

PRONALAŽENJE IZVORA ONEČIŠĆENJA U VODOOPSKRBNOJ MREŽI CONTAMINATION SOURCE DETECTION IN WATER DISTRIBUTION NETWORKS

Lado KRANJČEVIĆ – Marko ČAVRAK – Marko ŠESTAN

Sažetak: Numeričkim hidrauličkim simulacijama mreže cijevi računaju se piezometrične visine i protoci u unutarnjim točkama cijevi i drugim hidrauličkim elementima mreže. Osim tih proračuna, cilj simulacije također može biti i širenje polutanata ili otopine u cijevnoj mreži. Širenje polutanata kroz vodnodistribucijsku mrežu cijevi uglavnom je uvjetovano svojstvima procesa miješanja u križnim cijevnim spojevima. Realno miješanje u križnom spajaju se unutar pretpostavke modela potpunoga miješanja i modela nepotpunoga miješanja. U ovom radu pokazan je postupak inverznog modeliranja kako bi se odredio izvor zagađenja unutar mreže cijevi. Pretpostavljamo situaciju u kojem se koncentracije zagađenja mjeru u jednom, dva ili više čvorova mreže. Rezultati mjerjenja koriste se kao polazište za postupak inverznog traganja za izvorom zagađenja. Taj je postupak pokazan i verificiran na jednom eksperimentalnom modelu.

Ključne riječi:

- mreža cijevi
- nepotpuno miješanje
- disperzija polutanata
- inverzni postupak traganja za izvorom

Abstract: The numerical hydraulic simulation of pipe networks calculates the heads and discharges at the inner points of pipes and other non-pipe elements of the network. Besides these calculations, contaminant and solutes spreading in the pipe network can be of interest, too. The contamination spreading through the water-distribution pipe networks is controlled mainly by mixing properties at pipe junctions. Real mixing that can occur within a pipe junction lies between the complete-mixing model and incomplete-mixing model assumptions. In this paper, we demonstrate the inverse modeling in trying to detect the source of contamination within the pipe network. We assume a scenario where contaminant concentrations are measured in one, two or more nodes of the pipe network. These results are used as a starting point for the inverse source detecting procedure. The inverse source detection procedure is shown and verified on an experimental model.

Keywords:

- pipe network
- incomplete mixing
- contaminant dispersion
- inverse source detection

1. UVOD

Mreže cjevovoda predstavljaju osnovu inženjerske infrastrukture kod većine sustava za prijenos fluida, poput vodoopskrbnih sustava u velikim gradskim područjima, industriji, navodnjavanju te cijevnim sustavima u zgradama. Postoji mnoštvo numeričkih postupaka za hidrauličku analizu mreže cjevovoda kako bi se izračunali protoci i piezometričke visine. Često korišteni inženjerski računalni programi za stacionarnu i nestacionarnu analizu strujanja u cijevnim sustavima jesu EPANET [1] i AFT FATHOM [2], a jedna je od najčešće korištenih metoda za analizu mreže cijevi Hardy-Cross metoda [3].

U ovom je radu obrađena analiza distribucije onečišćujućih tvari ili otopina u mreži cjevovoda.

Slučajevi namjernoga ili nemamjernoga onečišćenja

1. INTRODUCTION

Pipe networks are a fundamental engineering infrastructure in most fluid transport systems such as the water supply to large urban areas, in industry, and for irrigation and networks inside buildings. There are many numerical techniques for the hydraulic analysis of pipe networks regarding discharge and pressure head. The popular engineering computer programs for steady and unsteady flow analysis in pipe networks are EPANET [1] and AFT FATHOM [2], and one of the most often used methods for pipe network analysis is the Hardy-Cross method [3].

This paper focuses on contaminant or solute distribution analysis in the pipe network. Contaminant transport in water-distribution systems is a growing concern because

sustava za distribuciju vode postaju sve veći problem. Razumijevanje načina na koji se otopljeni tvar prenosi i miješa u mrežnom sustavu cijevi i cijevnih spojeva iznimno je važna za provođenje interventnoga plana u incidentnim situacijama zagađenja. Računalni program EPANET [1], koji je sponzorirala Agencija za zaštitu okoliša SAD-a, standardna je aplikacija za hidrauličko modeliranje i modeliranje kakvoće vode u cjevovodnim sustavima za distribuciju vode. Mnogi postojeći modeli kakvoće vode u distributivnim sustavima zasnivaju se na jednostavnoj pretpostavci trenutnoga potpunog miješanja u križnim spojevima cijevi. Međutim, nedavne studije pokazuju da je miješanje u križnim cijevnim spojevima daleko od potpunoga i savršenoga miješanja: van Bloemen Waanders i dr. [4], McKenna i dr. [5], Romero-Gomez i dr. [6], Choi i dr. [7], Ho [8] te Ho i O'Rear [9]. Te su studije pokazale da pretpostavka o trenutnome potpunom miješanju u križnim cijevnim spojevima može generirati značajnu pogrešku. Stoga, da bi se izvršile točne procjene utjecaja uvedenih onečišćujućih tvari u sustav distribucije vode, trebalo bi modifisirati pretpostavku o potpunome miješanju i primijeniti realniji model miješanja u cijevnim spojevima. Spomenute numeničke simulacije procedure izvršit će se unatrag, kako bi se na osnovi mjerena koncentracije onečišćenja u pojedinim točkama unatražnim postupkom identificirale sve moguće lokacije izvora onečišćenja. Analizirat će se također osjetljivost inverzne procedure za detekcije izvora na broj mjernih točaka i njihovu poziciju u mreži.

2. HIDRAULIČKA ANALIZA I MODELIRANJE DISPERZIJE ONEČIŠĆENJA U CIJEVNOJ MREŽI

U ovome radu pretpostavljeno je stacionarno strujno polje u mrežnom sustavu cijevi pod tlakom, npr. fiksna otvorenost ventila, fiksna dobava u čvorove mreže, kontinuirani rad crpki, veliki spremnici i dr. Postoji mnogo numeničkih tehniki za rješavanje stacionarnih algebarskih jednadžbi mrežnoga sustava cijevi. Iz matematičke perspektive, potrebno je riješiti sustav nelinearnih algebarskih jednadžbi. Takvi sustavi jednadžbi mogu se riješiti Newton-Raphsonovom metodom [10] ili nekom drugom iterativnom numeničkom metodom. Iterativno rješavanje takvih velikih nelinearnih matrica sustava nije jednostavno. Kod slabo kondicioniranih matrica moguće je očekivati probleme konvergencije te numeničku nestabilnost. Specijalni elementi poput kontrolnih ventila za redukciju tlaka mogu također utjecati na numeničke probleme ili poteškoće u sustavu. Jedna od najčešće korištenih metoda za analizu mreže cijevi je Hardy-Cross metoda. Ta metoda zasniva se na pretpostavci da je pad tlaka u svakom zatvorenem krugu jednak nuli te radi na principu balansiranja pada tlaka u zatvorenim krugovima mreže cijevi korigiranjem pretpostavljenih protoka, zadovoljavajući pritom zakon

of the potential for accidental or intentional contamination events. Understanding how solutes move and mix through a network of pipes and junctions is critical for developing mitigation plans, should a contamination event occur. The software EPANET [1], sponsored by the U.S. Environmental Protection Agency, is the standard for modeling hydraulic and water-quality behavior in water-distribution piping systems. Many current water quality models in water distribution systems are based on the simple assumption of instantaneous complete mixing in pipe cross sections. Some recent studies reported that mixing at pipe cross sections is far from complete and perfect: van Bloemen Waanders et al. [4], McKenna et al. [5], Romero-Gomez et al. [6], Choi et al. [7], Ho [8] and Ho and O'Rear [9]. These studies showed that the assumption of complete and instantaneous mixing at pipe cross junctions may generate considerable errors, and therefore, to achieve an accurate prediction of the contaminant introduced in the water distribution system, the assumption should be modified based on a more realistic mixing model in pipe junctions.

Furthermore, we have reversed the mentioned numerical simulation procedures in order to identify all the possible locations that explain contamination incidents detected by the water quality measurements at different points. We need to analyze how sensitive the reverse source detection procedure is regarding the position and number of measurement points.

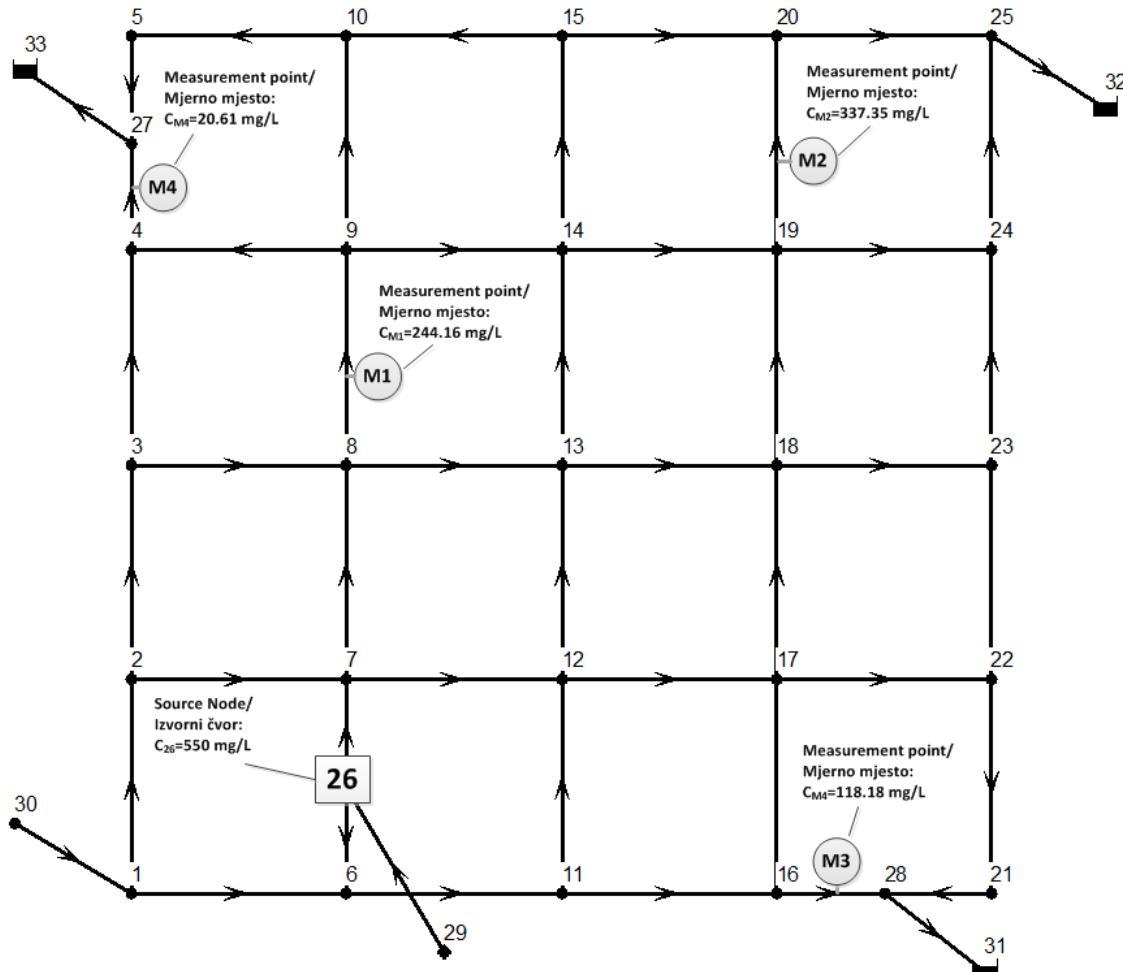
2. HYDRAULIC ANALYSIS AND CONTAMINANT DISPERSION MODELING IN PIPE NETWORK

In this paper, we assumed steady flow in pressure pipe networks, e.g. fixed valve openings, node demands and pump speed, large reservoirs etc. There are many numeničke techniques for solving the algebraic steady-state equations of a pipe network. From the mathematical point of view, the system of nonlinear algebraic equations needs to be solved. This nonlinear system can be solved by implementing the Newton-Raphson method or some other iterative technique. The iterative solution of these large non-linear matrices is not simple. Convergence problems, if the matrix is ill conditioned, as well as numeničke instabilities, may arise. Special elements like pressure reducing valves or check valves can also induce numeničke problems or operational troubles. The most widely used method of pipe network analysis is the Hardy-Cross method.

It uses the fact that the pressure drop in any closed circuit is zero and works on the principle of balancing circuit pressure drop by correcting assumed flows, taking into consideration that the principle of continuity is satisfied at each junction. The numbers of software solutions provide comprehensive, incompressible pipe flow

očuvanja mase u svakom cijevnom spoju u sustavu. Mnogobrojna softverska rješenja omogućuju sveobuhvatne nestacionarne analize strujanja u cijevima i modeliranje sustava npr. AFT FATHOM i EPANET.

analysis and system modeling, e.g. AFT FATHOM and EPANET.



Slika 1. Eksperiment – 5 x 5 mreža cijevi. Smjerovi strujanja označeni strelicama. Utok onečišćene vode (slana voda) u čvoru 26, a čiste vode u čvoru 1. Mjerne točke: M1-M4. Dobavne točke – izlazi iz mreže postavljeni su na cijevi 46, 47 i 48

Figure 1. Experimental setup – 5 x 5 pipe network. Flow directions are indicated by arrows. The contaminant (salt water) inlet is in node 26 and the clean water inlet in node 1. Measurement points: M1 – M4. Demand points – outlets from the network are placed at pipe segments 46, 47 and 48

Sve prikazane procedure za numeričku hidrauličku analizu verificirane su na eksperimentalnom primjeru [11] koji se sastoji od 5 x 5 mrežnog sustava cijevi pod tlakom. PVC-cijevi tipa 40 korištene su za izradu mreže koja se sastoji od 32 spojne cijevi i 25 cijevnih spojeva prikazanih na slici 1. Protoci i koncentracije onečišćujućih tvari u svim elementima cijevne mreže izraženi su u nedimenzijskom obliku koristeći Reynoldsov broj te vrijednosti koncentracija onečišćenja na izlazu iz spojeva normirane ulaznom koncentracijom. Dva plastična spremnika, svaki od 200 l, služe kao spremnici za dobavu vode u sustav. Jedan spremnik napunjeno je čistom vodom, a drugi slanom vodom (120 g

All the numerical hydraulic analysis procedures we showed and verified are on the experimental setup [11], which consists of a 5 x 5 pressurized pipe network. Schedule 40 PVC pipes were used to build a network of 32 pipe links and 25 pipe junctions, as shown in Figure 1. All the network flow and contaminant transport results were presented in dimensionless form using the Reynolds number and outflow contamination concentrations normalized with the inflow concentrations. Two plastic tanks of 200 l served as reservoirs to supply water to the system. One tank was filled with clean water and the other tank with salty water (120 g of NaCl dissolved into 200 l). The clean water tank was connected to junction

soli otopljeno u 200 l vode). Spremnik s čistom vodom spojen je na čvor broj 1, dok je spremnik sa slanom vodom spojen na čvor 26 i predstavlja ulaz onečišćenja u sustav.

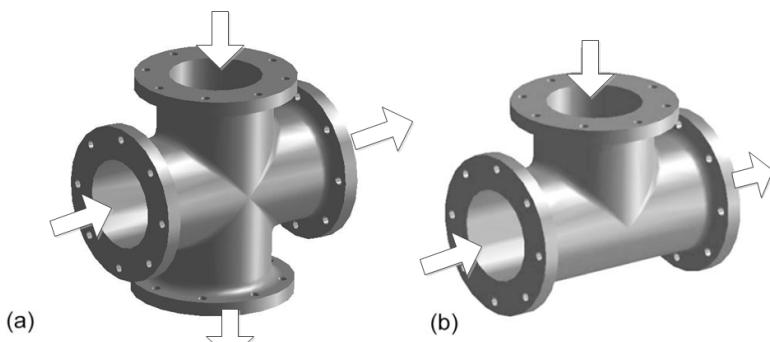
Hidraulika cijevne mreže simulirana je mjerelim utokom (0,87 l/s čiste vode i 0,25 l/s slane vode), dok je istok iz mreže postavljen na 1,12 l/s.

Na slici 1 dan je samo prikaz smjerova toka vode kroz cijevnu mrežu, a vrijednosti simuliranih protoka potpuno se slažu s eksperimentalnim mjerelim vrijednostima [11] i nisu prezentirani radi sažetosti. Protoci i tlak numerički su proračunati na tri različita načina: Hardy-Cross metodom, izravnim rješavanjem nelinearnoga sustava jednadžbi i korištenjem EPANET računalne aplikacije.

no. 1, while the salt-water tank was connected to the network in node 26 and it represented the contaminant inlet.

The network hydraulics was simulated with the measured inflow (0.87 l/s of clean water and 0.25 l/s of salt water) and outflow data (1.12 l/s).

Only flow directions are given in Figure 1, while detailed simulated discharge values were in complete agreement with the experimental measurements [11] and are not presented here for brevity. The discharge and head were numerically calculated in 3 different ways: with the Hardy-Cross method, by the direct solution of the nonlinear system of equations, and using EPANET software.



Slika 2. Tipični cijevni spojevi: (a) križni spoj; (b) T-spoj.

Figure 2. Typical pipe junctions: (a) cross junction; (b) T - junction

Disperzija kontaminanata u vodnom distribucijskom sustavu poprima sve veću pozornost zbog povećanih mogućnosti za iznenadnim ili namjernim incidentima onečišćenja uslijed starosti cjevovodnog sustava ili drugih razloga. Razumijevanje načina na koji se otopljene tvari mijesaju i prenose kroz cijevnu mrežu od izrazite je važnosti za razvijanje hitnih postupaka u slučajevima kontaminacije. Struktura toka onečišćene vode i geometrijska konfiguracija spojeva definira mijешanje i način prijenosa otopljene tvari kroz sustav cijevi u mreži. Tipični cijevni spojevi dozvoljavaju jednu ili mijешanje dviju fluidnih struja u jedan ili više izlaza iz cijevnoga spoja – slika 2.

Nedavne studije pokazale su da su prethodno korištene pretpostavke o potpunom mijешanju u cijevnim spojevima rezultirale netočnim modeliranjima transporta onečišćujućih tvari kroz mrežu [1, 11]. Granica dodira dviju struja u križnom ili T-spoju (slika 2) ima tendenciju razdvajanja, a ne potpunoga mijeshanja.

Fokus većine prethodnih istraživanja s ciljem modeliranja bio je način mijeshanja onečišćujućih tvari u križnim spojevima, koji se najčešće primjenjuju u mrežnim sustavima za distribuciju vode. Nekolicina vodovodnih inženjera procijenila je da 75 - 80 % svih cijevi koje se presijecaju koriste križni spoj umjesto dvostrukog T-spoja ili uparenog T-spoja (slika 3b) zbog niza razloga, uključujući: cijenu, tlačno ograničenje te jednostavnost konstrukcije. Iako mijeshanje u T-spojevima ili dvostrukim T-spojevima u stvarnosti nije potpuno, većina

Contaminant dispersion in water-distribution systems is a growing concern because of the potential for accidental or intentional contamination events. Understanding how solutes move and mix through a network of pipes and junctions is critical for developing urgent procedures in case of contamination. The flow pattern and geometric configuration of these junctions govern the mixing behavior of solutes that enter into them. Typical pipe junctions allow one or more incoming fluid streams to be combined into one or more outlet pipes – Figure 2.

As mentioned in the introduction, recent studies showed that previous assumptions of complete mixing in junctions lead to rather incorrect modeling of contaminant movement through the network. Impinging flows within a cross junction or a T junction (Figure 2) tended to bifurcate rather than mix completely.

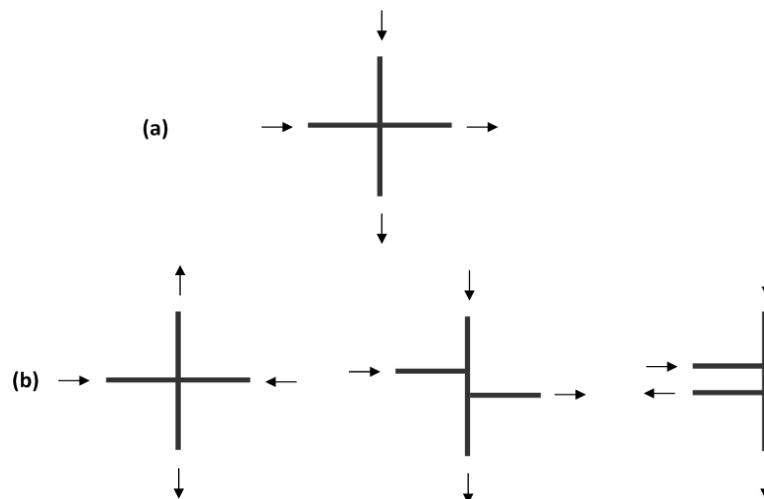
Most of the papers and modeling software focus on contaminant-mixing behavior in cross joints, which are commonly used in water-distribution network systems. Several water utility engineers have estimated that 75 - 80 % of all intersecting pipes use a cross junction instead of a double-T or paired-T junction (Figure 3b), due to a number of factors including cost, thrust restraint, and ease of construction. Even though mixing in T or double T junctions in reality is not complete in most of the specialized hydraulic software, such as EPANET-BAM, mixing is assumed to be complete in junctions of that type because the comprehensive database of mixing patterns has not been established and incorporated into

specijaliziranih hidrauličkih softvera, poput EPANET-BAM-a, pretpostavlja potpuno miješanje u spojevima takva tipa. Takav se pristup koristi zbog toga što opsežne baze tipova miješanja u takvim spojevima još nisu objedinjene niti ugrađene u takve računalne programe.

EPANET-BAM je proširena verzija EPANET aplikacije otvorenog koda, koju distribuira ona strana koja modelira strujanje i transport onečišćujućih tvari kroz cijevne mreže za distribuciju vode. EPANET-BAM koristi novi *Bulk Advective Mixing* (BAM) model za procjenu koncentracija otopljenih tvari u vodi na izlazima križnih spojeva prilikom simulacije kakvoće vode.

EPANET-BAM model korišten je u ovom radu za modeliranje transporta onečišćujuće tvari kroz zadani eksperimentalni model cijevne mreže (slika 1) te je također korišten u procedurama za detekciju izvora onečišćenja opisanim u sljedećem poglavljvu.

Kako bi se formirala baza podataka o miješanju u križnim spojevima pod pretpostavkom različitih ulaznih i izlaznih omjera promjera te uz pretpostavku fluida s različitim koncentracijama onečišćenja koji ulaze u cijevni spoj s različitim količinama gibanja, bilo je potrebno provesti velik broj eksperimenata i CFD-simulacija. Kako je opisano u [8], RANS i LES 3D CFD-simulacije pokazuju da se utočna strujanja odbijaju jedno od drugoga, kao da su kruta tijela tj. biljarske kugle. Miješanje je ograničeno na dodirnu površinu dviju struja, a intenzitet miješanja uvijek je manji od potpunoga.



Slika 3. (a) Pretpostavljeno nepotpuno miješanje; (b) pretpostavljeno potpuno miješenje u numeričkom modelu
Figure 3. (a) Complete mixing assumption; (b) bulk mixing assumption in numerical model

Također, ako npr. pretpostavimo da je protok u vertikalnoj cijevi veći od protoka u horizontalnoj cijevi (slika 4a), nešto čiste vode prolazi kroz križni spoj na suprotnu stranu, a protok onečišćene vode pritom se uglavnom odbija od struje čiste vode. Taj fenomen pri miješanju u križnom spoju, koji je potvrđen eksperimentima [8], predstavlja osnovu tzv. *bulk* modela miješanja.

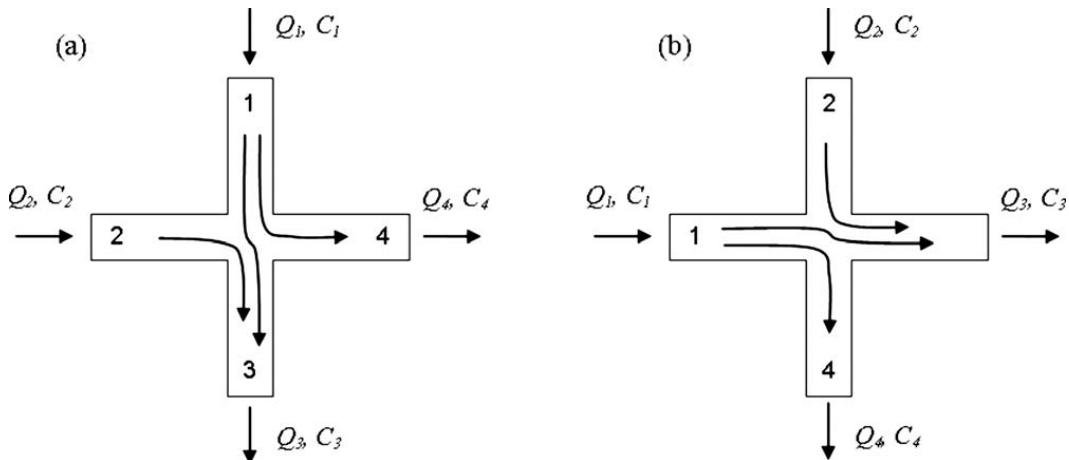
software yet.

EPANET-BAM is an augmented version of EPANET open-source software distributed by the U.S. Environmental Protection Agency that models flow and contaminant transport through water distribution pipe networks. EPANET-BAM uses a new Bulk Advective Mixing (BAM) model to predict concentrations of an aqueous solute at the outlets of cross junctions in water quality simulation.

It was used in this paper to model contaminant transport through a given experimental setup pipe network (Figure 1) and furthermore it was used in the contaminant source detection procedure shown in the next chapter.

In order to build a database of mixing behavior in cross junctions of various inlet and outlet diameter ratios, and assuming that fluid with different contaminant concentrations is entering the joint with differing momentum, numerous experiments and CFD simulations were made. As discussed in [8], RANS and LES 3D CFD simulations show that that the incoming flows reflect off one another, as if they were rigid bodies e.g., billiard balls. Mixing is confined to the impinging interface where the two flows meet, and the amount of mixing is always less than complete. Also, if we assume for example, that the flow in the vertical pipe is greater than the flow in the horizontal pipe (Figure 4a), some of the “clean” water crosses over the junction into the opposite

leg, deflecting most of the “contaminated” water. This kind of cross joint mixing CFD simulated phenomena, which have been confirmed by experiments [8], form the basis for the bulk-mixing model.



Slika 4. Križni spoj cijevi jednakog promjera. Nomenklatura označavanja u modelu nepotpunog miješanja za različite konfiguracije strujanja [8]: (a) veća količina gibanja je u vertikalnom smjeru; (b) veća količina gibanja je u horizontalnom smjeru. Volumni protok označen je sa $Q \text{ m}^3 \text{s}^{-1}$, a koncentracija sa $C \text{ kg m}^{-3}$

Figure 4. Equal pipe diameter cross junction. Numbering assignment in the bulk-mixing model for different flow configurations [8]: (a) greater momentum is in the vertical direction; (b) greater momentum is in the horizontal direction. Volume flow rate is denoted by $Q \text{ m}^3 \text{s}^{-1}$ and concentration is denoted by $C \text{ kg m}^{-3}$

Uz pretpostavku da su komponente dobro izmiješane prije ulaza i nakon izlaza iz spoja, očuvanje mase mješavine koja izlazi kroz cijev 4 (slika 4) daje:

If we assume that constituents are well mixed before entering and after leaving the junction, from a mass balance of the solute exiting from the outlet pipe 4 (Figure 4), it follows:

$$Q_4 C_4 = Q_4 C_1. \quad (1)$$

Budući da se prepostavlja da ništa od utoka iz cijevi 2 ne prolazi prijeko u izlaznu cijev 4, sav protok koji izlazi kroz cijev 4 dolazi iz ulazne cijevi 1. Iz (1) slijedi

$$C_4 = C_1. \quad (2)$$

Koncentracija u izlaznoj cijevi 3 proizlazi iz očuvanja mase u križnom spoju:

The concentration in outlet pipe 3 is derived by performing a solute mass balance on the entire cross junction:

$$Q_1 C_1 + Q_2 C_2 = Q_4 C_1 + Q_4 C_4. \quad (3)$$

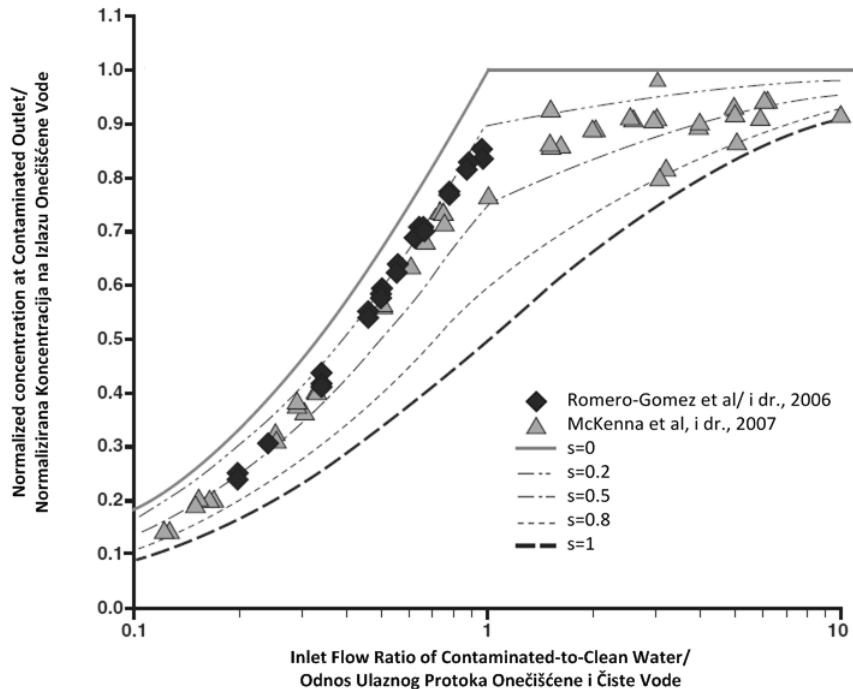
Upotreba dviju prethodnih jednadžbi u sljedećem izrazu za koncentraciju mješavine u izlaznoj cijevi 3:

$$C_3 = C_{BAM} = (Q_2 C_2 + (Q_1 - Q_4) C_1) / Q_3. \quad (4)$$

Prethodni izraz opisuje *bulk* konvektivno miješanje (BAM) te daje izlazne koncentracije uz pretpostavku da su protoci i ulazne koncentracije poznati. Pretpostavka *bulk* miješanja zanemaruje nestabilnosti i difuziju na dodirnoj granici dviju struja te zato ona predstavlja donju granicu intenziteta miješanja koje se javlja u križnom spaju (slika 5).

Using the previous two equations results in the following equation for the solute concentration in outlet pipe 3:

The previous equation provides the solution to the bulk advective mixing (BAM) model and solves for the outlet concentrations, assuming the flow rates and inlet concentrations are known. Bulk mixing presumption neglects instabilities and diffusion at the interface of the impinging flows and therefore it provides a lower bound to the amount of mixing that occurs in the cross junction (Figure 5).



Slika 5. Modelirane i eksperimentalne koncentracije na izlazu onečišćene vode (izlaz onečišćene vode priležeći uz ulaz onečišćene vode) za različite ulazne protoke i iste izlazne protoke

Figure 5. Modeled and experimental normalized concentrations at the contaminated outlet (contaminated outlet adjacent to the contaminated inlet) for different inlet flow rates and equal outlet flow rates

Prepostavka potpunoga miješanja korištena u EPANET-u [1] i mnogim drugim starijim računalnim programima za modeliranje definira da su izlazne koncentracije jednake, što je rezultat prepostavke trenutnoga miješanja unutar križnoga spoja:

$$C_{complete} = C_3 = C_4 = C_{BAM} = (Q_1 C_1 + Q_2 C_2) / (Q_3 + Q_4). \quad (5)$$

Model potpunoga miješanja (5) postavlja gornju granicu intenziteta miješanja koje se događa u križnom spaju (slika 5). Stvaran intenzitet miješanja leži između modela BAM i modela potpunoga miješanja (slika 5). Parametar miješanja $0 \leq s \leq 1$ definira stoga koncentraciju nepotpunoga miješanja

$$C_{incomplete} = C_3 = C_{BAM} + s(C_{complete} - C_{BAM}), \quad (6)$$

pri čemu je s vrijednost parametra miješanja koja ovisi o svojstvu fluida, uvjetima strujanja i geometrijskoj konfiguraciji cijevnoga spoja. Prethodna jednadžba definira model nepotpunoga miješanja. Slika 6 pokazuje da se model nepotpunoga miješanja jako dobro slaže s eksperimentalnim rezultatima dok rezultati simulacija uz potpuno miješanje pokazuju potpuno neslaganje s eksperimentalnim mjerenjima. Dijagonalna crta predstavlja potpuno slaganje [11]. Te se jednadžbe primjenjuju sekvensijalno niz trajektoriju strujanja počevši od cijevnoga spoja na granici gdje su postavljeni

The complete mixing presumption used in EPANET [1] and many other older network modeling software defines the outlet concentrations to be equal as a result of instantaneous mixing within the cross junction:

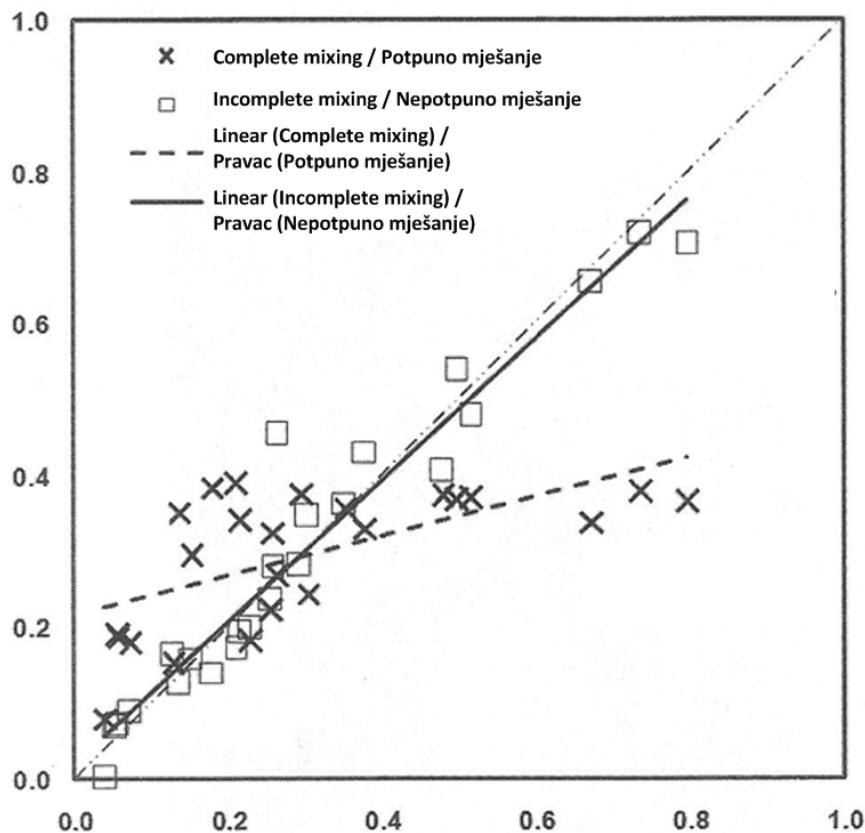
The complete mixing model (5) provides an upper bound to the amount of mixing that occurs in the cross junction (Figure 5). The real mixing amount of mixing lies between the BAM and complete mixing models (Figure 5). Therefore, a mixing parameter, $0 \leq s \leq 1$ is defined in order to estimate an incomplete concentration

where the value of the mixing parameter s depends on fluid properties, flow conditions and the geometric configuration of the pipe junction. The previous equation defines the incomplete mixing model. Figure 6 shows incomplete mixing as having very good agreement with the experimental results while the complete mixing simulation results completely miss the experimental measurements. The diagonal line represents the full match [11]. These equations are applied sequentially downstream from the flow path, starting with the junction on the boundary where boundary conditions are set.

granični uvjeti. Prije provođenja simulacije širenja onečišćenja potrebno je izračunati protoke unutar mreže cijevi. Model nepotpunoga miješanja u križnim spojevima može se koristiti i u nestacionarnim simulacijama tako da se u svakom vremenskom koraku primjenjuje s ažuriranim vrijednostima protoka. Dosad smo tretirali samo križne spojeve s priležećim ulazima i istim promjerima cijevi, dok križni spojevi s priležećim ulazima i različitim promjerima cijevi uzrokuju dodatne fenomene strujanja.

Before contaminant dispersion modeling, flow rates within the pipe network must be calculated. The incomplete mixing model in the cross junction can be used even in the unsteady simulations, applying it at each time step with updated discharge values.

So far, we have discussed only cross junctions with adjacent inlets with equal pipe diameters, while cross junctions with adjacent inlets with unequal pipe sizes bring additional phenomena.



Slika 6. Usporedba eksperimentalnih i simuliranih (potpuno miješanje i nepotpuno miješanje) koncentracija onečišćenja

Figure 6. Comparison of measured and simulated (complete mixing and incomplete mixing) contamination concentrations

U slučaju mnogo veće količine gibanja u većoj cijevi, protok s većom količinom gibanja u većoj cijevi prelazi na drugu stranu istodobno potpuno blokirajući protok iz manje cijevi. U suprotnom slučaju veće količine gibanja u manjoj cijevi javlja se efekt *omatanja*, pri čemu protok veće količine gibanja prodire na drugu stranu prolazeći kroz protok iz veće cijevi. Protok iz veće cijevi *omata* se oko protoka veće količine gibanja iz manje cijevi [9].

T-spojevi, dvostruki T-spojevi i ostali cijevni spojevi nisu do sada bili sistematski obradivani i klasificirani glede parametra miješanja s te se tu otvara prostor za budući CFD i eksperimentalni rad.

In the case of a much higher momentum in the larger pipe, a high momentum flow from the larger pipe crosses over on the other side, completely blocking the flow from the smaller pipe. In the opposing case of a higher flow momentum in the smaller pipe, wraparound effect emerges where high momentum flow penetrates on the other side through the larger pipe flow. Flow from the larger pipe wraps around the high momentum flow from the smaller pipe [9].

T-junctions, double T-junctions and other pipe junctions have not been elaborated and classified systematically regarding the mixing parameter s and there is a potential for future CFD and experimental work in this area.



Slika 7. Rezultat simulacije distribucije onečišćenja baziranoj na modelu nepotpunog miješanja u križnim spojevima cijevi – izolinije koncentracija onečišćenja

Figure 7. Simulation results of the contamination distribution based on the incomplete mixing model in cross junctions - isoconcentration lines of the contamination

Modeliranje širenja onečišćenja

Provđena je numerička simulacija širenja onečišćenja u eksperimentalnoj mreži cijevi (slika 1) te su pritom uzeti u obzir modeli potpunoga i nepotpunoga miješanja te parametar s . Numerička simulacija slijedila je postavke eksperimenta, pri čemu je slana voda zadane koncentracije NaCl korištena kao onečišćivač i injektirana je u sustav u čvoru 26. Parametar miješanja postavljen je na vrijednost $s = 0,5$ u križnim spojevima, dok je u T-spojevima pretpostavljeno potpuno miješanje. Rezultati simulacija dani su na slici 1, gdje su pokazane dobivene vrijednosti koncentracija u točkama M1 do M4. Izolinije koncentracija onečišćenja na slici 7 pokazuju *oblak* onečišćenja koji se prostire dijagonalno prema gornjem desnom kutu mreže. Dobiveni oblik konturnih linija bio je očekivan s obzirom na to da je simulacija provedena uz model nepotpunoga miješanja u križnim spojevima. Rezultati dobiveni simulacijom – koncentracije onečišćenja u zadanim točkama M1, M2, M3 i M4 – koriste se kao polazna točka u unatražnom postupku traganja za izvorom onečišćenja izloženom u sljedećem poglavljju. Uspješno proveden unutražni postupak trebao bi pokazati da je čvor 26 izvor onečišćenja, a postupak kreće od *izmjereneh* koncentracija u jednoj ili više točaka M1 – M4.

Contamination distribution modeling

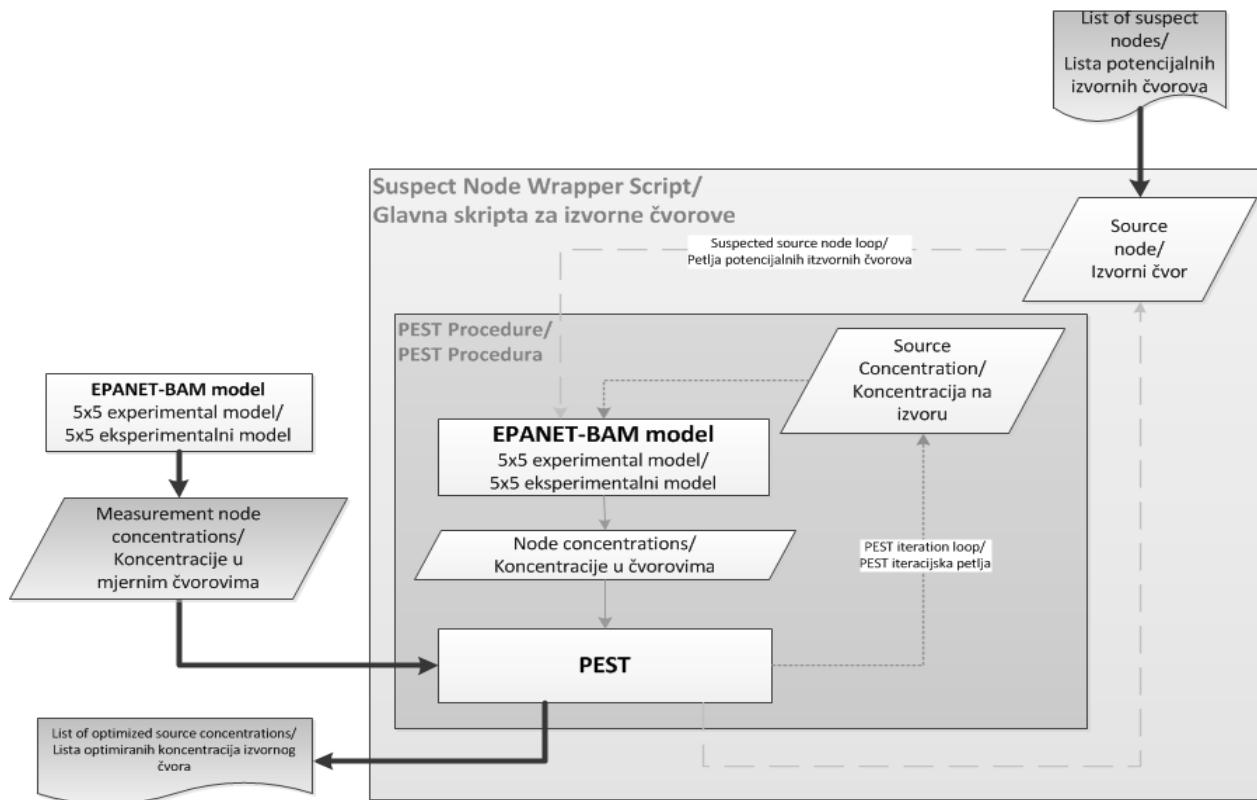
Taking into consideration the complete and incomplete mixing models and mixing parameter s , the numerical simulation of the contaminant distribution in the experimental pipe network (Figure 1) was performed. Numerical simulation followed experimental setup, where salty water with the given NaCl concentration was used, as in node 26. The mixing parameter was set as $s = 0.5$ in cross junctions, while complete mixing was assumed in the T-junctions. The results of the simulation are given in Figure 1, showing simulated concentrations in points M1 to M4. Contours representing isoconcentration lines of the contaminant are presented in Figure 7, showing contamination plume spreading diagonally to the upper right corner of the network. The resulting shape of the contour lines was expected following the implementation of the incomplete mixing model in the cross junctions. Obtained simulation results – contaminant concentrations in the given points M1, M2, M3 and M4 – are used as a starting point for the reverse contamination source detection procedure presented in the next chapter. The successful reverse modeling procedure would have to indicate the node 26 as the source of contamination starting from measured concentrations in one or more of the points M1 – M4.

3. INVERZNI NUMERIČKI POSTUPAK TRAGANJA ZA IZVOROM ONEČIŠĆENJA

Česte su pojave grupnih obolijevanja određenoga dijela populacije nekoga urbanog područja zbog dugotrajne izloženosti zagađenoj vodi iz vodovodnog sustava. Bilo dugotrajnim izlaganjem pučanstva niskorizičnim razinama onečišćenja ili kratkoročnim visokorizičnim razinama onečišćenja vode, izrazito je važno pravodobno procijeniti izvor zagađenja kako bi se zaštitilo građanstvo i očuvao okoliš. Centri za praćenje stanja u okolišu te za upravljanje vodovodnim sustavima trebali bi poduzimati sigurnosne mjere i upravljati rizičnim situacijama razvijanjem i primjenom metodologije za mjerjenje, detekciju i pravodobno obavješćivanje o potencijalnim onečišćenjima u sustavu. Jedan je od sastavnih dijelova upravljanja rizikom i procedura za identifikaciju izvora onečišćenja u kombinaciji sa sustavom za kontinuirano mjerjenje kakvoće pitke vode u sustavu.

3. INVERSE CONTAMINATION SOURCE DETECTION NUMERICAL PROCEDURE

Prolonged exposure to an unknown contaminant can often influence the wellness of certain groups of the population that are in contact with polluted water. Therefore, it is crucial to estimate the location of the pollution source in time for natural preservation and human health whether: exposure is long-term at a low toxic level or short-term at a highly toxic level. Environmental protection agencies and water distribution network control centers should undertake security measures and include risk management for different scenarios by developing and applying a methodology for pollution measurement, detection and early warning public notification. One of important parts of risk management is a procedure for the identification of a potential source of water pollution in combination with continuous water quality measurements.



Slika 8. Shematsizirani prikaz inverzne procedure za detekciju izvora korištenjem EPANET-BAM modela u kombinaciji sa PEST algoritmom te njemu pripadnim ulaznim podacima

Figure 8. Schematic diagram presenting inverse source detection procedure using EPANET-BAM in combination with PEST and its input data requirements

Primjena zahtjevnih računalnih algoritama za detekciju izvora onečišćenja omogućena je razvojem računala visokih performansi. Inverzni numerički postupak omogućuje identifikaciju izvora zagađenja te razinu

The growth of high performance computers has enabled the application of demanding computer algorithms for pollution source detection. The inverse numerical procedure is one of the algorithms for the identification of

konzentracije kojom izvor zagađuje. Sastoji se od optimizacijskog algoritma koji kontrolira i modificira ulazne i izlazne podatke nezavisnoga hidrauličkog modela i modela za disperziju onečišćujućih tvari u mreži cjevovoda.

Primjenjeni sustav detekcije prikazan je na slici 8. Provedena je inverzna detekcija izvora zagađenja na eksperimentalnom mrežnom modelu (5 x 5) – slika 1. U prethodnom poglavljju pokazana je simulacija širenja zagađenja iz čvora 26 (koncentracije 550 mg/l), a u ovom poglavljju pokazat će se inverzni postupak kako bi se došlo do nepoznatog izvora zagađenja (čvor 26).

Prepostavimo situaciju u kojoj se nakon pritužbi građana izvode mjerena onečišćenja u određenim točkama mreže. Na osnovi mjerena provodi se inverzni numerički postupak koji kao rješenje upućuje na jedan ili više čvorova u mreži koji su izvor onečišćenja.

Za svaki potencijalni izvorni čvor provodi se niz hidrauličkih proračuna i modela za disperziju EPANET-BAM, gdje je kao nezavisni parametar uzeta razina koncentracije na potencijalnom izvornom čvoru, a koja može poprimiti vrijednosti u rasponu od 0 do 2000 mg/l. Kontrolu razine koncentracije provodi evolucijski algoritam PEST [12] čija je funkcija cilja minimizacija razlike modeliranih i mjereneh vrijednosti koncentracija u mjernim čvorovima.

PEST [12] je slobodni računalni program za provođenje nelinearne optimizacije parametara nezavisnog modela. Koristi robusni Gauss-Marquardt-Levenbergov algoritam koji kombinira prednosti inverzne Hessianove metode i metode strmog silaska, čime omogućava efikasniju konvergenciju prema minimumu funkcije cilja. PEST koristi lokalnu kalibracijsku metodu i traga za najboljom vrijednosti parametra modela pomoću minimizacije sume kvadrata razlike između mjereneh i modelom proračunatih vrijednosti ϕ .

$$\varphi = \sum_{i=1}^m \left[C_{\text{model}}^i - C_{\text{measurement}}^i \right]^2, \quad (7)$$

i – indeks mjerne točke/measurement point index,
 m – broj mjernih točaka/number of measurements/observations.

U ovom je članku provedeno niz prethodno opisanih simulacija kako bi se istražio utjecaj broja mjernih točaka na točnost detekcije izvora zagađenja. Korištenjem minimalnih lokacijskih uvjeta odabrane su četiri mjerne lokacije u čvornoj mreži eksperimentalnoga modela (5 x 5) (slika 1), a vrijednosti njima pripadnih koncentracija očitane su iz modela disperzije prezentiranog u prethodnom poglavljju (slika 1).

pollution sources and their contamination levels. It contains an optimization algorithm that controls and modifies input and output data for a combination of the hydraulic and the water pollution dispersion model.

The detection system applied in this article is presented in Figure 8. The presented inverse source detection procedure was conducted on the experimental network model (5 x 5) – Figure 1. In the previous chapter, simulation of contamination distribution from the node 26 (550 mg/l concentration) was presented, and in this chapter the inverse procedure to detect the *unknown* source of contamination (node 26) is defined.

Let's suppose the scenario in which, following citizen complaints, local officials take water samples to determine contamination concentration at certain points in the network. Following the measurements, the inverse numerical procedure is implemented and it identifies one or more nodes in the network as the possible source of contamination.

A series of hydraulic and dispersion simulations using the EPANET-BAM model were conducted for each suspect node. The concentration level at the suspect node was taken as an independent parameter. Its values can range between 0 and 2000 mg/l and it is under the control of the evolutionary algorithm PEST [12] whose objective it is to minimize the difference between measured and modeled concentration values at the measurement nodes.

PEST [12] is the nonlinear parameter estimation and optimization package, which offers model independent optimization routines. It applies a robust Gauss–Marquardt–Levenberg algorithm, which combines the advantages of the inverse Hessian method and the steepest descent method and therefore provides faster and more efficient convergence towards the objective function minimum. PEST uses a local calibration method and searches for the best values of the model parameters by minimizing the sum of squares of the differences between measured and calculated model results ϕ .

In this article, a series of such simulations were performed to investigate the impact of a varying number and location of quality measurement points on the accuracy of source detection. Using minimal sensory location conditions, four measurement locations are chosen in the network of the experimental model 5 x 5 (Figure 1), while their concentration values are read from the dispersion model results presented in previous chapter (Figure 1).

Tablica 1. Rezultati provedene inverzne detekcije izvora kontaminacije koji prikazuje potencijalne izvorne čvorove zagađenja s obzirom na odabrane mjerne čvorove

Table 1. Display of results of inverse source detection procedure showing characteristics of suspected source nodes according to selected measurement nodes

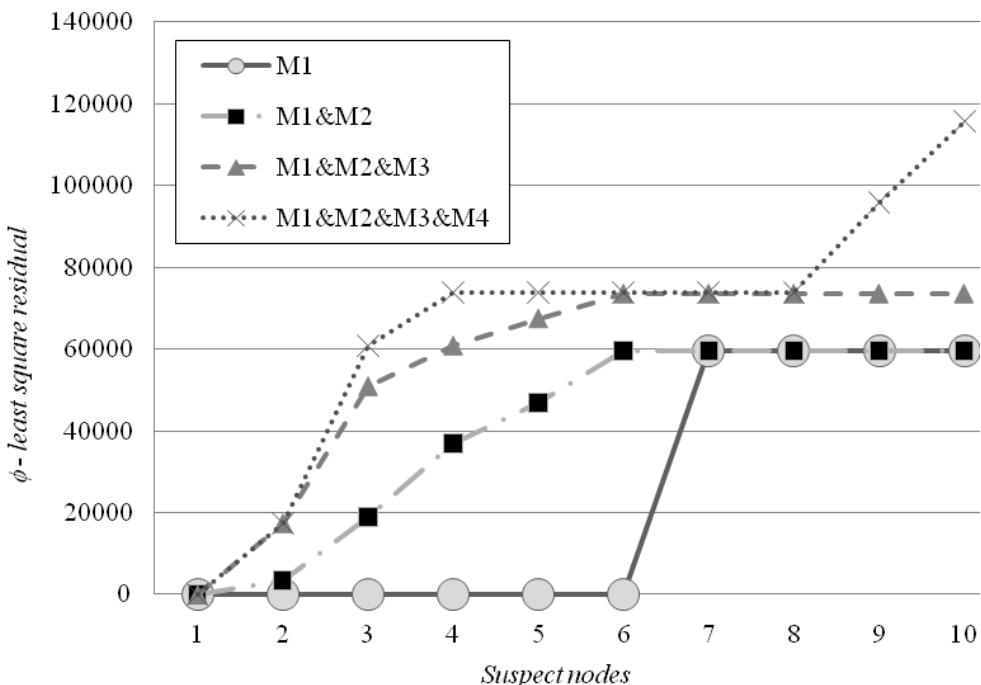
Measurement Node/ Mjerni čvor	Source Node/ Izvorni čvor	Source Concentration/ Konzentracija na izvoru [mg/L]	Optimized least square value	Measurement Node/ Mjerni čvor	Source Node/ Izvorni čvor	Source Concentration/ Konzentracija na izvoru [mg/L]	Optimized least square value
M1	1	438.80	0.00	M1+M2	26	549.51	0.01
	2	438.80	0.00		7	367.86	3487
	3	1102.30	0.00		1	579.96	18877
	7	313.36	0.00		2	593.40	36983
	N8	244.00	0.00		N8	327.55	46873
	26	549.64	0.00		26	549.55	0.01
M2	1	871.60	0.00	M1+M3	2	438.80	13924
	2	1212.16	0.00		3	1102.30	13924
	7	418.92	0.00		7	313.36	13924
	N8	804.15	0.00		N8	244.00	13924
	12	581.59	0.00		26	549.41	0.00
	13	397.98	0.00		2	1212.16	13924
	14	727.19	0.00		7	418.92	13924
	18	628.06	0.00		N8	804.15	13924
	N19	337.00	0.00		12	581.59	13924
	26	549.43	0.00	M2+M3	26	549.54	0.17
M3	1	150.29	0.00		6	118.00	441
	6	118.00	0.00		11	118.00	441
	11	118.00	0.00		16	118.00	441
	16	118.00	0.00		1	72.93	6109
	26	549.12	0.00		26	549.48	0.01
M4	1	21.82	0.00	M1+M2+M3	7	367.86	17411
	2	21.82	0.00		2	593.40	50907
	3	22.48	0.00		N8	327.55	60797
	4	21.00	0.00		1	333.54	67404
	7	319.45	0.00	M1+M2+M3+M4	26	549.51	0.18
	N8	225.36	0.00		7	367.67	17422
	9	225.36	0.00		N8	326.90	60886
	26	560.31	0.00		12	581.59	73901
					13	397.98	73901

Prvotno su provedene simulacije scenarija kod kojih je uključeno samo jedno mjerno mjesto (M1, M2, M3 ili M4). Takvi scenariji pojedinačno su rezultirali nizom od više potencijalnih uzstupnih izvora i njima optimiziranim koncentracijama. Svaki scenarij koji uključuje samo jedno mjerjenje, posjeduje više čvorova kod kojih je kvadrat razlike mjerenih i proračunatih vrijednosti koncentracija u mjernoj točki jednak nuli, što je vidljivo u tablici 1 (lijevo), te time jedan mjerni čvor ne može biti dovoljan za postupak inverzne detekcije izvora onečišćenja. Međutim, kod provedenih simulacija s dva ili više mjernih čvorova rezultati ukazuju na očekivani izvorni čvor onečišćenja (čvor 26) s točnom koncentracijom onečišćenja od 550 mg/l (tablica 1 desno).

Što se više mjernih točaka koristi u inverznoj proceduri, to je konvergencija brža i veća je razlika u rezultatu između prvoga i sljedećeg na listi suspektnih čvorova.

Initially, single sensor node scenarios were simulated for M1, M2, M3 and M4 measurement nodes. These scenarios have individually resulted in a series of multiple potential upstream sources along with their optimized concentrations. Each scenario that includes only one measurement point yields multiple potential sources with zero-level least square residuals (shown in Table 1 - left) and therefore, only one measurement node is not enough for the source detection procedure. On the other hand, scenarios that include two or more measurement nodes lead exactly toward the expected source node 26 with an exact contamination concentration of 550 mg/l (Table 1 - right).

When more sensors were included in the inverse detection procedure, the convergence to an optimal value was faster and the difference in the result between the first and the second suspect nodes was greater.



Slika 9. Usporedba minimiziranih najmanjih kvadrata razlike mjerene i modelirane vrijednosti koncentracija za svaki promatrani izvorni čvor sortiranih prema manjim vrijednostima ϕ , a u odnosu na broj mjerene koncentracije

Figure 9. A comparison of minimized least square residuals for each suspected source node sorted according to lesser values with respect to the number of measured concentrations

Konačno, moguće je zaključiti, prema dijagramu prikazanom na slici 9, da su tri mjerne točke optimalni broj za inverznu detekciju izvora.

Rezultati su također pokazali da, svaka kombinacija dva mjerna čvora (M1 - M2, M2 - M3, M1 - M3 i M3 - M4), odabrana prema gore definiranoj metodologiji, točno detektira izvor zagađenja i pripadnu koncentraciju u približno istom proračunskom vremenu. Povećanjem broja mjernih čvorova na tri i četiri mjernih mjesta (M1 - M3, M1 - M4) uočljive su nešto veće razlike u rezultatima na listi suspektnih čvorova dok se proračunsko vrijeme nije znatno promijenilo.

4. ZAKLJUČAK

U ovom radu prikazan je postupak za detekciju izvora onečićenja korištenjem sustava računalnih aplikacija za hidraulički proračun mreže cjevovoda (EPANET), Bulk Advective Mixing modela (BAM) te algoritma za parametarsku optimizaciju (PEST).

Rezultati provedenih inverznih simulacija nad eksperimentalnim modelom 5×5 pokazali su da je detekcija izvora uspješno provedena te da se izvor poklapa s očekivanom lokacijom osim kod scenarija kod kojih je korištena samo jedna merna točka ili nisu zadovoljeni određeni uvjeti kod određivanja lokacija mjernih točaka. Vrijednosti koncentracije na izvoru također se izvrsno poklapaju s očekivanim vrijednostima

Finally, it can be stated that, according to the plot in Figure 9, three measurements are adequate for superior source detection.

Results have also shown that each combination of two measurement points (M1 - M2, M2 - M3, M1 - M3 i M3 - M4), chosen by aforementioned methodology, reached the exact solution within the same timeframe and with exactly the same concentration level. Three or four measurement nodes provided more significant result differences on the suspect nodes list and produced no computer time change.

4. CONCLUSION

The procedure for contamination source detection was conducted in this paper, using the hydraulic model (EPANET), Bulk Advective Model (BAM) and an optimization routine for parameter estimation (PEST). Evaluation of the inverse source detection procedure was conducted on the 5×5 experimental model. Results show successful detection of the source location when more than one sensor was included in the analysis and when minimal conditions for the choice of measurement locations were met. Source concentration values match the expected values from the experimental simulation, hence justifying the application of the evolutionary algorithm for nonlinear parametrical optimization PEST.

te opravdavaju primjenu evolucijskog algoritma za nelinearnu optimizaciju parametara PEST. Nadalje, provedena je također analiza osjetljivosti inverzne procedure na odabir mjernih lokacija. Prilikom odabira mjernih lokacija potrebno je voditi računa o minimalnim uvjetima koji utječu na mogućnost detekcije izvornog čvora. Minimalni uvjeti pod kojima će uspješnost detekcije biti ostvarena dobiveni su kao rezultat niza simulacija s nasumičnim odabirom lokacija i različitim brojem mjernih čvorova te detaljnog analizom strujnog polja mreže cjevovoda.

Uočeno je da mjerni čvorovi moraju biti dovoljno udaljeni kako se ne bi nalazili na istoj trajektoriji te potencijalni mjerni čvorovi moraju imati što veći broj različitih uzstrujnih čvorova.

Algoritmi i postupci prikazani u ovom radu obuhvaćaju identifikaciju jedinstvenog izvora onečišćenja, što je i najčešći slučaj u praksi, međutim mogući su scenariji traganja za više izvora zagađenja istodobno. Takve simulacije zahtijevaju višeciljnu optimizaciju i statističku analizu kako bi se mogao procijeniti najvjerojatniji scenarij.

Buduća istraživanja u ovom području trebala bi proširiti bazu podataka miješanja u cjevnim spojevima izvođenjem 3D CFD-simulacija u raznim cjevnim spojevima. Potrebno je provesti optimizaciju prilikom određivanja broja i pozicija mjernih točaka te je potrebno istražiti druge optimizacijske metode u inverznom postupku traganja za izvorom onečišćenja.

POPIS OZNAKA

Koncentracija i-te cijevi	C_i
Protok kroz i-tu cijev	Q_i
Parametar mješanja	s
i-ta mjerna točka	M_i
Vrijednost najmanjih kvadrata	ϕ

LITERATURA REFERENCES

- [1] Rossman, L. *EPANET – User's manual*, United States Environmental Protection (USEPA), 2000.
- [2] AFT Fathom User's Guide, Applied Flow Technology Corporation, 2008.
- [3] Streeter, V.L., Wylie, E.B., *Fluid Mechanics*, 8th Edition, McGraw-Hill, Inc., USA, 1985.
- [4] Van Bloemen Waanders, Hammong, G., Collis S. J., Murray, R. *A comparison of Navier-Stokes and network models to predict chemical transport in municipal water distribution systems*, Proc. World Water and Environmental Resources Congress, ASCE/EWRL, Anchorage, 2005.
- [5] McKenna, S. A., O'Rear, L., Wright, J. L., *Experimental determination of solute mixing in pipe joints*, Proc. World Water and Environmental Resources Congress, ASCE/EWRL, Tampa, 2007.
- [6] Romero-Gomez, P., Choi, C. Y., van Bloemen Wanders, B., McKenna, S. A. *Transport phenomena at intersections of pressurized pipe systems*, Proc. 8th Annual Water Distribution Systems Analysis Symp., ASCE, 2006.
- [7] Choi, C. Y., Shen, J. Y., Austin, R., *Development of a comprehensive solute mixing model (AZRED) for double-tee, cross, and wye junctions*, Proc. 10th Annual Water Distribution Systems Analysis Symp., ASCE, 2008.

Sensitivity analysis regarding the choice of measurement locations of the inverse procedure is implemented. Positions of the measurement points have to satisfy the minimal conditions needed for the inverse detection algorithm to make quality predictions. Those minimal conditions are a result of the series of simulations with a random choice of locations, variable number of nodes and with a detailed analysis of the flow field in the observed pipe network.

It is noted that measurement nodes need to be distant enough not to reside on the same trajectory and potential measurement nodes must have as many different upstream nodes as possible.

The algorithms and procedures shown in this paper contribute to the identification of a unique source of contamination, which is the most likely a real-life scenario but nevertheless, scenarios with multiple sources of contamination are quite possible. Multiple sources detection simulations require multiobjective optimization techniques and statistical analysis in order to evaluate the most probable scenario.

Further research in this area should broaden the database of mixing properties in pipe joints performing 3D CFD simulations in various pipe joints; optimization of the measurement points number and locations should be implemented and other optimization methods in the reverse contamination source detection procedure should be investigated.

LIST OF SYMBOLS

Concentration of i^{th} pipe	C_i
Discharge rate through the i^{th} pipe	Q_i
Mixing parameter	s
i^{th} measurement point	M_i
Least square value	ϕ

-
- [8] Ho, C. K., *Solute Mixing Models for Water-Distribution Pipe Networks*, Journal of Hydraulic Eng., ASCE, 2008.
 - [9] Ho, C. K., O'Rear jr L., *Evaluation of solute mixing in water distribution pipe junctions*, Journal AWWA 101:9, 2009.
 - [10] Chapra, S. C., Canale, R. P., *Numerical Methods for Engineers*, 2nd International Edition, McGraw-Hill Inc., Applied Mathematics Series, 1990.
 - [11] Song, I., Romero-Gomez, P. and Choi, C. Y. *Experimental Verification of Incomplete Solute Mixing in a Pressurized Pipe Network with Multiple Cross Junctions*, Journal of Hydraulic Engineering, Vol. 135, No 11, 2009.

Primljeno/Received: 10.11.2010.

Prihvaćeno / Accepted: 24.11.2010

Izvorno-znanstveni članak

Original scientific paper

Adresa autora / Authors' address:

Assist. Prof. Ph.D. Lado Kranjčević, Mech. Eng.
M. Sc. Marko Čavrak, Mech. Eng.
BSc. Marko Šestan, Eng.
University of Rijeka, Faculty of Engineering
Vukovarska 58
HR-51000 RIJEKA, Hrvatska