

ANTROPOGENI UTJECAJ NA PODZEMNE VODE CRPILIŠTA STRMEC (ZAGREB, HRVATSKA)

Zoran NAKIĆ¹, Andrea BAČANI¹, Tatjana VLAHOVIĆ²

¹ Rudarsko-geološko-naftni fakultet Sveučilišta u Zagrebu, L. Pierottija 6, HR-10 000 Zagreb, Hrvatska

² Hrvatske Vode, ul. grada Vukovara 232, HR-10 000 Zagreb, Hrvatska

Ključne riječi: Multivarijantne statističke metode, Hidrokemija, Kvaliteta podzemnih voda, Crpilište Strmec, Hrvatska

Multivarijantne statističke metode: "Cluster" analiza i "Multidimensional scaling" analiza pokazale su da se pijezometri unutar zaštitnih zona crpilišta Strmec s obzirom na pokazatelje antropogenog zagađenja mogu grupirati u tri "cluster-a" ili grupe. Rezultati tih analiza omogućili su procjenu utjecaja odlagališta otpada Trebež na podzemnu vodu crpilišta Strmec. "Principal component" analiza odredila je najznačajnije makro i mikro komponente koje su ili koje mogu biti posljedica antropogenog zagađenja. Analiza vremenskih serija podataka ("Time series analysis") pokazala je trendove najznačajnijih komponenata.

Uvod

Projektom "Evidencija i gospodarenje podzemnim vodom Hrvatske" (EGPV) registrirane su brojne pojave kontinuiranog i povremenog zagađenja na lokacijama promatranih pijezometara. Ustanovljeno je da je kvaliteta podzemne vode na području cijelog zagrebačkog vodonosnog sustava evidentno pogoršana. Jedno od najvećih zagrebačkih crpilišta, crpilište Strmec, posebno je ugroženo jer se nalazi nizvodno od Trebeža, velikog odlagališta otpada. Ostali potencijalni izvori zagađenja unutar zaštitnih zona crpilišta Strmec su: divlje šljunčare i divlja smetlišta, poljoprivredna zemljišta, otvoreni kanalizacijski sustav grada Samobora, te potok Rakovica koji prima otpadne vode kućanstva i industrije.

Kako bi odredili glavne uzroke zagađenja i opću kvalitetu podzemne vode unutar postojećih zaštitnih zona, Bačani i dr. (2001) istražili su kvalitetu vode na odabranim lokacijama pijezometara. Rezultati su pokazali prilično velike varijacije kvalitete vode, kako prostorno, tako i vremenski. Dokazana je negativna uloga odlagališta otpada Trebež u pogoršanju kvalitete podzemne vode na nizvodnim pijezometrima. Nije međutim ustanovljeno područje utjecaja odlagališta. Također je uočena i promjena kvalitete vode na većini pijezometara unutar zaštitnih zona crpilišta, s naznakom pojave trendova pojedinih makro i mikro komponenata.

Stoga su u cilju daljih istraživanja na tom području od komunalnog poduzeća "Vodoopskrba i odvodnja" prikupljeni dodatni podaci o kvaliteti podzemne vode crpilišta Strmec. Kako bi se ispitale sličnosti i međupovezanosti hidrokemijskih podataka iz pijezometara, s obzirom na moguće antropogene utjecaje, provedeno je ispitivanje prikupljenih podataka. Zaključeno je da su za dalju obradu relevantni podaci za 1998. godinu, za stanje visokih vodostaja podzemnih voda, te podaci za 2000. godinu, za stanje niskih vodostaja. Pri tom su korištene multivarijantne statističke metode: "Cluster" i "Multidimensional scaling" analiza.

Provedena je i analiza vremenskih serija podataka s pojedinih pijezometara. Primjenom "Principal component"

Key-words: Multivariate statistic methods, Hydrochemistry, Ground water quality, Strmec well field, Croatia

The multivariate statistic methods: the Cluster analysis and the Multidimensional scaling analysis showed the grouping of the piezometers within sanitary protection zones in the three clusters, concerning the indexes of anthropogenic pollution. The results of the analyses provided the evaluation of the influences of the waste depository Trebež on the ground water of the Strmec well field. The Principal component analysis revealed the most important macro and micro components, which are or could be the consequence of the anthropogenic pollution. The Time series analysis showed the trends of the most important components.

analize utvrđene su najznačajnije makro i mikro komponente, koje su, ili koje mogu biti posljedice antropogenog utjecaja, a utječu na promjene kvalitete podzemne vode. Daljom analizom vremenskih serija određeni su trendovi tih komponenata.

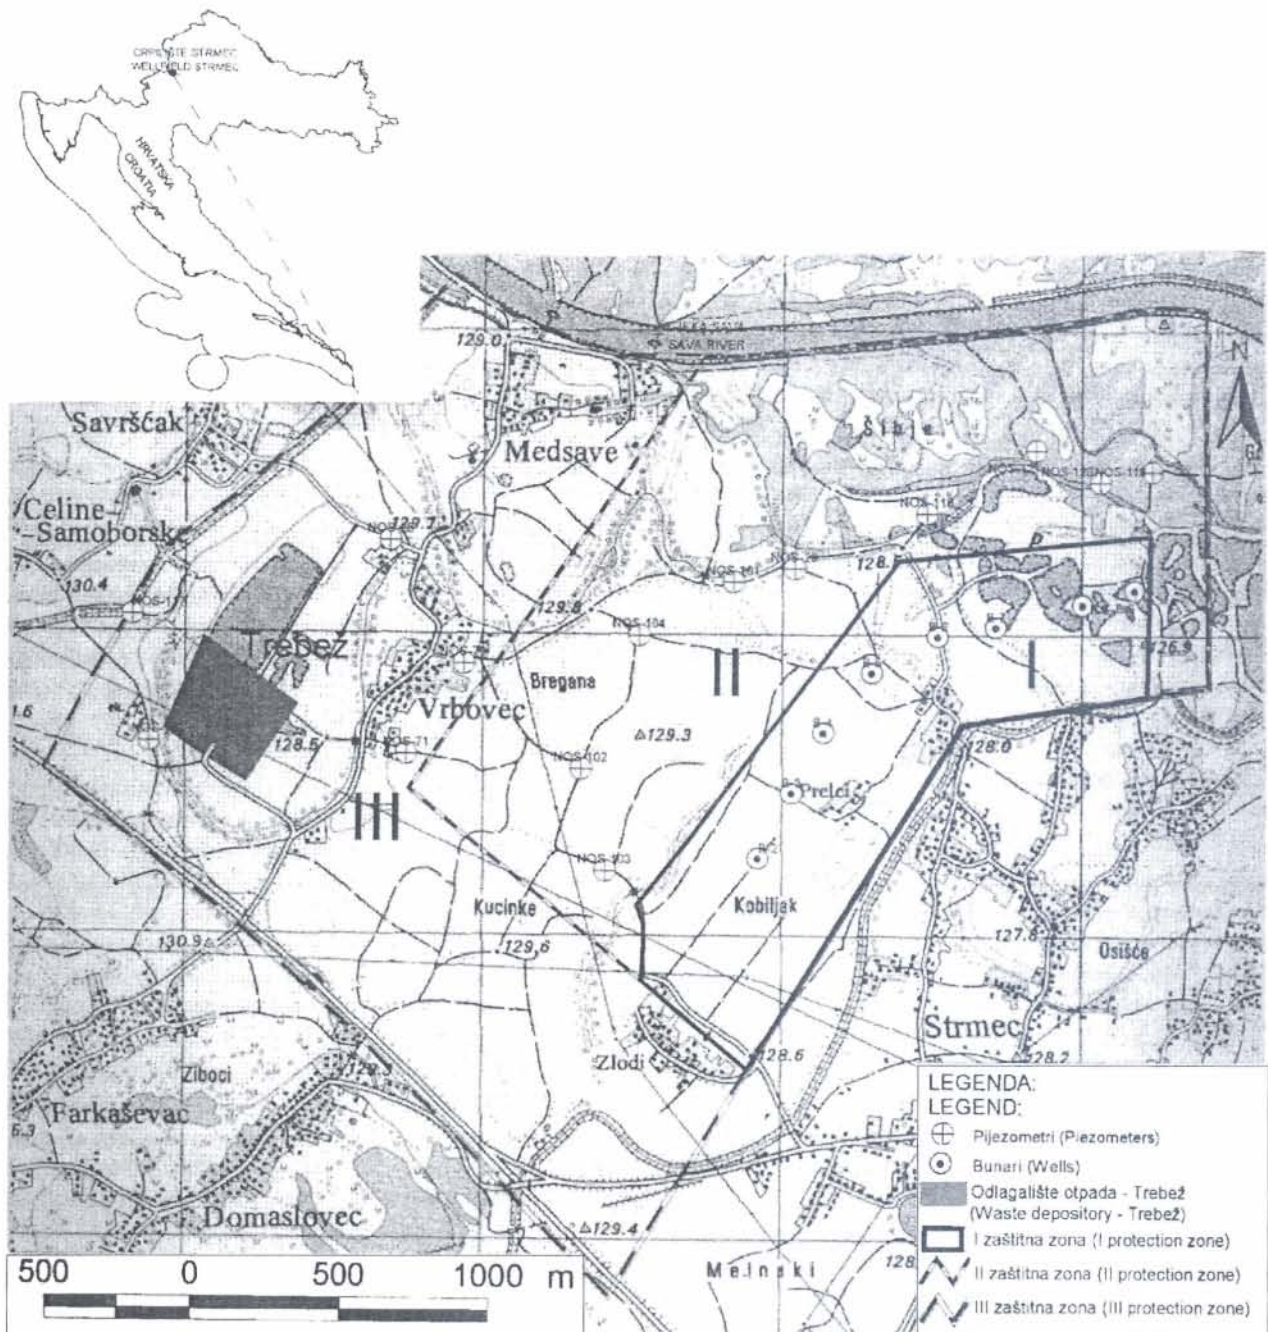
Statističke analize provedene su pomoću software-skog paketa "Statistica for windows" 5.1. (STATSOFT, 1995).

Opis lokacije i hidrogeološki odnosi

Crpilište Strmec smješteno je sjeverozapadno od sela Strmec, na desnoj obali rijeke Save, u zapadnom dijelu grada Zagreba (sl. 1). Koristi se za vodoopskrbu zapadnog dijela grada Zagreba i grada Samobora. Na crpilištu je izvedeno devet bunara, od kojih su četiri u pogonu s ukupnim kapacitetom od 500 l/s. Zone sanitarne zaštite su utvrđene na temelju Prijedloga Odluke o zaštitnim zonama, koji nikada nije ozakonjen. Ukupna površina zaštitnih zona je 7,21 km², od čega je površina prve zone 1,21 km², druge zone 2,60 km², a treće zone 3,4 km².

Zagrebački vodonosni sustav je kvartarne starosti, taložen tijekom srednjeg i gornjeg pleistocena i holocena (Ve li ć & D u r n , 1993). Vodonosni sustav na području crpilišta Strmec dio je zagrebačkog vodonosnog sustava. Debljina vodonosnih naslaga prelazi 50 m, a u poprečnom presjeku razlikuju se dva vodonosna sloja. Prvi vodonosni sloj sastoji se pretežno od srednje do fino zrnatog šljunka i pijeska, s mjestimičnim pojavama međuslojeva gline i praha. Njegova debljina je oko 30 m. Drugi vodonosni sloj sastoji se od šljunka i pijeska s lećama silta i gline. Debljine je od 15 do 20 m. Pokrovne naslage vodonosnih slojeva su debljine od 30 cm do 3 m, i pretežito se sastoje od pijeska i/ili siltozne gline.

Smjer toka podzemne vode i u vrijeme visokih i u vrijeme niskih voda je od zapada prema istoku (sl. 2). Razlike u razinama podzemne vode između perioda visokih i niskih voda na lokacijama promatranih pijezometara u presjeku su 2 m. Podzemna voda iz bunara na crpilištu crpi se iz prvog vodonosnog sloja.



Sl. 1. Lokacijska karta
Fig. 1. Location map

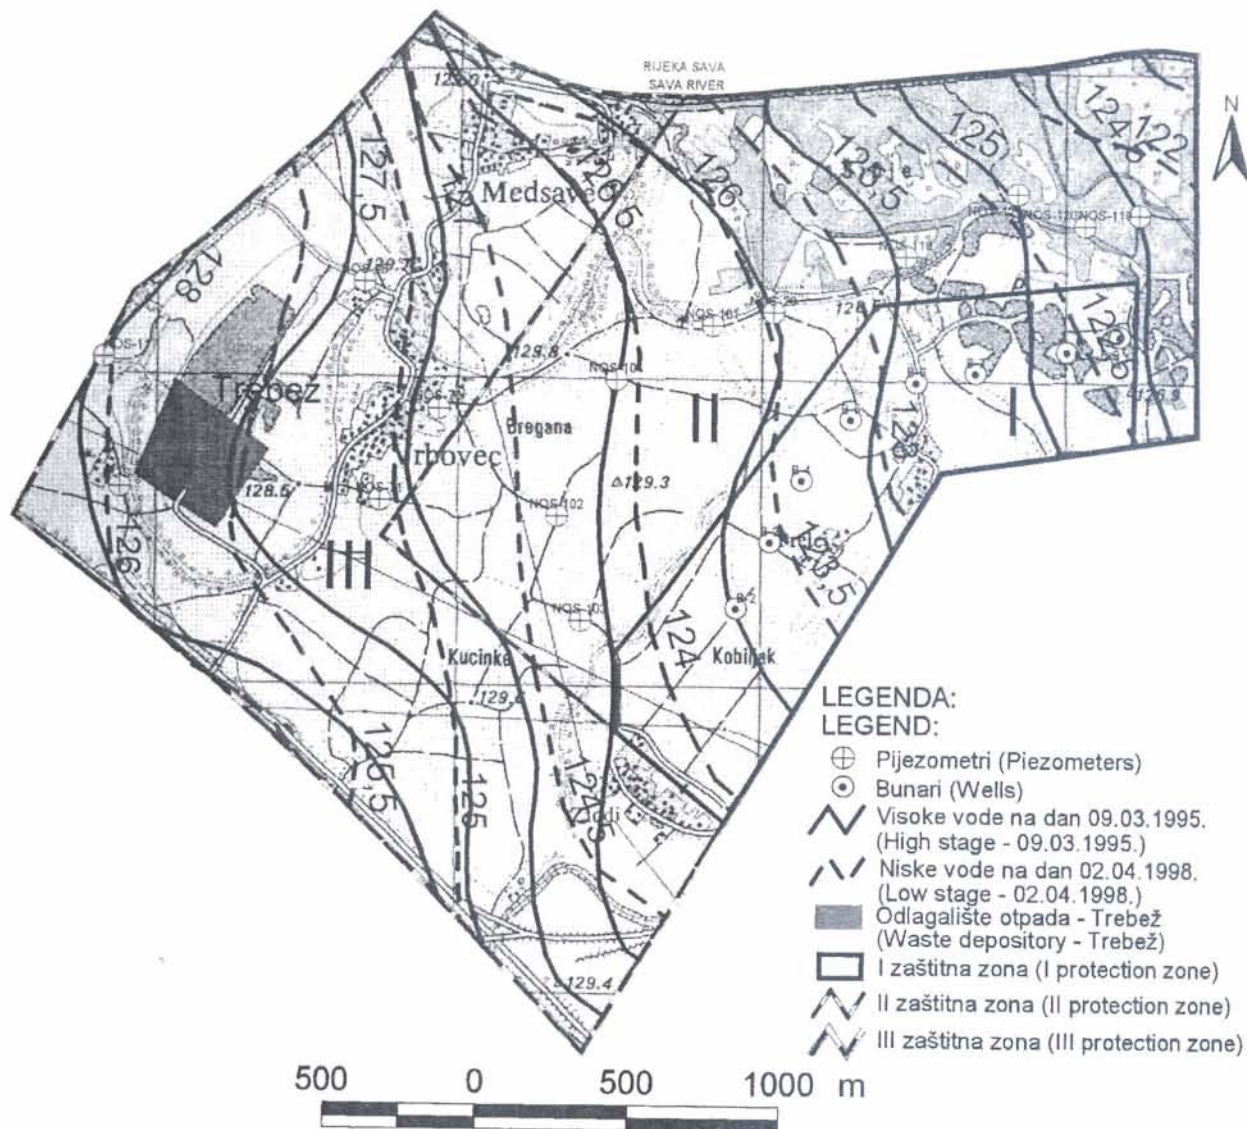
Metode

"Cluster" analiza

"Cluster" analiza je tehnika koja se koristi za grupiranje pojedinih varijabli ili uzoraka tako da se ovisno o mjenim karakteristikama maksimalizira udaljenost između pojedinih grupa. "Cluster" analiza razlikuje se od drugih metoda klasifikacije u tome što broj i karakteristike pojedinih grupa nisu poznate prije analize, već se dobivaju direktno iz podataka (Brown, 1998).

Procedura kod "Cluster" analize sastoji se u tome da se originalna matrica podataka $n \times p$ transponira u $n \times n$ matricu, čime se određuje sličnost između varijabli/uzoraka.

Koristili smo metodu "Hierarchical tree clustering" koja predstavlja grafički prikaz grupiranja pojedinih "cluster-a" pomoću dendograma. Specifično, koristi se Ward-ova metoda "Hierarchical tree clustering" koja predstavlja pristup analize varijance za procjenu udaljenosti između "cluster-a" (S t a t s o f t, 1995). "Cluster" analiza provedena je na standardiziranim podacima (srednja vrijednost = 0, varijanca = 1).



Sl. 2. Karta razina podzemnih voda u vrijeme visokog i niskog vodostaja
Fig. 2. Map of headlines (high and low stage)

“Multidimensional scaling” analiza

“Multidimensional scaling” metoda (MDS) je tehnika kojom se reducira dimenzionalnost i temelji se na udaljenosti između točaka. Rezultat je iskazan kao reducirani broj dimenzija, te se koristi za predstavljanje podataka na način da se što manje iskrive originalni podaci (Brown, 1998). MDS metoda slična je “Principal component” analizi, ali MDS metoda je prvenstveno individualno orijentirana tehnika (“Q mode”). MDS je jedina multivarijantna statistička metoda koja zahtijeva ulazne podatke u formi matrice. Kao ulazni podaci mogu se koristiti matrice sličnosti/različitosti, kao i korelacijske matrice. Logika MDS metode sastoji se u tome da se utvrdi konačan broj dimenzija uzoraka, koji će reproducirati utvrđene udaljenosti (Stattos, 1995). Broj dimenzija koji se utvrđuje ovom metodom posljedica je nužnog preklapanja reproducirane i opažane matrice. Naravno cilj je reducirati složenost utvrđenih

veličina, te objasniti matricu koja pokazuje različitosti kroz manji broj dimenzija.

Kao ulazni set podataka koristila se “distance” matrica dobivena transponiranjem $n \times p$ matrice podataka u $n \times n$ matricu. MDS analiza je korištena kao nadopuna “Cluster” analizi u objašnjavanju razlika između pojedinih uzoraka.

“Principal component” analiza

“Principal component” analiza (PCA) je tehnika koja pokušava objasniti odnose između nekoliko varijabli istovremeno u smislu pronalaženja jednostavnijih odnosa koji osiguravaju uvid u njihovu prikrivenu strukturu (Sukidrić, 1999). Ovi jednostavniji odnosi izraženi su u smislu novog seta varijabli, nazvanih “principal component-e”, koje zadržavaju maksimalnu količinu informacija i određuju koje su od njih međusobno povezane.

"Principal component-e" povezane su s izmjerenim varijablama preko "factor loading" matrice koja opisuje stupanj korelacije između dva seta varijabli. Početne vrijednosti "factor loading" koje se dobivaju iz PCA analize u većini slučajeva ne objašnjavaju strukturu varijabli na zadovoljavajući način. Kako bi se bolje uočila struktura provodi se linearna transformacija inicijalnih "factor loading-a" u novi set zajedničkih "factor-a", pomoću rotacije "factor-a". Najznačajniji parametri dobiveni iz PCA analize su "communality", "factor loading", "eigenvalue" i suma objašnjene varijance. "Communality" je dio varijance objašnjen pomoću zajedničkih faktora, "eigenvalue" je količina varijance objašnjena pojedinim faktorom odnosno "principal component-om", a suma objašnjene varijance predstavlja ukupnu količinu dobivene varijance iz rezultirajućih vrijednosti "eigenvalue".

Uobičajena procedura kod PCA je sljedeća (Brown, 1998., Suk i dr. 1999., Grande i dr. 1996):

- iz originalne matrice podataka koja se sastoji od $n \times x$ podataka i $p = y$ varijabli računa se pxp korelacijska matrica,
- analizira se korelacijska matrica, traže se dokazi za multikolinearnost i singularnost, kao i nedovoljna korelacija između varijabli,
- ispituju se vrijednosti "factor loading-a" na temelju kojih se procjenjuje mogućnost interpretacije,
- i na kraju provodi se rotiranje "factor-a" u cilju lakše interpretacije.

PCA analiza ne zahtijeva normalitet podataka i zato je primjenjiva u svim slučajevima koji zadovoljavaju analizu korelacijske matrice.

PCA je korišten kako bi se otkrile najznačajnije makro i mikro komponente, koje su ili koje mogu biti posljedice antropogenog utjecaja, a koje utječu na promjenu kvalitete podzemne vode unutar zaštitnih zona crpilišta Strmec. Rezultati PCA analize korišteni su za određivanje vremenskih trendova tih komponenata na lokacijama pijezometara.

PCA analiza provedena je na standardiziranim podacima (srednja vrijednost = 0, varijanca = 1).

Analiza vremenskih serija ("Time series analysis")

Analiza vremenskih serija provodi se na podacima koji su kontinuirano mjereni u jednakim vremenskim razmacima. Dva su osnovna cilja ove analize (S t a t s o f t, 1995):

1. Određivanje prirode fenomena iz vremenskog niza promatranja i

2. Predviđanje budućih vrijednosti mjerenih varijabli.

U osnovi procedura obrade podataka u analizi vremenskih serija sastoji se u sljedećem (Brown, 1998):

- prva operacija je "desezonalizacija" podataka, gdje su oni podijeljeni pomoću odgovarajućih sezonskih indeksnih brojeva, čiji rezultati predstavljaju podatke koji su regulirani s obzirom na sezonsku komponentu,
- druga operacija je procjena cikličke komponente na način da se podaci podijele s odgovarajućom trendovskom vrijednosti,
- treća operacija je procjena nepravilne ili slučajne komponente koja se postiže prilagodbom podataka za sezonske, cikličke i trendovske varijacije,
- četvrta operacija uključuje predviđanje budućih vrijednosti, tj. ekstrapolaciju podataka u neko buduće vrijeme.

Koristili smo se *Metodom klasičnog sezonskog rastavljanja (Classical Seasonal Decomposition - Census method 1)* koja se temelji na radnjama opisanim u prvim trim gore navedenim operacijama. Vremenska analiza provedena je za svaki promatrani pijezometar posebno, a rezultati su prikazani grafički i odnose se na procjenu trendova kretanja pojedinih komponenata. *Census 1 metoda* omogućuje

prikaz trendova koji uključuju i cikličku komponentu, dok su sezonska i slučajna komponenta odstranjene iz prikaza. Dvojaki je način prikaza rezultata:

a) kao trendovi + cikličke komponente iz standardiziranih vrijednosti koncentracija (srednja vrijednost = 0, varijanca = 1), primjenom klasičnog sezonskog rastavljanja, kako bi se istodobno mogle pratiti promjene svih komponenata na pojedinim lokacijama pijezometara,

b) kao stvarne koncentracije i linearni trendovi.

Na većini pijezometara uzimanje uzoraka za ispitivanje kvalitete podzemne vode provodi se kontinuirano i uzastopno zadnjih tri ili četiri godine, što nije zadovoljavajuće za kvantitativnu ocjenu trendova pojedinih komponenata. U radu stoga dajemo samo kvalitativnu ocjenu trendova komponenata, i to samo onda kada je to moguće.

Rezultati i rasprava

Ispitivanje kvalitete podzemne vode na području crpilišta Strmec obavlja komunalno poduzeće "Vodoopskrba i odvodnja" od 1991. godine.

Razmatrani su podaci o kvaliteti vode s 14 lokacija pijezometara. Samo na nekim pijezometrima mjerenja se vrše od 1991. godine, a na većini pijezometara od 1994. godine, ali sa svega nekoliko analiza godišnje. Od 1996. godine, u pravilu se uzorci za ispitivanje kvalitete podzemne vode, na većini razmatranih pijezometara uzimaju 11 puta godišnje.

Kako bi se ispitale sličnosti i međupovezanosti hidrokemijskih podataka iz pijezometara, s obzirom na moguće antropogene utjecaje, provedeno je ispitivanje prikupljenih podataka. Zaključeno je da su za dalju obradu relevantni podaci u razdoblju od 22.09.-28.10.1998. godine za stanje visokog vodostaja podzemne vode, te podaci u razdoblju od 24.07.-06.09.2000. godine za stanje niskog vodostaja (tablica 1). U setu podataka za 2000. godinu zbog nedovoljnog broja podataka izostavljen je pijezometar NOS-103.

"Cluster" analiza i "Multidimensional scaling" analiza (MDS) su korištene u obradi podataka. Rezultati "Cluster" analize za stanje visokih voda pokazuju grupiranje pijezometara u tri najznačajnija "Cluster-a" (sl. 3). Rezultati MDS analize za isto razdoblje potvrđuju da se rezultati "Cluster" analize mogu gotovo identično reproducirati u MDS analizi, osim u slučaju pijezometara NOS-102 i NOS-29 (sl. 5). Naime, pijezometar NOS-102 iako je s obzirom na "Linkage distance" relativno blizu centru "Cluster-a" 3, ne pripada njemu. Međutim, u MDS analizi nalazi se vrlo blizu pijezometra NOS-101. U slučaju pijezometra NOS-29 situacija je obrnuta.

Rezultati "Cluster" analize za stanje niskih voda pokazuju grupiranje u tri "Cluster-a" (sl. 4). Rezultati MDS analize za isto razdoblje gotovo su identični "Cluster" analizi osim u slučaju pijezometra NOS-70, koji je u MDS analizi izdvojen iz "Cluster-a" 1 (sl. 6).

Uspoređujući rezultate "Cluster" i MDS analize, za oba stanja podzemnih voda, uočavaju se objekti koji su grupirani zajedno u oba slučaja.

Pijezometri NOS-118, NOS-119, NOS-120 i NOS-121 zajedno su grupirani i kod "Cluster" i kod MDS analize za oba stanja podzemne vode. Ovi pijezometri blizu su jedan drugome i nalaze se sjeverno od 1. zaštitne zone, osim NOS-118 koji je malo izdvojen (sl. 1). Kod stanja niskog i visokog vodostaja posebno dobro se zapaža izuzetna sličnost kemijskog sastava pijezometara NOS-119 i NOS-121, pa i NOS-120 kod niskog vodostaja. Moguće je da blizina površinskih voda utječe na njihov kemijski sastav, što tek treba verificirati usporedbom sa sastavom površinskih voda. Pijezometar NOS-104 nalazi se u istom "Cluster-u", u peri-


Tablica 1. Podaci kemijskih analiza za a) 22.09.-28.10.1998. (visoke vode) i b) 24.07.-06.09.2000. (niske vode)
 Table 1. Chemical data of a) 22.09.-28.10.1998 (high stage) and b) 24.07.-06.09.2000 (low stage)

a)	NO ₃ ⁻ (mg/l)	Cl ⁻ (mg/l)	So ₄ ²⁻ (mg/l)	UK ULJA (TOTAL OIL) (µg/l)	MIN ULJA (MINER. OIL) (µg/l)	Pb (µg/l)	Fe (µg/l)	Mn (µg/l)
NOS-101	0	2,3	14,5	41,4	9,3	1	756	118
NOS-102	0	1,8	8,2	26,1	7,9	0	108	201
NOS-103	8,1	7,2	26,5	28,2	8,5	4	0	0
NOS-104	2,1	9,4	45,3	36,8	7,3	2	0	0
NOS-105	5	12,2	36,3	36,2	7,7	0	6	15
NOS-117	1,9	10,2	39,9	32,1	8,1	0	5	0
NOS-118	0	5,4	30,4	39,7	4,9	14	8	62
NOS-119	1,2	3,3	31,3	44,7	7,5	22	0	8
NOS-120	0,7	4,6	36,6	44,6	5	25	0	8
NOS-121	0,8	4,9	33,5	50,3	7,8	19	0	8
NOS-28	2,1	12,3	51,1	33,7	7,4	4	7	0
NOS-29	0	0,7	31,3	45	5,6	10	534	117
NOS-70	0,4	9,3	34,7	40,2	7,5	0	0	0
NOS-71	1,7	14	35,3	48,6	7,4	0	4	0
b)								
NOS-101	0,1	2,7	16,7	9,7	0,7	5	764,8	134
NOS-102	0,3	2	9,5	10,5	2,7	1	147,9	237,6
NOS-104	0,8	10,9	40,9	9,7	1,3	0	10,1	0,3
NOS-105	3	9,4	31,3	17,5	5,7	1	0	95,4
NOS-117	2,2	8,2	35,6	12,3	5	3	0	0,4
NOS-118	0,2	9,9	25	7,7	1,6	0	90,9	1
NOS-28	1,3	10,7	39,1	16,2	4,9	0	0,2	0,1
NOS-29	0,1	1,3	6,8	9,6	0,5	8	758	120,1
NOS-70	0,7	15,1	36,1	22,5	1,8	0	0	0,6
NOS-71	2,2	15,1	32	17,9	3,7	0	0	0,8
NOS-119	0,1	9,7	26,4	15,1	2,5	0	24,5	0
NOS-120	0,3	8,1	23,8	13,2	1,3	0	0,3	1,5
NOS-121	0,6	7	26,9	10,5	1,6	0	0	0,7

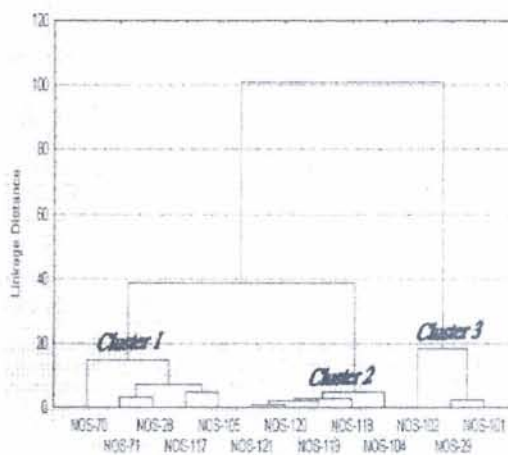
odu niskog vodostaja (2000. god), kod "Cluster" i MDS analize. Međutim, u vrijeme visokog vodostaja rezultati obje analize pokazuju da se nalazi grupiran s pijezometri- ma iz treće zaštitne zone. Pijezometar NOS-104 nalazi se u drugoj zaštitnoj zoni, nizvodno od odlagališta otpada Trebež i geografski je odvojen od spomenutih pijezome- tara.

Pijezometri NOS-70, NOS-71, NOS-28, NOS-105 i NOS-117 zajedno su grupirani i kod "Cluster" i kod MDS analize za oba stanja podzemnih voda (osim NOS-70 kod


MDS analize u vrijeme niskog vodostaja). Ovi pijezometri se nalaze uzvodno (NOS-105, NOS-117) i nizvodno (NOS-70, NOS-71, NOS-28) u neposrednoj blizini odlagališta Trebež, u trećoj zaštitnoj zoni (sl. 1). Vrlo mala "Linkage distance" između njih, kao i tijesno grupiranje kod MDS analize, ukazuju na sličnost kemijskog sastava vode ovih pijezometara, s obzirom na razmatrane kemijske kompo- nente. Blizina odlagališta Trebež sasvim sigurno utječe na pijezometre koji su nizvodno prema aktualnim kartama razina srednjeg visokog i niskog vodostaja, ali ostavlja mo-



Sl. 3. Rezultati "Cluster" metode prikazani pomoću dendograma za pe- riod 22.09.-28.10.1998. (visoke vode)
 Fig. 3. Results of clustering shown by dendrogram for the ground water sampled by 22.09.-28.10.1998 (high stage)

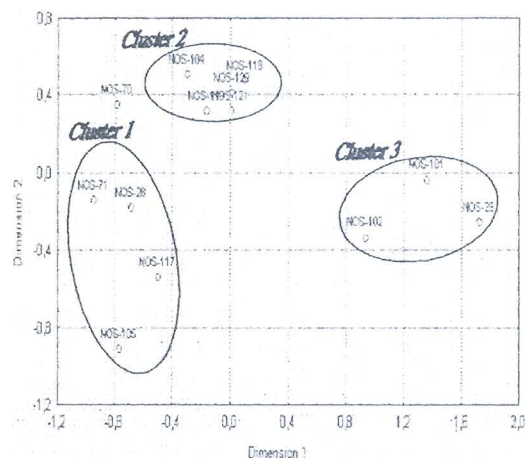


Sl. 4. Rezultati "Cluster" metode prikazani pomoću dendograma za pe- riod 24.07.-06.09.2000. (niske vode)
 Fig. 4. Results of clustering shown by dendrogram for the ground water sampled by 24.07.-06.09.2000 (low stage)



Sl. 5. Rezultati MDS metode za dvije najznačajnije dimenzije (22.09.-28.10.1998. - visoke vode)

Fig. 5. Results of MDS method shown by the two of the most significant dimensions (22.09.-28.10.1998 - high stage)



Sl. 6. Rezultati MDS metode za dvije najznačajnije dimenzije (24.07.-06.09.2000. - niske vode)

Fig. 6. Results of MDS method shown by the two of the most significant dimensions (24.07.-06.09.2000 - low stage)

gućnost utjecaja i zapadno od smetlišta. Drugo objašnjenje za kemijski sastav vode u pijezometrima NOS-105 i NOS-117 je postojanje neregistriranih divljih smetlišta ili potencijalnih zagađivača zapadnije od odlagališta Trebež. Kao što je već napomenuto, u vrijeme visokih voda rezultati i "Cluster" i MDS analize pokazuju da je s njima grupiran pijezometar NOS-104.

Pijezometri NOS-101 i NOS-29 zajedno su grupirani u "Cluster" analizi za stanje visokih voda, dok je pijezometar NOS-29 izdvojen u MDS analizi za isto razdoblje. Pijezometar NOS-102 izdvojen je od njih u "Cluster" analizi (iako još uvijek blizu "cluster" centru), ali je u MDS analizi vrlo blizu NOS-101. U vrijeme niskih voda sva tri pijezometra su grupirana zajedno kod obje metode. Geografski gledano, pijezometri NOS-101 i NOS-29 blizu su jedan drugome, dok je pijezometar NOS-102 izdvojen (sl. 1).

Od posebnog značaja su rezultati analiza za pijezometre NOS-102, NOS-103 i NOS-104. Oni se nalaze na približno jednakoj udaljenosti od odlagališta Trebež, i omogućavaju procjenu utjecaja odlagališta na podzemnu vodu u 2. zaštitnoj zoni.

Pijezometar NOS-102, koji je i najbliži odlagalištu Trebež, ne pripada niti u jedan "Cluster" u vrijeme visokog vodostaja, dok je u vrijeme niskog vodostaja u istom "Cluster-u" s pijezometrima NOS-101 i NOS-29. Rezultati MDS analize, u vrijeme visokog i niskog vodostaja, pokazuju slične rezultate. Pijezometar NOS-103 uključen je u analizu samo u vrijeme visokog vodostaja zbog nedovoljnog broja podataka u vrijeme niskog vodostaja. "Cluster" analiza u vrijeme visokog vodostaja pokazuje da jedino taj pijezometar ne pripada u neki od "Cluster-a", što potvrđuju rezultati i MDS analize. Pijezometar NOS-104 je u vrijeme visokog vodostaja izrazito povezan s pijezometrom NOS-28 i pijezometrom NOS-117, dok u vrijeme niskog vodostaja pripada u "Cluster" s pijezometrima NOS-118, NOS-119, NOS-120 i NOS-121.

Ovi rezultati upućuju na pretpostavku da na udaljenosti od približno 400 do 500 m od I. zaštitne zone odlagalište otpada Trebež ne utječe znatnije na kvalitetu podzemne vode. Pijezometar NOS-104, koji je ujedno i najudaljeniji od odlagališta, jedini u vrijeme visokih voda pokazuje sličnost s pijezometrima koji se nalaze neposredno nizvodno od odlagališta. Ta činjenica može ukazivati da u vri-

jeme visokih voda dolazi do promjene smjera toka podzemne vode, tj. da voda teče od jugozapada prema sjeveroistoku.

"Principal component" analiza (PCA) je korištena kako bi se otkrile najznačajnije makro i mikro komponente, koje su ili koje mogu biti posljedice antropogenog utjecaja, a koje utječu na promjenu kvalitete podzemne vode na području unutar zaštitnih zona crpilišta Strmec. PCA je provedena na 8 varijabli i rezultati korelacijske matrice za razdoblje visokog i niskog vodostaja (tablica 2) pokazuju da postoji dovoljno dobra korelacija, te da ne postoji singularnost i multikolinearnost između varijabli. U tablici 3 prikazani su rezultati PCA koji otkrivaju dvije najvažnije "Principal component-e", koje objašnjavaju oko 70% varijance za podatke u 1998. godini, te blizu 80% varijance za podatke iz 2000. godine. U tablici 4 prikazane su vrijednosti "Communality" iz dvije najznačajnije "Principal component-e", te "Factor loading" nakon Varimax rotacije. Vidljivo je da su vrijednosti "Factor loading-a" prve "Principal component-e" za nitrate, sulfate, željezo i mangan najznačajnije za objašnjenje kvalitete vode u vrijeme visokog i niskog vodostaja. Upravo ti parametri kvalitete vode korišteni su u daljoj analizi podataka vremenskih serija.

Analiza vremenskih serija ("Time series analysis") provedena je primjenom klasičnog sezonskog rastavljanja podataka ("Classical seasonal decomposition - Census I") za svaki promatrani pijezometar posebno, a rezultati su prikazani grafički i odnose se na procjenu trendova kretanja pojedinih komponenata. Trendovi su procijenjeni za 9 od 14 pijezometara: NOS-101, NOS-102, NOS-103, NOS-104, NOS-118, NOS-119, NOS-120, NOS-121 i NOS-29.

Rezultati su prikazani dvojako:

1. kao trendovi + cikličke komponente iz standardiziranih vrijednosti koncentracija (srednja vrijednost = 0, varijanca = 1), primjenom Metode klasičnog sezonskog rastavljanja, kako bi se istodobno mogle pratiti promjene svih komponenata na pojedinim lokacijama pijezometara,

2. kao stvarne koncentracije i linearni trendovi.

Izrazito pozitivan trend sulfata prisutan je jedino na lokaciji pijezometra NOS-101 (s. 7) od 1997. godine. Slabo negativan trend sulfata prisutan je na lokacijama pijezometara NOS-119 (sl. 12), NOS-120 (sl. 13) i NOS-121 (sl.

14) od 1997. godine i NOS-104 od 1998. godine.

Slabo pozitivan trend klorida prisutan je na lokacijama pijezometara NOS-101 (sl. 7) i NOS-118 (sl. 11) od 1997. godine. Slabo negativan trend klorida prisutan je na lokaciji pijezometra NOS-29 (sl. 15).

Slabo negativan trend željeza prisutan je eventualno na lokaciji pijezometra NOS-118 (sl. 11) od 1997. godine. Slabo pozitivan trend mangana prisutan je na lokaciji pijezometra NOS-101 (sl. 7) od 1997. godine i na lokaciji pijezometra NOS-102 (sl. 8) od 1994. godine. Slabo negativan trend mangana prisutan je na lokaciji pijezometra NOS-118 (sl. 11) od 1997. godine.

Sumarno, iz rezultata vremenske analize podataka mogu se izvući slijedeći zaključci:

Grupa 1:

- na lokaciji pijezometra NOS-118 (sl. 11) prisutan je slabo pozitivan trend klorida, te slabo negativan trend željeza i mangana. Ipak, relativno visoke koncentracije željeza i mangana, kao i nagle promjene koncentracija u vremenu upućuju na izrazitu zavisnost koncentracija ovih komponenta s obzirom na promjenu hidrodinamičkih uvjeta u podzemlju. Blizina površinskih voda dodatno ukazuje na tu činjenicu, iako postojeće *Karte razina podzemnih voda* tu vezu nisu dokazale;

- kemijska svojstva vode na lokacijama pijezometara NOS-119 (sl. 12), NOS-120 (sl. 13) i NOS-121 (sl. 14) izrazito su slična. Prisutan je slabo negativan trend sulfata, te niske koncentracije željeza i mangana, s povremenim naglim promjenama koncentracija. Očigledno radi se o istim uzrocima promjene kvalitete vode na lokacijama svih triju pijezometara, što može biti posljedica sličnih hidrodinamičkih uvjeta u podzemlju i blizine površinskih voda. Prema kartama razina podzemnih voda, trebala bi postojati veza samo između pijezometara NOS-120 i NOS-119, međutim, rezultati svih multivarijantnih statističkih metoda ukazuju da nije tako, što dodatno upućuje na lokalnu povezanost kemijskog sastava površinskih voda s kemijskim sastavom podzemnih voda na tom području.

Grupa 2:

- na lokaciji pijezometra NOS-101 (sl. 7) prisutan je pozitivan trend rasta sulfata, klorida i mangana, što može značiti da je najvjerojatnije zahvaćen lokalnim utjecajem poljoprivredne aktivnosti;
- na lokaciji pijezometra NOS-102 (sl. 8) osim slabo pozitivnog trenda mangana ne postoji dokaz za neki vanjski, kontinuirani uzrok promjene kvalitete vode;
- na lokaciji pijezometra NOS-29 (sl. 15) prisutan je samo slabo negativni trend koncentracije klorida i relativno mala

Tablica 2. Korelacijska matrica za 8 varijabli izračunata iz podataka kemijskih analiza za a) 22.09.-28.10.1998. (visoke vode) i b) 24.07.-06.09.2000. (niske vode).

Table 2. Correlation matrix of 8 variables computed from chemical data of a) 22.09.-28.10.1998 (high stage) and b) 24.07.-06.09.2000 (low stage)

a)									
	Varijable (Variables)	1	2	3	4	5	6	7	8
1	NO ₃	1,00							
2	Cl	,44	1,00						
3	SO ₄	,18	,67	1,00					
4	UK. ULJA (TOTAL OIL)	-,44	-,11	,19	1,00				
5	MIN. ULJA (MINER. OIL)	,35	,17	-,28	-,33	1,00			
6	Pb	-,26	-,48	,09	,54	-,57	1,00		
7	Fe	-,34	-,56	-,50	,15	,18	-,15	1,00	
8	Mn	-,44	-,68	-,80	-,25	,01	-,16	,62	1,00

b)									
	Varijable (Variables)	1	2	3	4	5	6	7	8
1	NO ₃	1,00							
2	Cl	,44	1,00						
3	SO ₄	,54	,83	1,00					
4	UK. ULJA (TOTAL OIL)	,48	,69	,49	1,00				
5	MIN. ULJA (MINER. OIL)	,86	,35	,49	,47	1,00			
6	Pb	-,18	-,70	-,62	-,38	-,29	1,00		
7	Fe	-,44	-,72	-,71	-,44	-,53	,90	1,00	
8	Mn	-,17	-,76	-,76	-,29	-,10	,50	,57	1,00

Tablica 3. Vrijednosti "Eigenvalue" iz PCA analize, postotak ukupne varijance, kumulativne vrijednosti "eigenvalue" i kumulativni postoci objašnjeni pomoću faktora: a) 22.09.-28.10.1998. - visoke vode, b) 24.07.-06.09.2000 - niske vode

Table 3. Eigenvalues extracted through PCA analysis, percent of total variance, cumulative eigenvalues and cumulative percent explained by factors a) 22.09.-28.10.1998. - high stage, b) 24.07.-06.09.2000 - low stage

Faktori (Factors)	Eigenval	% ukupne varijance (% total variance)	Kumul. (Cumul.) Eigenval	Kumul. (Cumul.) %
a)				
1	3,160785	39,50981	3,160785	39,50981
2	2,388781	29,85976	5,549566	69,36957
b)				
1	4,761265	59,51581	4,761265	59,51581
2	1,495020	18,68775	6,256285	78,20356

Tablica 4. "Communalities" iz dva dobivena faktora/principal component-e (a), "Factor loadings" (b) nakon rotacije faktora kroz Varimax metodu (22.09.-28.10.1998. - visoke vode, 24.07.-06.09.2000 - niske vode)


Table 4. Communalities from two extracted factors/principal components (a), Factor loadings (b) after factor rotation through Varimax method (22.09.-28.10.1998. - high stage, 24.07.-06.09.2000 - low stage)

a)				
22.09.-28.10.1998	NO ₃	Cl	SO ₄	UK. ULJA (TOTAL OIL)
	0,570877	0,819249	0,787401	0,586935
	MIN. ULJA (MINER. OIL)	Pb	Fe	Mn
	0,590994	0,728718	0,592909	0,872483
24.07.-06.09.2000	NO ₃	Cl	SO ₄	UK. ULJA (TOTAL OIL)
	0895554	0,877404	0,821652	0,518683
	MIN. ULJA (MINER. OIL)	Pb	Fe	Mn
	0,896448	0,719312	0,788267	0,738965
b)				
	Faktor 1 (Factor 1)		Faktor 2 (Factor 2)	
	22.09.-28.10.1998	24.07.-06.09.2000	22.09.-28.10.1998	24.07.-06.09.2000
NO ₃	,489515	,140659	,575545	,935825
Cl	,829887	,878973	,361299	,323744
SO ₄	,860034	,807955	-,218501	,410926
UK. ULJA	,054325	,434441	-,764188	,574407
MIN. ULJA	-,095561	,135118	,762799	,937119
Pb	,010831	,838093	-,853581	-,130050
Fe	-,769590	-,805170	,025298	-,374123
Mn	-,927213	,859286	,112955	,024354
Označene vrijednosti loading-a su > .700000 (Marked loading are > .700000)				


koncentracija sulfata, što može značiti smanjenje lokalne poljoprivredne aktivnosti.

- kemijski sastav podzemne vode na lokaciji pijezometra NOS-103 (sl. 9) obilježen je relativno niskim koncentrac-

ijama željeza i mangana. Za sve četiri razmatrane komponente karakteristična je nagla promjena koncentracija u vremenu, bez trenda rasta, što upućuje na ovisnost kemijskog sastava o hidrodinamičkim i lokalnim hidroge-




Sl. 7. Pijezometar NOS-101, trendovi kemijskih komponenata u vodi
Fig. 7. Piezometer NOS-101, trends of chemical components in water




Sl. 8. Pijezometar NOS-102, trendovi kemijskih komponenata u vodi
 Fig. 8. Piezometer NOS-102, trends of chemical components in water

okemijskim uvjetima. Prema rezultatima provedenih analiza nema dokaza da je podzemna voda na lokaciji NOS-103 posljedica antropogenog zagađenja. - na lokaciji pijezometra NOS-104 (sl. 10) prisutan je slabo negativan trend sulfata, te izrazita cikličnost u promjena-

ma koncentracija sulfata i klorida. Koncentracije željeza i mangana su do 2000. godine izrazito niske, gotovo na nuli, osim u slučajevima iznenadnih naglih promjena i rasta, koji je vrlo kratkog trajanja. Od početka 2000. godine zapaža se postupno povećanje i rast željeza i manga-



Sl. 9. Pijezometar NOS-103, trendovi kemijskih komponenata u vodi
 Fig. 9. Piezometer NOS-103, trends of chemical components in water

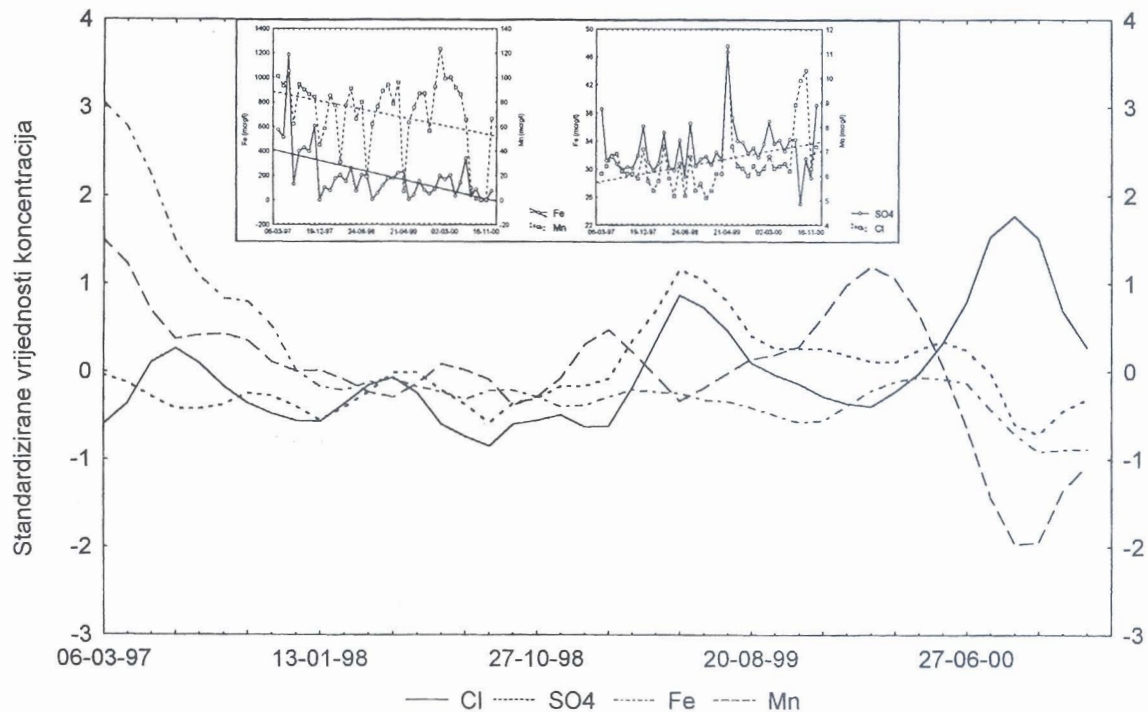


Sl. 10. Pijezometar NOS-104, trendovi kemijskih komponenata u vodi
Fig. 10. Piezometer NOS-104, trends of chemical components in water


na, što tek treba verificirati u budućnosti. Rezultati "Cluster" i MDS analize ukazuju na moguću vezu podzemne vode na lokaciji NOS-104 s odlagalištem otpada Trebež, međutim analiza vremenskih podataka za razmatrane komponente za sada to ne potvrđuje.

Zaključci

Crpilište Strmec je od izuzetnog značaja za vodoopskrbu zapadnog dijela grada Zagreba, kao i grada Samobora. Crpilište se nalazi nizvodno od smetlišta Trebež, a prisutni su i brojni drugi potencijalni zagađivači, divlje šljunčare




Sl. 11. Pijezometar NOS-118, trendovi kemijskih komponenata u vodi
Fig. 11. Piezometer NOS-118, trends of chemical components in water



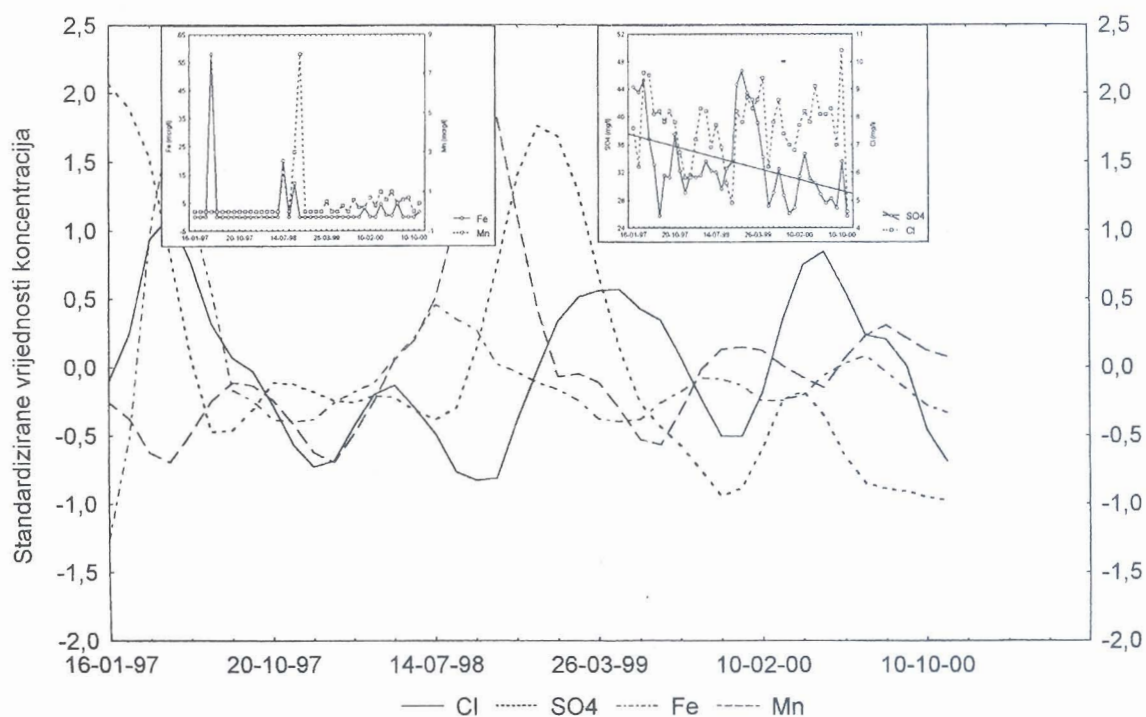
Sl. 12. Pijezometar NOS-119, trendovi kemijskih komponenata u vodi
 Fig. 12. Piezometer NOS-119, trends of chemical components in water

zatrpane smećem, kao i manja divlja smetlišta. Dosadašnje aktivnosti na zaštiti crpilišta pretežno su bile vezane za područje neposredno uz crpilište, u granicama 1. zaštitne zone, pogotovo što zaštitne zone nisu ozakonjene pravnim aktom.


Kako bi potaknuli istraživanja kvalitete vode na tom području i utvrdili temelje za buduće aktivnosti na zaštiti podzemnih voda crpilišta Strmec, Bačani i dr. (2001) provode istraživanja kvalitete vode na odabranim lokacijama promatranih pijezometara. Zaključuju kako je prisu-



Sl. 13. Pijezometar NOS-120, trendovi kemijskih komponenata u vodi
 Fig. 13. Piezometer NOS-120, trends of chemical components in water



Sl. 14. Pijezometar NOS-121, trendovi kemijskih komponenata u vodi
 Fig. 14. Piezometer NOS-121, trends of chemical components in water



Sl. 15. Pijezometar NOS-29, trendovi kemijskih komponenata u vodi
 Fig. 15. Piezometer NOS-29, trends of chemical components in water

tan utjecaj odlagališta Trebež na podzemne vode nizvodno od smetlišta, te da postoje značajne varijacije kvalitete vode, kako prostorno, tako i vremenski.

U ovom članku prikazane su dalje aktivnosti istraživanja kvalitete podzemne vode unutar zaštitnih zona crpilišta Strmec. Ispitane su sličnosti i međupovezanosti hidro-kemijskih podataka iz pijezometara, s obzirom na moguće an-

tropogene utjecaje. Također je provedena i analiza vremenskih serija podataka s pojedinih pijezometara. U analizi podataka korištene su četiri multivarijantne statističke metode: "Cluster" analiza, "Multidimensional scaling" analiza (MDS), "Principal component" analiza (PCA), te Analiza vremenskih serija ("Time series analysis").

"Cluster" analiza i MDS provedene su na podacima kemijskih analiza iz četrnaest pijezometara u vrijeme visokog vodostaja u podzemlju (od 22.09. do 28.10.1998. godine), te u vrijeme niskog vodostaja (od 24.07. do 06.09.2000. godine). Za statističku analizu odabrano je osam komponenata koje mogu ukazivati na antropogeno zagađenje.

Rezultati analiza za oba stanja podzemnih voda pokazali su grupiranje pijezometara u tri "Cluster-a" ili grupe.

Prva grupa obuhvaća pijezometre: NOS-118, NOS-119, NOS-120 i NOS-121, koji se nalaze sjeverno od 1. zaštitne zone. Zaključeno je da postoji mogućnost utjecaja lokalnih površinskih voda na kemijski sastav podzemne vode na tom području. U periodu niskog vodostaja u ovu grupu se priključuje pijezometar NOS-104.

Druga grupa obuhvaća pijezometre NOS-101, NOS-29 i NOS-102. Pijezometri NOS-101 i NOS-29 nalaze se blizu jedan drugome, dok je pijezometar NOS-102 udaljen od njih.

Treća grupa obuhvaća pijezometre u 3. zaštitnoj zoni, neposredno uz odlagalište otpada Trebež: uzvodno od odlagališta nalaze se NOS-117 i NOS-105, a nizvodno NOS-70, NOS-71 i NOS-28. U vrijeme visokog vodostaja u istu grupu se priključuje i pijezometar NOS-104, koji se nalazi nizvodno od odlagališta u 2. zaštitnoj zoni. Zaključeno je da odlagalište Trebež sigurno utječe na pijezometre koji su nizvodno prema aktualnim *kartama razina srednjeg visokog i niskog vodostaja*, međutim postoji mogućnost utjecaja i zapadno od odlagališta. Drugo objašnjenje za kemijski sastav voda u pijezometrima NOS-105 i NOS-117 je postojanje neregistriranih divljih smetlišta ili potencijalnih zagađivača zapadnije od odlagališta Trebež.

Rezultati analiza za pijezometre NOS-102, NOS-103 i NOS-104, koji se nalaze na približno jednakoj udaljenosti od odlagališta otpada Trebež, omogućavaju procjenu utjecaja odlagališta na podzemnu vodu u 2. zaštitnoj zoni. Zaključeno je da, na udaljenosti od približno 400 do 500 m od 1. zaštitne zone, odlagalište Trebež za sada ne utječe znatnije na kvalitetu podzemne vode. Takav zaključak je izveden na temelju dosadašnjih podataka iz kemijskih analiza. To ne znači da se u budućnosti stanje ne može promijeniti, pogotovo u uvjetima izmjenjene hidrodinamičke slike zbog izgradnje HE Podsused. Pijezometar NOS-104, koji se nalazi na najvećoj udaljenosti od odlagališta, jedini u vrijeme visokog vodostaja pokazuje sličnost s pijezometrima koji se nalaze neposredno nizvodno od odlagališta. Ta činjenica može ukazivati da u vrijeme visokog vodostaja dolazi do promjene smjera toka podzemne vode prema sjeveroistoku.

PCA je korišten kako bi se otkrile najznačajnije makro i mikro komponente, koje su ili koje mogu biti posljedice antropogenog utjecaja, a koje utječu na promjenu kvalitete podzemne vode na području unutar zaštitnih zona crpilišta Strmec. Rezultati PCA su pokazali da su: sulfati, kloridi, željezo i mangan najznačajnije komponente za dalju analizu podataka vremenskih serija.

"Time series" analiza provedena je za svaki promatrani pijezometar posebno, a rezultati su prikazani grafički i

odnose se na procjenu trendova pojedinih komponenata. Trendovi su procijenjeni za 9 od 14 pijezometara: NOS-101, NOS-102, NOS-103, NOS-104, NOS-118, NOS-119, NOS-120, NOS-121 i NOS-29. Na temelju otkrivenih trendova pijezometara i varijacija koncentracija komponenata na lokacijama pojedinih pijezometara izvedeni su zaključci za već ranije određene grupe pijezometara.

Za pijezometre iz prve grupe zaključeno je da su najvjerojatnije pod utjecajem blizine lokalnih površinskih voda, iako aktualne *Karte razina podzemnih voda* ne potvrđuju tu pretpostavku.

Pijezometri iz druge grupe su zahvaćeni lokalnim hidrodinamičkim i hidrogeokemijskim utjecajima. Jedino je na lokaciji pijezometra NOS-101 izražen pozitivan trend sulfata i klorida, što je očiti znak lokalnog utjecaja poljoprivredne aktivnosti. Na lokacijama pijezometara NOS-29 i NOS-102 nije potvrđen antropogeni utjecaj.

Također i na lokaciji pijezometra NOS-103, koji ne pripada niti u jednu grupu, nije potvrđen antropogeni utjecaj.

Na lokaciji pijezometra NOS-104, koji u vrijeme visokog vodostaja pripada u treću grupu, a u vrijeme niskog vodostaja u prvu grupu, tek je u 2000. godini zabilježen porast koncentracije željeza i mangana, te za sada nema dokaza da je zahvaćen utjecajem odlagališta otpada Trebež.

Na području crpilišta Strmec relativno je malo učinjeno na zaštiti podzemne vode. Ne postoji katastar zagađivača, nisu ozakonjene zaštitne zone i nije uvažavana činjenica da je crpilište tek mjesto zahvata podzemne vode za vodoopskrbu, te da je potrebno kontrolirati cijelo slivno područje. Stoga, možemo zaključiti da je nužno proširiti postojeću mrežu promatranja kvalitete podzemne vode na području cijelog sliva, te je potrebno pratiti kvalitetu vode kroz dulje vrijeme. Nadalje, potrebno je redovito ažurirati sve potencijalne i stalne zagađivače na području sliva. Tek tada mogu se ostvariti pretpostavke za pravodobno reagiranje u slučajevima utvrđenog pogoršanja kvalitete podzemne vode na cijelom priljevnom području.

Primljeno: 2001-05-09

Prihvaćeno: 2001-10-23

LITERATURA

- Bačani, A., Vlahović, T. and Nakić, Z. (2001): Endangered water quality of the Strmec well field. 3rd International Conference on Future Groundwater Resources at Risk. June 25-27, 2001, Lisbon, Portugal. In press.
- Brown, C.E. (1998): Applied Multivariate statistics in geohydrology and related sciences, Springer-Verlag, 248 p.
- Grande, J.A., Gonzalez, A., Beltran, R. and Sanchez-Rodas, D. (1996): Application of factor analysis to the study of contamination in the aquifer system of Ayamonte-Huelva (Spain). - *Ground water*, 34/1, 155-161.
- STATSOFT, Inc. (1995): Statistica for Windows (Volume 3), Statistics 2., 2nd edition. Statsoft, Inc., Tulsa, 3001-3781.
- Suk, H. & Kang-Kun, L. (1999): Characterization of a groundwater hydrochemical system through multivariate analysis: clustering into groundwater zones. *Ground water*, 37/3, 358-366.
- Velić, J. & Durn, G. (1993): Alternating Lacustrine-Marsh Sedimentation and Subaerial Exposure Phases During Quaternary: Prečko, Zagreb, Croatia, *Geol. Croat.*, 46/1, 71-91, Zagreb.

Assessment of Anthropogenic Effects on the Strmec Well Field Groundwater (Zagreb, Hrvatska)

Zoran Nakić, Andrea Bačani and Tatjana Vlahović

The project *Croatian Groundwater Recording and Management* results include evidence on numerous occurrences of permanent and occasional pollution at the locations where monitored observation wells are set up. Groundwater quality in the entire Zagreb aquifer system area has obviously degraded. One of the major Zagreb well fields, the **Strmec Well Field**, is particularly endangered for being located downstream large **Trebež Landfill**. Other potential pollution sources inside the Strmec Well Field protection areas include illegal gravel pits and dump sites, agricultural land, the City of Samobor open sewage system, and the Rakovica Brook that receives waste water from households and industry.

The results of earlier research conducted by Bačani *et al.* in 2001 confirm major spatial and time-related fluctuations in water quality. The impact of the Trebež Landfill on degradation of the groundwater quality at the observation wells downstream from the landfill is proven, however the landfill influence area is not determined. Also, change in water quality is detected on most observation wells inside the well field area, as well as change in trends of some macro and micro components.

The present article describes the results of further investigation into anthropogenic effects within the Strmec Well Field protective areas. The principal objective of the research is to investigate into similarities and interrelations among the hydrochemical data obtained from the observation wells related to possible anthropogenic effects. For that reason, additional data on the Strmec Well Field groundwater quality were acquired from Vodoopskrba i Odvodnja (*Water Supply and Sewage*) utility. It is concluded that 1998 and 2000 data are relevant for further analysis of high and low groundwater tables, respectively. Multivariate statistical methods *Cluster* and *Multidimensional scaling (MDS)* were used for the data analyses. *Principal component (PCA)* analysis is used to determine occurrence of the major macro and micro components that are and may be caused by anthropogenic effects, and which cause changes in groundwater quality. The paper also analyses time series of data from specific observation wells. The *Cluster* and *Multidimensional scaling* analysis results for both high and low groundwater tables indicate grouping of observation wells in three clusters (Figs. 3, 4, 5 and 6).

The *first cluster* includes observation wells NOS-118, NOS-119, NOS-120, and NOS-121 is located to the north of the first protection area. It is concluded that impact of local surface water on the groundwater chemistry in the area is possible. During the low groundwater table, this cluster is joined by the observation well NOS-104 (Fig. 2).

The *second cluster* includes the observation wells NOS-101, NOS-29, and NOS-102. The observation wells NOS-101 and NOS-29 are close to each other, while the observation well NOS-102 is placed on some distance (Fig. 2).

The *third cluster* includes the observation wells in the third protection area, immediately by the Trebež Landfill - NOS-117 and NOS-105 upstream, and NOS-70, NOS-71 and NOS-28 downstream from the landfill. During high groundwater table, this cluster is joined by the observation well NOS-104, located downstream the landfill in the second protection area (Fig. 2). It is concluded that the Trebež Landfill certainly affects the observation wells located downstream, as shown in the currently applicable *medium-high and low groundwater table maps*. How-

ever, an additional impact westward from the landfill is also possible. Another explanation of the groundwater chemistry in the observation wells NOS-105 and NOS-117 is presence in the area of unrecorded illegal dump sites or polluters located further to the west from the Trebež Landfill.

The analysis results for the observation wells NOS-102, NOS-103, and NOS-104 located at approximately equal distance from the Trebež Landfill enable assessment of the landfill impact on the groundwater in the second protection area. It is concluded that, for the time being, there is no major impact of the Trebež Landfill on the groundwater quality at distance of some 400 to 500 m from the first protection area. The conclusion is based on the results of conducted chemical analyses. This does not mean that the situation will not change in the future, particularly due to possible change in hydrodynamic status caused by construction of the Podused Hydroelectric Power Plant. The observation well NOS-104, the one most distanced from the landfill, is the only piezometer that shows similarities with the observations wells located immediately downstream from the landfill during high groundwater tables. This might be an indication that during high tables the groundwater flow direction changes towards NE.

The *PCA* was used to detect the most important macro and micro components which have or could have been caused by anthropogenic impact resulting in the groundwater quality change within the Strmec Well Field protection areas. The *PCA* results have shown that sulphates, chlorides, iron and manganese are the most important components for further time-series data analyses (Table 4).

The *Time series* analysis was conducted for each individual parameter, and the results are shown graphically as an assessment of trends of specific components. The trends were assessed for 9 out of 14 observation wells: NOS-101 (Fig. 7), NOS-102 (Fig. 8), NOS-103 (Fig. 9), NOS-104 (Fig. 10), NOS-118 (Fig. 11), NOS-119 (Fig. 12), NOS-120 (Fig. 13), NOS-121 (Fig. 14) and NOS-29 (Fig. 15).

The detected trends on the observation wells and variations in component concentrations at the locations of individual piezometers led to the conclusions on the above determined observation well clusters.

It is concluded that the first cluster observations wells are most probably affected by the vicinity of the local surface water, although the applicable *Groundwater Table Maps* do not confirm the assumptions.

The *second cluster* observation wells are affected by local hydrodynamic and hydrogeochemical impacts. Only the location of the observation well NOS-101 shows positive trend in sulphates and chlorides, which is an obvious sign of local impact of agricultural activity. No anthropogenic effects were confirmed at the locations of observation wells NOS-29 and NOS-102.

Also, no anthropogenic effects were confirmed at the location of observation well NOS-103, which belongs to no cluster.

Further, for the location of the observation well NOS-104, which falls in the third cluster during high and in the first cluster during the low groundwater tables, the increase in iron and manganese concentrations had not been recorded for the period before the year 2000, so there is no proof that it is affected by the Trebež Landfill.