložiti slika 7 na kojoj je prikazano polje brzina u jednom nasumičnom trenutku numeričke analize. Naime, vidljivo je da je vrtložno strujanje itekako prisutno te time ostvarena podudarnost između izmjerenih i izračunatih podataka dodatno opravdava izbor usvojenih numeričkih parametara.


Komparativna analiza između izmjerenih i izračunatih podataka se provela i koristeći korijen srednje vrijednosti kvadrata odstupanja (eng. *Root Mean Square Error*, RMSE) koji predstavlja standardnu devijaciju odstupanja za određeni niz podataka, i definiran je u obliku

$$RMSE = \sqrt{\frac{\sum_{i=1}^N \sigma_i^2}{N}} \quad (21)$$


gdje σ_i predstavlja odstupanje i -tog člana niza, a N broj članova niza. Vežano za proračun ranojesenskog



Slika 5: Komparacija izmjerenog vertikalnog rasporeda temperature vode i izračunate temperature vode u točki B1 (slika 1) i za svaki dan u kojem su provedena terenska mjerenja



Slika 6: Komparacija izmjerenog vertikalnog rasporeda masene koncentracije mangana i izračunate masene koncentracije mangana u točki B1 (slika 1) i za svaki dan u kojem su provedena terenska mjerenja



Slika 7: Prikaz karakterističnog polja brzine u nasumičnom vremenskom koraku provedene numeričke analize u kojem se lako može prepoznati vrtložno strujanje vode, ali i volumen vode na dnu akumulacije s jasno izraženim smjerom strujanja u pravcu temeljnog ispusta. Polje brzine je prikazano za čitav volumen vode te je u tu svrhu vertikalno uzorkovanje polja brzine ujednačeno unutar čitave domene. U prikazanom polju brzine je izražena strujna cijev označena crvenom bojom koja ima orijentaciju prema temeljnom ispustu i zahvaća volumen vode koji se ispušta

ispuštanja promatrao se RMSE temperature vode i masene koncentracije mangana u točki B1 za svaki dan ispuštanja te za sve dane ukupno. Rezultati ove analize su prikazani u tablici 2. Obzirom da su prostorne i vremenske izmjene u polju temperature i

masene koncentracije mangana ispravno predviđene numeričkim modelom, s razinom točnosti koja ima praktični značaj, zaključeno je da se model može koristiti u svrhu analiza drugačijih scenarija toka. Istovremeno, pretpostavlja se da su evidentirana odstupanja uzrokovana dotocima u akumulaciju koji u ovoj analizi nisu uzeti u obzir.


5. NUMERIČKI PRIMJER

Kalibrirani numerički model je korišten u svrhu izrade numeričkih primjera vezanih za ispuštanje pridnenog anoksičnog sloja iz akumulacije Butoniga. Ispuštanje se provodi kroz temeljni ispust kojem je moguće mijenjati protočnu površinu i na taj način regulirati protok. Neovisno o zadanom protoku, ispuštanje se u svakoj varijanti provodi u vremenu dok se razina vode u jezeru ne spusti za 1 m, što će rezultirati ispuštenim volumenom vode u iznosu od 1.290.000 m³. Numerički model se koristio u svrhu provedbe numeričkih primjera koji su se mogli kategorizirati u dvije skupine: I.) primjeri s konstantnim protokom u vremenu trajanja ispuštanja i II.) primjeri s varijabilnim protokom u vremenu trajanja ispuštanja.

Tablica 2: Tabela prikaz RMSE analize temperature vode i masene koncentracije mangana u točki B1 za svaki dan ispuštanja te za sve dane ukupno.

Uzorak:	1. dan:	2. dan:	3. dan:	4. dan:	5. dan:	Ukupno:
RMSE temperature [°C]	0,2	0,54	0,75	0,98	0,25	0,62
RMSE mangana [mg/l]	0,178	0,148	0,174	0,117	0,069	0,143


U prvoj se seriji numeričkih primjera razmatrao učinak konstantnog protoka na količinu ispuštenog mangana iz akumulacije, te se pritom uspoređivala učinkovitost ispuštanja za različite iznose protoka. Ispitan je raspon protoka od $1 \text{ m}^3/\text{s}$ do $15 \text{ m}^3/\text{s}$, s inkrementom uvećanja od $1 \text{ m}^3/\text{s}$. Treba primijetiti da je numeričkim modelom lako pratiti prostorne i vremenske varijacije u rasporedu neke suspendirane tvari. Za ovdje prikazani numerički primjer je to mangan, te se tako može u svakom vremenskom koraku točno kvantificirati masa mangana u čitavoj akumulaciji, zasebno masa mangana u pridnom sloju te isto tako i masa mangana koja je ispuštena kroz temeljni ispust. Tako se za slučaj protoka od $3 \text{ m}^3/\text{s}$ na slici 8 može vidjeti vremenska promjena mase mangana u pridnom sloju, u akumulaciji i ukupna količina mangana ispuštena kroz temeljni ispust u nekom trenutku.




Slika 8: Za slučaj konstantnog protoka ispuštanja vode u iznosu od $3 \text{ m}^3/\text{s}$, dijagram prikazuje: vremensku izmjenu mase mangana u pridnom sloju (crvena krivulja), ukupnu izmjenu mase mangana u akumulaciji (plava krivulja) te ukupnu masu mangana ispušteni kroz temeljni ispust u svakom trenutku (zeleno krivulja)

Na taj je način lako pratiti učinkovitost ispuštanja vode te je interesantno primijetiti da je numerička analiza pokazala da količina ispuštenog mangana ne prati trend porasta protoka na temelju ispustu, već štoviše, pokazuje da veći protoci imaju manju učinkovitost ispuštanja suspendiranih tvari, a optimum se postiže za manje iznose protoka (ali ne i za najmanje protoke). Na slici 9 su prikazane ukupne količine mangana u akumulaciji prije i nakon ranijesenskog ispuštanja za svaki ispitani protok zasebno. S druge strane, slika 10 za svaki ispitani protok prikazuje ukupne količine mangana u pridnom sloju (od dna do 28 m nm.) prije i nakon ispuštanja. Dakle, za protoke od 1 ili $1.5 \text{ m}^3/\text{s}$ je pokazano da se kroz temeljni ispust ispusti gotovo 80% prisutnog mangana u pridnom sloju, što je najveći postotak u odnosu na druge protoke, no kada se promatra cijela akumulacija (slika 9), ispuštene količine mangana su manje nego za npr. za protok od 2 ili $3 \text{ m}^3/\text{s}$. Daljnjim povećanjem protoka se smanjuje ispuštena količina mangana, kako za cijelu akumulaciju, tako i za slučaj pridnog sloja. Za protoke veće od

$4 \text{ m}^3/\text{s}$ je masa ispuštenog mangana sve manja, no u pridnom sloju je ispuštena količina prividno veća. Naime, u tom slučaju količina mangana koja je smanjena u pridnom sloju nije ispuštena kroz temeljni ispust, već je uslijed turbulentnog miješanja u blizini temeljnog ispusta i prirodne konvekcije pomiješana u gornje slojeve vode. Zanimljivo je primijetiti da će naredna analiza pokazati da veći iznosi protoka mogu biti i korisni ako im prethode manji protoci. Naravno, kao i za ranije navedene zaključke i ovdje treba primijetiti da je ova analiza provedena za specifične početne i rubne uvjete te da je u svrhu definiranja općenitih zaključaka potrebno provesti opsežniju parametarsku analizu.




Slika 9: Dijagram prikazuje ukupnu masu mangana u akumulaciji prije ispuštanja (crna horizontalna linija) i ukupnu masu mangana u akumulaciji nakon što je za različite protoke provedeno ispuštanje vode kroz temeljni ispust (crna krivulja označena obojanim točkama za svaki diskretni protok). Ispitan je utjecaj protoka od $1, 1.5, 2, 3, 4 \dots$ do $15 \text{ m}^3/\text{s}$. Treba napomenuti da se krivuljom ukupne mase mangana u akumulaciji ne može prepoznati dio koji pripada pridnom sloju




Slika 10: Dijagram prikazuje ukupnu masu mangana u pridnom sloju prije ispuštanja (crna horizontalna linija) i ukupnu masu mangana u pridnom sloju nakon što je za različite protoke provedeno ispuštanje vode kroz temeljni ispust (crna krivulja označena obojanim točkama za svaki diskretni protok). Ispitan je utjecaj protoka od $1, 1.5, 2, 3, 4 \dots$ do $15 \text{ m}^3/\text{s}$

U drugoj seriji numeričkih primjera se provela analiza ispuštanja mangana temeljena na ideji aktivacije inercijanih sila putem izmjene protoka u vremenu trajanja ispuštanja. Na taj bi način promjena količine gibanja, koja nastaje u vremenu izmjene protoka, mogla potaknuti podizanje suspendiranih tvari na više kote gdje je strujanje izraženije i time bi se pospješilo ispuštanje tvari. Koristeći povoljne rezultate prethodno napravljene numeričke analize, ovdje su se provele dvije varijante ispuštanja koje su se razlikovale u iznosu početnog protoka koji je trajao prvih 48 sati nakon kojeg se protok povećao. Tako su se mogle razlikovati analize u kojima je protok u prvih 48 sati iznosio $2 \text{ m}^3/\text{s}$ i analize u kojima je u istom vremenskom periodu protok iznosio $3 \text{ m}^3/\text{s}$. Za jedan i drugi slučaj su se potom protoci povećali na iznose 6, 8, 10, 12, ili $15 \text{ m}^3/\text{s}$. U svim ovim slučajevima je vrijeme ispuštanja vode bilo različito, a trajalo je dok se razina vode ne spusti za 1 m (kako je i bilo 2016. godine kada su provedena terenska mjerenja). U prvom redu je potrebno primijetiti da se ideja o aktivaciji inercijalnih sila u načelnom smislu pokazala korisnom, jer kako je ilustrirano na slici 11 (koja prikazuje vremensku izmjenu količine mangana u pridnenom sloju, u akumulaciji i masu mangana ispuštenu kroz temeljni ispust), vidljivo je da se u trenutku izmjene protoka povećava količina ispuštenog mangana. Pritom ovaj zaključak nije primjenjiv na sve ispitane protoke te je za općenitiji zaključak potrebno provesti opsežniju parametarsku analizu. Rezultati provedenih analiza su pokazali i da u slučaju varijabilnog protoka odabrani početni protok (2 ili $3 \text{ m}^3/\text{s}$) nema veliki značaj na količinu mangana u čitavoj akumulaciji, ali kada se promatra samo pridneni sloj, primjećuje se da se uz početni protok od $2 \text{ m}^3/\text{s}$ ispusti veća količina mangana. Naime, na slici 12 gornji dijagram prikazuje vremensku promjenu masenog protoka mangana kroz temeljni ispust za slučaj da je početni protok iznosio $2 \text{ m}^3/\text{s}$, a donji dijagram prikazuje slučaj da je početni protok iznosio $3 \text{ m}^3/\text{s}$. Na svakom od navedenih dijagrama su prikazane i vremenske promjene masenog protoka mangana za različite protoke koji bi se mogli postići povećavajući svijetli otvor temeljnog ispusta nakon 48 sati ispuštanja s početnim svijetlim otvorom. U prvom redu je na ovim dijagramima vidljiva kvantifikacija uštede vremena s izmjenom protoka. Osim navedenoga, lako se može prepoznati da porastom protoka kroz temeljni ispust, koji slijedi nakon 48 satnog ispuštanja s konstantnim protokom, dovodi i do povećanja količine ispuštanja mangana iz akumulacije. Pritom, ovi podatci sami za sebe mogu dovesti do krivih zaključaka u kontekstu optimalnog upravljanja akumulacijom Butoniga, i to iz razloga što veći protoci ujedno i POSPJEŠUJU turbulenciju koja prijeti u kontekstu iniciranja miješanja vode. Ovaj put ne radi prirodne konvekcije, već radi mehaničkog miješanja vode induciranog izmjenom količine gibanja. Dakle, utvrđivanje najprikladnije kombinacije protoka iziskuje podrobniju numeričku analizu koja će rezultirati kompromisnim rješenjem, odnosno varijantom protoka

koja će maksimizirati količinu ispuštenog mangana iz pridnenog sloja i istovremeno minimizirati utjecaj turbulencije i putem toga izbjeći miješanje pridnenog sloja s ostatkom vode. U svrhu navedenoga je potrebno provesti opsežniju parametarsku studiju.



Slika 11: Za slučaj varijabilnog protoka ispuštanja vode, koji je u prvih 48 sati iznosio $3 \text{ m}^3/\text{s}$, a kasnije $15 \text{ m}^3/\text{s}$, dijagram prikazuje: vremensku izmjenu mase mangana u pridnenom sloju (crvena krivulja), ukupnu izmjenu mase mangana u akumulaciji (plava krivulja) te ukupnu masu mangana ispuštenu kroz temeljni ispust u svakom trenutku (zeleno krivulja). Lako je prepoznati povoljan lom u crvenoj krivulji u trenutku povećanja protoka (označeno isprekidanom vertikalnom linijom)



Slika 12: Maseni protok mangana kroz temeljni ispust za: a) slučaj početnog protoka od $2 \text{ m}^3/\text{s}$ i b) za slučaj početnih protoka od $3 \text{ m}^3/\text{s}$. U jednom i u drugom slučaju daljnje povećanje protoka reducira vrijeme trajanja ispuštanja i povećava količinu ispuštenog mangana. Pritom veći protoci ugrožavaju stabilnost između slojeva i potiču nepoželjno turbulentno miješanje slojeva

Kako je ključno da se ranije ispuštanje obavi prije nego što nastupi miješanje slojeva vode, bitan parametar vezan za analizu su razlike u temperaturi

Tablica 3: Prikaz temperaturne razlike gornjeg i donjeg sloja vode na kraju ispuštanja za razmatrane slučajeve varijabilnih protoka. Za slučaj početnog protoka od 2 m³/s se prešla iskustvena granica od 4°C kod koje nastupa miješanje slojeva.

Početni protok [m ³ /s]	2					3				
Krajnji protok [m ³ /s]	6	8	10	12	15	6	8	10	12	15
Razlika u temperaturi [°C]	2,73	2,87	3,17	2,98	2,84	4,74	4,61	4,76	4,12	4,36

između gornjeg i donjeg sloja vode. Čak i kada je voda u pridonnom sloju manje temperature, vanjski čimbenici poput vjetra ili pritoka mogu pokrenuti miješanje slojeva. Kako navedeni čimbenici nisu uključeni u proračun, smatrat će se da miješanje započinje kada se razlika u temperaturi između slojeva spusti ispod 4°C, što je iskustveni podatak osoblja akumulacije. U **tablici 3** može se vidjeti da se za svaki slučaj s početnim protokom od 2 m³/s može očekivati miješanje slojeva prije završetka ispuštanja.

6. ZAKLJUČAK

Da bi se pridonijelo unaprjeđenju gospodarenja akumulacijskim jezerima, u ovom je radu prikazan numerički model koji se koristio u svrhu analize učinkovitog ispuštanja anoksičnog pridonog sloja u ranijosenskom periodu iz akumulacije Butoniga u Istri. Prikazani numerički model se temelji na sustavu Navier-Stokesovih jednadžbi, „realizable“ $k-\varepsilon$ modelu turbulencije te uključuje energetska jednadžbu u svrhu kvantifikacije skalarnog polja temperature i jednadžbu pronosa suspendirane masene koncentracije tvari. Prije primjene modela u svrhu izrade analiza toka za različite scenarije ispuštanja vode, model je kalibriran koristeći podatke terenskih mjerenja provedenih u 2016. godini. Kalibracija numeričkog modela je provedena progresivnom adaptacijom numeričkih parametra i sukcesivnom komparacijom izmjerenih i izračunatih podataka za odgovarajuće rubne i početne uvjete. Ključni dio izrade numeričkog modela bilo je definiranje turbulentne viskoznosti, turbulentne difuzije topline te turbulentne difuzije pasivnog skalara. Radi specifičnosti vezanih za numerički model, korištenje standardnog $k-\varepsilon$ modela turbulencije rezultiralo bi nefizikalnim vrijednostima turbulentne viskoznosti te se stoga koristio fleksibilniji „realizable“ $k-\varepsilon$ model. S druge strane, kako je bilo potrebno kvantificirati prigušenje turbulentne difuzije topline i pasivnog skalara na granici dva sloja vode difuzija se definirala kao funkcija u zavisnosti o Richardsonovom broju, a sve na temelju rezultata eksperimentalnih istraživanja navedenih u radu.

Kalibrirani model se koristio u svrhu izrade numeričkih primjera putem kojih se željelo istražiti utjecaj varijabilnog protoka na učinkovitost ispuštanja štetnih tvari u pridonnom sloju. Kriteriji ili indikator učinkovitog ispuštanja je masa mangana ispuštena kroz temeljni ispušt za više različitih dinamika pražnjenja

akumulacije koje uvijek dovode do smanjenja razine vode u jezeru za 1 m. Ovim analizama je pokazano da je za uvjete kakvi su bili 2016. godine protok od 3 m³/s povoljniji u odnosu na protok od 2 m³/s budući je tada sigurno da prije kraja ispuštanja neće nastupiti miješanja gornjeg i donjeg sloja vode (kako je i utvrđeno terenskim mjerenjima da se dogodilo u zadnja dva dana ispuštanja vode u 2016. godini). Naravno, navedeno vrijedi za zadane početne i rubne uvjete te je u svrhu postavljanja općenitijeg zaključka potrebno provesti opsežnije numeričke analize. S druge strane, numeričkim modelom je ispitana mogućnost izmjene protoka u vremenu pražnjenja akumulacije, potaknuta idejom o aktivaciji inercijalnih sila koje bi u trenutku izmjene protoka pokrenule veću masu suspendirane tvari prema temeljnom ispustu. U svim varijantama se protok mijenjao nakon 48 sati ispuštanja te se pokazalo da veći iznosi kasnijih protoka imaju veću učinkovitost u pogledu ispuštanja štetnih tvari iz akumulacije, ali istovremeno i omogućavaju brže pražnjenje akumulacije. Međutim, kao i za slučaj konstantnog protoka ispuštanja, i ovdje je zaključak utemeljen na zadanim početnim i rubnim uvjetima te bi za poopćeni zaključak trebalo provesti opsežniju numeričku analizu.

Naredne istraživačke aktivnosti će zasigurno uključiti modeliranje pritoka i modeliranje utjecaja vjetra na proces miješanja vode u akumulacijskim jezerima. Štoviše, za ovakve numeričke modele se može prepoznati potreba parametrizacije svih vanjskih utjecaja koji utječu na proces miješanja vode, a njih je u općem slučaju četiri: I.) pad temperature zraka, II.) razina vode u jezeru prije ispuštanja, III.) utjecaj vjetra te IV.) utjecaj hidroloških uvjeta tj. dotoka. Nastavak istraživanja će zasigurno uključiti sistematizaciju parametara kako bi se mogle izraditi analize putem kojih će se predvidjeti kombinacije navedenih vanjskih utjecaja na iniciranje procesa miješanja vode. Osim navedenoga, za modeliranje ovako složenih fizikalnih procesa je potrebno i provoditi kontinuirana uzorkovanja i prikupljanje meteoroloških i hidroloških podataka kako bi se numerički modeli mogli kalibrirati. Prikupljanje podataka vezanih za sastav vode se može u nekim od daljnjih istraživačkih aktivnosti koristiti u svrhu definiranja funkcija za produkciju i raspadanje suspendiranih tvari, čime bi se mogle modelirati i posljedice preuranjenih ispuštanja na kvalitetu vode u akumulacijskim jezerima kao što je Butoniga. ■

LITERATURA

- Abbasi, A.; Annor, F.O.; van de Giesen, N. (2016.): Investigation of temperature dynamics in small and shallow reservoirs, case study: Lake Binaba, Upper East Region of Ghana, *Water*, 8(3), 84.
- Anderson, P.S. (2009.): Measurement of Prandtl Number as a Function of Richardson Number Avoiding Self-Correlation, *Boundary-Layer Meteorology*, 131, 3.
- Ferziger, J.H.; Perić, M. (2002.): *Computational Methods for Fluid Dynamics*, 3rd edition, Springer Verlag, Berlin, Germany.
- Greenshields, C.J. (2017.): *OpenFOAM User Guide*, version 5.0. OpenFOAM Foundation Ltd.
- Hrvatske vode (2017.): *Brana i akumulacija Botonega – kratak opis, osnovni podatci, situacija, presjeci*, brošura.
- Huq, P.; Stewart, E.J. (2008.): Measurements and analysis of the turbulent Schmidt number in density stratified turbulence, *Geophysical research letters*, 35, L23604.
- Kim, D.H.; Lynett, P.J. (2011.): Turbulent mixing and passive scalar transport in shallow flows, *Physics of Fluids*, 23, 016603.
- Launder, B.E.; Sharma, B.I. (1974.): Application of the Energy Dissipation Model of Turbulence to the Calculation of Flow Near a Spinning Disc, *Letters in Heat and Mass Transfer*, 1, 131-138.
- Lozzi-Kožar, D. (2012.): *Numeričko trodimenzionalno modeliranje raspodjele temperature u jezeru Botonega*. Disertacija, Fakultet građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, Split.
- Mihelčić, N.; Šikoronja, M.; Oštrić, M. (2017.): *Analiza monitoringa kakvoće vode nakon ranojesenskog ispuštanja 2016*, Hrvatske vode, Rijeka.
- OpenCFD (2016.): OpenFoam 4.0. Source code. Izvorni kod.
- Pope, S.B. (2000.): *Turbulent Flows*, Cambridge University Press, Cambridge.
- Reynolds, W. C. (1987.): "Fundamentals of turbulence for turbulence modeling and simulation", Lecture Notes for Von Karman Institute Agard Report No. 755.
- Shen, Y.; Zheng, Y.; Komatsu, T.; Kohashi, N. (2002.): A three-dimensional numerical model of hydrodynamics and water quality in Hakata Bay, *Ocean Engineering*, 29, 461-473.
- Shih, T. H.; Liou, W.W.; Shabbir, A.; Yang, Z.; Zhu, J. (1995.): A New k-ε Eddy Viscosity Model for High Reynolds Number Turbulent Flows-Model Development and Validation, *Computers Fluids*, 24(3) : 227-238.
- Simons, T.J. (1974.): Verification of Numerical Models of Lake Ontario: Part I. Circulation in Spring and Early Summer, *Journal of Physical Oceanography*, 4, 507-523.
- Simpson, R.L.; Whitten, D.G.; Moffat, R. J. (1970.): An experimental study of the turbulent Prandtl number of air with injection and suction, *Int. J. of Heat and Mass Transfer*, Vol.13, pp. 125.
- Sukoriansky, S.; Galperin, B.; Staroselsky, I. (2005.): A quasnormal scale elimination model of turbulent flows with stable stratification, *Physics of Fluids*, 17, 085107.
- Wang, Y.; Hutter, K.; Bäuerle, E. (2000.): Wind-induced baroclinic response of Lake Constance, *Annales Geophysicae*, 18, 1488 – 1501.
- Weinan, E.; Vanden-Eijnden, E. (2001.): Turbulent Prandtl number effect on passive scalar advection, *Physica D*, 152-153.

Approach to modelling natural convection in reservoirs as exemplified by the Butoniga reservoir

Abstract. In the context of reservoir management, natural convection, i.e. volumetric flow occurring as a consequence of the temperature gradient is a particularly important physical process that can significantly influence the decision-making and reservoir management processes. This will be illustrated by the paper on the example of the Butoniga reservoir, in which natural convection plays a very significant role. In the summer period, a thermocline is formed in the Butoniga reservoir and thus anoxic conditions are induced in the lower near-bottom layer that, in the presence of mud at the reservoir bottom and through biological and chemical processes, significantly deteriorate water quality in this area. As long as there is a balanced thermal stratification, the mixing of this anoxic layer with the remaining water is prevented. However, due to a progressive decrease in the mean air temperature value in the early autumn period, the top water layer cools down and a significant vertical circulation begins, which may cause the mixing of the anoxic layer and endanger the quality of the remaining water in the reservoir through natural convection. For this reason, it is necessary to forestall the moment when vertical circulation is activated and empty the near-bottom layer of the reservoir. The decision-making regarding the moment when the reservoir should be emptied is an elaborate process that is based on the previously performed field measurements and very complex computer simulations. After the most appropriate time of the reservoir emptying is established, which requires a comprehensive parameter analysis, the attention is focused on the determination of the most efficient emptying dynamics, which is the topic of this paper.

Key words: Butoniga reservoir, early autumn discharge, numerical model, OpenFOAM

Ansatz zur Modellierung natürlicher Konvektion in Stauseen am Beispiel des Stausees Butoniga

Zusammenfassung. Im Management von künstlichen Stauseen ist die natürliche Konvektion, d.h. Strömung aufgrund von Temperaturunterschieden im Wasser, ein sehr wichtiger physikalischer Vorgang, der das Entscheidungsverfahren und Modell vom Stauseemanagement wesentlich beeinflussen kann. Der Ansatz zur Modellierung natürlicher Konvektion wird am Beispiel des Stausees Butoniga illustriert, wo die natürliche Konvektion besonders wichtig ist. Im Sommerzeitraum entsteht im Stausee Thermokline, und in der bodennahen Wasserschicht entwickeln sich anoxische Bedingungen, die samt dem Schlamm auf dem Seeboden und biologischen und chemischen Vorgängen die Wasserqualität in dieser Schicht sehr verschlechtern. Solange eine ausgewogene Temperaturschichtung erhalten bleibt, wird die Vermischung von anoxischer Schicht und anderen Wasserschichten verhindert. Allerdings, wegen der zunehmenden Erniedrigung der mittleren Lufttemperatur im Frühherbst wird auch die obere Wasserschicht kühler, womit eine vertikale Strömung beginnt, die wegen der natürlichen Konvektion die Vermischung der anoxischen Schicht verursachen und die Qualität des Restwassers im Stausee gefährden kann. Aus diesem Grund ist es wichtig, die Aktivierung der vertikalen Strömung zu antizipieren und die bodennahe Schicht aus dem Stausee abfließen lassen. Das Entscheidungsverfahren bezüglich der Frage, wann den Stausee zu entleeren, ist ein ziemlich komplexes Verfahren, das auf früher erfolgten Feldmessungen und sehr komplexen Rechnersimulationen beruhen muss. Nachdem die optimale Zeit zur Entleerung bestimmt wird, was auch eine umfangreiche Parameteranalyse verlangt, soll der wirkungsvollste Zeitplan der Entleerung bestimmt werden, was das Thema dieser Arbeit ist.

Schlüsselwörter: Butoniga-Stausee, Frühherbstentleerung, numerisches Model, OpenFOAM