

Analysis of Oceanographic Properties of the Adriatic Sea by GIS Technique

V. Dadić¹, M. Srdelić², Z. Gržetić²

¹Institute of Oceanography and Fisheries, Split, Croatia

Tel: 385/21-358-688, e-mail: dadic@izor.hr

²Croatian Hydrographic Institute, Split, Croatia

Tel: 385/21-361-840, e-mail: mladen.srdelic@st.tel.hr

ABSTRACT. *All historical data of classical oceanographic parameters (temperature, salinity, oxygen, and pH) stored in Marine Environmental Database of the Adriatic Sea (MEDAS) have been analysed in the paper. Since the main figure of data distribution is not regular in space and time, it was necessary to estimate the value of the each parameter at the nodes of an interpolated grid. All parameters were interpolated on the standard oceanographic levels, and the semivariogram graphs were used to describe the structural properties of field of each parameter. Geostatistics was used for interpolation of data because it estimates values corresponding to the average values of a random function with minimum standard deviation error of interpolated data. GIS technique was used for the final analysis and presentation of output data (seasonally, monthly, yearly data distributed in different layers of water column and different sub regions of the Adriatic Sea). In addition, overlaying of different oceanographic parameters, maps show an influence of climate and environmental change on biodiversity in the Adriatic Sea.*

1. INTRODUCTION

The main figure of available classical oceanographic data (temperature, salinity, oxygen and pH) is their statistically random distribution in space (geographic position and layer in the water column) and time (year, season and month). Therefore, it was necessary to handle these data in three steps to get output data in suitable form for analysis:

- Interpolation of measuring data on standard oceanographic levels
- Estimating of interpolating data in square nodes of geographic grid, and
- Presentation of output results in GIS form.

Other oceanographic data have passed through a similar control procedure depending on nature and distribution of data. For example, data related fishes caught by trawlers represent bottom layer in water column but randomly distributed in geographic space. As the main objective of any spatial investigation is to simplify the analysis of spatially distributed data to end users, the special GIS system was designed to perform the following functions: data input, data storage and

Analiza oceanografskih svojstava Jadranskoga mora s pomoću tehnike GIS-a

V. Dadić¹, M. Srdelić², Z. Gržetić²

¹Institut za oceanografiju i ribarstvo, 21000 Split

Tel: 385/21-358-688, e-mail: dadic@izor.hr

²Hrvatski hidrografski institut, 21000 Split

Tel: 385/21-361-840, e-mail: mladen.srdelic@st.tel.hr

SAŽETAK. U radu su analizirani povijesni podatci klasičnih oceanografskih parametara (temperature, slanosti, kisika i pH) koji se čuvaju u bazi oceanografskih podataka Jadranskoga mora MEDAS. Budući da su oceanografski podatci neravnomjerno raspoređeni u prostoru i vremenu, radi lakše analize interpolirani su u čvorovima pravilne geografske mreže te na standardne oceanografske razine. Za ocjenu svojstava strukture prostornog polja upotrijebljen je variogram, dok su za interpolaciju podataka upotrijebljene geostatističke metode koje omogućuju procjenu prostornih vrijednosti što odgovaraju srednjim vrijednostima slučajne funkcije s najmanjom pogrješkom standardne devijacije. Tehnika GIS-a upotrijebljena je za završnu analizu i prikaz izlaznih rezultata (godišnjih, sezonskih i mjesečnih srednjaka u različitim slojevima vodenog stupca i različitim područjima Jadranskoga mora). Preklapanjem slojeva različitih oceanografskih parametara i njihovom analizom moguće je npr. spoznati utjecaj klimatoloških promjena ekoloških parametara na biološku raznolikost Jadranskoga mora.

1. UVOD

Glavna osobina raspoloživih podataka klasičnih oceanografskih parametara (temperature, slanosti, kisika i pH) u Jadranskome moru njihova je statistički slučajna raspoređenost u prostoru (geografskim položajima i razinama u vodenom stupcu) i vremenu (godinama, sezonama i mjesecima). Zbog toga je rukovanje tim podacima potrebno obaviti u tri koraka kako bi se mogli dobiti izlazni rezultati prikladni za različite analize:

- interpolacija mjerenih podataka na standardne oceanografske razine,
- procjena interpoliranih podataka u čvorovima kvadratne mreže, i
- prikaz izlaznih rezultata u GIS-obliku.

Drugi oceanografski podatci podvrgavaju se sličnim postupcima provjere, ovisno o njihovoj prirodi te prostornoj i vremenskoj raspodjeli, pa se npr. podatci o broju ulovljenih riba s pomoću kočara odnose samo na pridneni sloj vodenog stupca i također su prostorno slučajno raspoređeni.

Kako je glavna svrha prostornih istraživanja pojednostavniti prikaz i analizu prostorno slučajno

database management system, data analysis and processing, interaction of spatial data with GIS basic layers through graphics interface, and data output first of all in graphic forms.

The maps created on the basis of Geographical Information System (GIS) have represented all

been collected by many institutions and measured at various sea levels using different methods and instruments (BOT – bottle data, MBT – mechanical bathythermograph, XBT – expanded bathythermograph, CTD – multiparameter probe), data quality control (QC) has been one of major tasks. After QC procedure that included duplicate elimination, range checking,

Table 1. Number of classical oceanographic data received from different countries/projects and number of unique and correct data

Tablica 1. Broj podataka klasičnih oceanografskih parametara dobivenih iz različitih izvora (zemalja i projekata) te broj ispravnih podataka nakon provjere kvalitete

Data source <i>Izvor podataka</i>	Temperature <i>Temperatura (°C)</i>			Salinity <i>Slanost (psu)</i>			Oxygen <i>Kisik (ml/l)</i>	pH
	BOT	MBT	XBT	CTD	BOT	CTD		
Croatia <i>Hrvatska</i>	27934	25693	0	834	22524	834	5394	2138
Italy <i>Italija</i>	8372	0	0	275	5612	275	974	293
USA <i>SAD</i>	6618	2137	2436	162	4517	162	1094	895
Greece <i>Grčka</i>	0	0	0	1356	0	1356	0	0
MEDAR <i>MEDAR</i>	9488	1142	553	2241	8488	2241	0	0
MODAB <i>MODAB</i>	4036	638	0	174	2504	2174	0	0
Russia <i>Rusija</i>	3840	375	0	0	1314	0	0	0
France <i>Francuska</i>	1398	0	0	0	1225	0	185	63
Total <i>Ukupno</i>	61686	29985	2989	5042	46184	7042	7647	3389
Unique and correct data <i>Jedinstveni i točni podaci (%)</i>	31279	27496	2737	1352	28722	3841	5840	2925
	50.7	91.7	91.5	26.8	62.2	54.5	76.3	86.0

measured, aggregated and estimated data. Based on the maps produced by means of such data processing, various analyses of oceanographic properties of the Adriatic Sea have been possible.

2. MATERIAL AND METHODS

2.1 Oceanographic data


Oceanographic investigation in the Adriatic Sea has been done for more than a century by many institutions from Croatia, as well as many international oceanographic organisations. It includes physical oceanography, chemistry, biology and fisheries. Classical oceanographic parameters represent the most often measured oceanographic parameters. As data have

statistical checks and static stability check of data have been completed, more data were excluded from processing, e.g. 49% of BOT data and 8% of MBT data (Table 1).

The main figure of data distribution is not regular in space and time (Fig. 1). The data have been collected at various (statistically random) sea levels, geographic positions (oceanographic stations) and seasons during a year depending on the used methods and purpose of measurements.

2.2 Method of data interpolation at standard levels

There are more so called general and local methods of interpolation. Local interpolation methods take into account only neighbourhood data and they are more



Slika 1. Broj raspoloživih nizova podataka klasičnih oceanografskih parametara po godinama (A) i prostorna raširenost mjernih postaja u Jadranskom moru (B)

Fig. 1 Number of measured data on the yearly basis (A) and spatial distribution of the stations in the Adriatic Sea (B)

raspoređenih podataka krajnjim korisnicima, razvijen je GIS koji omogućuje: unos i spremanje podataka u sklopu sustava za njihovo rukovanje, analizu, obradu i preklapanje slojeva prostornih podataka s osnovnim slojevima GIS-a preko grafičkog sučelja te ponajprije njihov prikaz u grafičkom obliku.

S pomoću karata napravljenih u sklopu GIS-a predstavljeni su svi mjereni, agregirani i procijenjeni podatci u prostoru na osnovi kojih je relativno jednostavno moguće obaviti različite analize oceanografskih svojstava Jadranskoga mora.

2. MATERIJAL I METODE

2.1. Oceanografski podatci

Oceanografska istraživanja u Jadranskom moru izvode hrvatske i međunarodne institucije duže od jednog stoljeća i obuhvaćaju fiziku, kemiju i biologiju mora te ribarstvo, a najčešće su mjereni klasični oceanografski parametri (temperatura, slanost, kisik i pH). Kako su te parametre mjerile u relativno dugom razdoblju mnoge institucije na različitim razinama u moru, različitim metodama i mjernim instrumentima (BOT – crpci s prekretnim termometrima, MBT i XBT – mehanički i elektronički batitermograf, CTD – višeparameterska sonda), kvalitativna provjera podataka (QC) bila je jedan od najvažnijih zadataka. Nakon provedene provjere kvalitete, koja je uključivala eliminaciju višestruko ponovljenih podataka, provjeru graničnih vrijednosti i statističku provjeru, veliki broj nizova

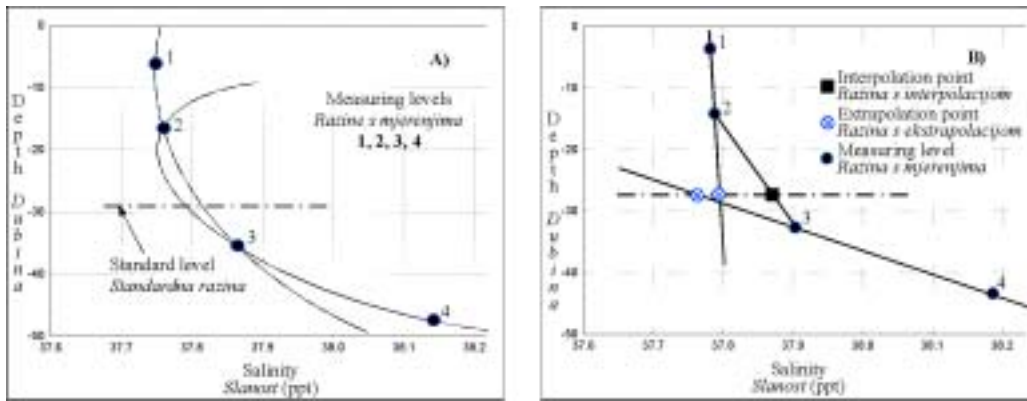
podataka isključen je iz obrade, kao npr. 49% BOT i 8% MBT podataka (tablica 1).

Glavna je osobina oceanografskih podataka njihova neravnomjerna raširenost u prostoru i vremenu (slika 1) jer su mjereni na različitim razinama u moru (statistički slučajnim), geografskim položajima (oceanografskim postajama) i godišnjim razdobljima ovisno o upotrijebljenim metodama i ciljevima zbog kojih su obavljena pojedina mjerenja.

2.2. Interpolacija podataka na standardne oceanografske razine

Općenito postoji više općih i lokalnih metoda interpolacije. Lokalne interpolacijske metode, odnosno metode koje se za interpolaciju koriste samo susjednim podacima, znatno su primjerenije za interpolaciju podataka na standardne oceanografske razine zbog toga što vodene mase mogu imati vrlo različite oceanografske osobine u pojedinim slojevima vodenog stupca. Za interpolaciju oceanografskih parametara upotrijebljeno je više varijacija lokalnih metoda (Ratrray, 1958; Reiniger i Ross, 1964; Dadić, 2000). U ovom je radu upotrijebljena Newtonova metoda konačnih razlika drugoga reda kroz tri nejednako udaljene točke mjesto Lagrangeove metode, koja kao rezultat daje interpolirane vrijednosti $p_{ijk}(x_0)$ i njihove pogreške $R_{ijk}(x_0)$ u točki interpolacije x_0 .

Ako su vrijednosti ovisne varijable y_1, y_2, y_3, y_4 poznate u točkama x_1, x_2, x_3, x_4 , gdje je $x_4 > x_3 > x_0 > x_2 > x_1$, onda se vrijednost y_0 u točki x_0 smještenoj između točaka x_2 i x_3



Slika 2. Postupci interpolacije na standardne oceanografske razine upotrebom Newtonove metode konačnih razlika (A) poboljšane linearnom referentnom krivuljom (B)
 Fig. 2 Procedure of local interpolation on the standard oceanographic levels using second order of Newton's method (A) corrected by linear reference curve (B).

suitable for data interpolation at the standard levels because water has completely different properties in specific parts of water column. There are more local methods of interpolation (Rattray, 1958; Reiniger and Ross, 1964, Dadić, 2000). In this paper, the second order Newton's method of finite differences from three unequally spaced positions is used instead Lagrange's method. This method determines the interpolated value $p_{ijk}(x_0)$ and its errors $R_{ijk}(x_0)$.

Let us take values of the dependent variable y_1, y_2, y_3, y_4 to be known at successive positions x_1, x_2, x_3, x_4 where $x_4 > x_3 > x_0 > x_2 > x_1$. Then the value of y_0 at position x_0 lying between x_2 and x_3 is

$$y_0 = p_{ijk}(x_0) + R_{ijk}(x_0)$$

where

$$p_{ijk}(x) = y_i + k_1(x - x_i) + k_2(x - x_i)(x - x_j)$$

and

$$k_1 = [x_i, x_j] = \frac{y_j - y_i}{x_j - x_i}$$

$$k_2 = [x_i, x_j, x_k] = \frac{[x_j, x_k] - [x_i, x_j]}{x_k - x_i}$$

where with i, j, k equal to either 1, 2, 3 or 2, 3, 4, respectively.

This formula was improved according to Reiniger and Ross (1964) by introducing a reference curve to minimise the effect of unacceptable parabola on the final interpolated values. It is created by adjusting the linearly interpolated value by an amount related to the difference between the interpolated value (two inner points) and extrapolated value (two outer points). There is a weighting used which is inversely proportional to

some power of the differences between the interpolated and extrapolated points. According to Dadić (2000) the

best-fitted reference curve for classical oceanographic parameters in the Adriatic Sea has the form:

$$y_R(x) = \frac{1}{2} \left(y_{23} + \frac{y_{34}(y_{12} - y_{23})^{1.5} + y_{12}(y_{23} - y_{34})^{1.5}}{(y_{12} - y_{23})^{1.5} + (y_{23} - y_{34})^{1.5}} \right)$$

Interpolation $y(x)$ includes linear interpolation between the values obtained from two parabola (Fig. 2.A) and the reference curve $y_R(x)$ (Fig. 2.B) as in formula:

$$y(x) = \frac{y_{p2}(y_R - y_{p1})^{0.6} + y_{p1}(y_R - y_{p2})^{0.6}}{(y_R - y_{p1})^{0.6} + (y_R - y_{p2})^{0.6}}$$

where

$$y_{p1} = s_{23}y_1 + s_{31}y_2 + s_{12}y_3, \quad y_{p2} = s_{34}y_2 + s_{42}y_3 + s_{23}y_4,$$

$$s_{jk} = \frac{(x - x_j)(x - x_k)}{(x_i - x_j)(x_i - x_k)}$$

and y_1, y_2, y_3, y_4 are the values of parameters in the points x_1, x_2, x_3, x_4 , taking into account $x_1 < x_2 < x_3 < x_4$.

For the top and bottom of water column where there is only one point above or below standard level, it is necessary to adopt this formula for linear interpolation. This formula gives less reliable results than in the interior of water column because the curve is almost completely dominated by information below or above the region of interpolation.

An automatic software tool was developed for interpolating data from observed to standard oceanographic levels with graphic visualisation of output results (interpolated value and expected error). All data profiles were passed through quality control before and after their interpolation at standard levels.

računa s pomoću jednadžbe:

$$y_0 = p_{ijk}(x_0) + R_{ijk}(x_0)$$

uz

$$p_{ijk}(x) = y_i + k_1(x - x_i) + k_2(x - x_i)(x - x_j)$$

$$i \quad k_1 = [x_i, x_j] = \frac{y_j - y_i}{x_j - x_i}$$

$$k_2 = [x_i, x_j, x_k] = \frac{[x_j, x_k] - [x_i, x_j]}{x_k - x_i}$$

gdje i, j, k odgovaraju točkama 1, 2 i 3, odnosno 2, 3 i 4.

Ta je jednadžba poboljšana u skladu s preporukom Reinigera i Rossa (1964) uvođenjem referentne krivulje radi smanjivanja utjecaja nelinearnosti parabola na izračunane vrijednosti interpoliranih podataka. Referentna krivulja u točki interpolacije uvodi linearno interpolirane vrijednosti kao razliku interpolirane vrijednosti između dviju unutarnjih točaka i ekstrapolirane vrijednosti između dviju vanjskih točaka (slika 2). To se postiže uvođenjem težinskog množitelja obrnuto proporcionalnog nekom eksponentu razlika između interpolirane i ekstrapolirane vrijednosti. Prema Dadiću (2000), najbolja referentna krivulja za interpolaciju klasičnih oceanografskih parametara u Jadranskome moru ima sljedeći oblik:

$$y_R(x) = \frac{1}{2} \left(y_{23} + \frac{y_{34}(y_{12} - y_{23})^{1.5} + y_{12}(y_{23} - y_{34})^{1.5}}{(y_{12} - y_{23})^{1.5} + (y_{23} - y_{34})^{1.5}} \right)$$

Interpolacija $y(x)$ uključuje linearnu interpolaciju između vrijednosti dobivenih s pomoću dviju parabola (slika 2A) i referentne krivulje $y_R(x)$ (slika 2B) kao u jednadžbi:

$$y(x) = \frac{y_{p2}(y_R - y_{p1})^{0.6} + y_{p1}(y_R - y_{p2})^{0.6}}{(y_R - y_{p1})^{0.6} + (y_R - y_{p2})^{0.6}}$$

gdje su


$$y_{p1} = s_{23}y_1 + s_{31}y_2 + s_{12}y_3, \quad y_{p2} = s_{34}y_2 + s_{42}y_3 + s_{23}y_4,$$

$$s_{jk} = \frac{(x - x_j)(x - x_k)}{(x_i - x_j)(x_i - x_k)}$$


a y_1, y_2, y_3, y_4 vrijednosti parametara u točkama x_1, x_2, x_3, x_4 uz uvjet da je $x_1 < x_2 < x_3 < x_4$.

U površinskom i pridnenom sloju vodenog stupca nalazi se samo jedna točka iznad, odnosno ispod standardne oceanografske razine, pa je gornju jednadžbu potrebno prilagoditi kako bi se izvela linearna interpolacija s pomoću dviju unutarnjih točaka. Ta linearna jednadžba daje lošije rezultate nego kod interpolacije unutar vodenog stupca jer interpolirana vrijednost ovisi samo o izmjerenim vrijednostima na razinama iznad i ispod standardne oceanografske razine.

U svrhu interpolacije s mjerenih na standardne oceanografske razine razvijen je programski paket s grafičkim prikazom izlaznih rezultata (interpoliranih vrijednosti i očekivanih pogriješaka). Prije interpolacije na standardne oceanografske razine svi su mjereni podatci podvrgnuti složenoj statističkoj provjeri kvalitete. Tako su se npr. vrijednosti svih parametara trebale nalaziti unutar određenih granica (najmanje i



Slika 3. Strukturno polje (A) i poluvariogram (B) unutar izotropnog i neizotropnog polja
Fig. 3 Field structure (A) and semivariogram (B) inside isotropic and anisotropic field



Slika 4. Eksperimentalni poluvariogram bez smjera
Fig. 4 Omnidirectional experimental variogram

Values of all parameters have to be within minimum and maximum, as well as within climatological range.

2.3 Method of geostatistical analysis and presentation of spatially distributed data

Geostatistical analysis represents an application of probability theory to estimate statistics relating to spatial variables. There are more geostatistical methods for interpolation of spatially distributed data. In this paper linear geostatistics, applying kriging techniques was used for estimation value of the given variables in each unsampled point (Journel and Hjugregts, 1978). Kriging method is optimal method of interpolation that provides best linear unbiased estimate of the variable at a given point. It is an extract interpolator in the sense that interpolated values, or best local average, will coincide with the values at the data points. In mapping, values have been interpolated for points on a regular grid that is finer than the spacing used for sampling.

Generally, the spatial distribution of variables related oceanographic parameters in the sea could be represented as a complex surface (Fig. 3). We used the semivariogram as a useful tool to describe the structural properties of this surface (Fig. 4). It measures the level of dissimilarity between points as a function of the distance between them. If the semivariogram increases as the distance increases, then closer points are more similar than more distant points and therefore there is spatial structuring. If the semivariogram is flat, then close points have as different values as distant ones, and therefore there is no spatial structuring. The semivariogram can be calculated along several directions to highlight structural anisotropy (Fig. 4).

In homogeneity conditions of the spatial field the semivariance $\gamma(h)$ can be estimated from sample data:

where n is a number of pairs of sample stations separated by distance h called the lag. Usually, some mathematical models (Gauss, exponential, spherical,

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n \{ V(x_i) - V(x_i + h) \}^2,$$

etc) have been fitted through the experimentally derived data stations in order to be able to describe the way in which semivariogram changes with the lag.

Kriging is a method of interpolation used when one wish to estimate the values of the variable at the nodes of an interpolation grid. As for any interpolation method, kriging allows moving from random sampling configuration to regular configuration, which automatically provides a map. Kriging allows the estimation of underlying process values on the interpolation grid. The kriged estimated values correspond to the average values of the random function. We have used the values of neighboring sample points to estimate the values of the density surface at non-sample points. The neighborhood is the area around the point to be estimated in which we find the samples to be used for the estimation. The kriging weight given to each neighborhood sample depends on spatial structure, its position in relation to the point to be estimated and its position relative to the other neighborhood samples. The kriging weights are functions of the semivariogram and of the sampling configuration.

najveće moguće vrijednosti), kao i unutar granica klimatoloških vrijednosti.

2.3. Geostatistička analiza i prikaz podataka slučajno raspoređenih u prostoru

Geostatistička analiza primjena je teorije vjerojatnosti u procjeni statističkih osobina prostornih varijabli. Postoji više geostatističkih metoda za interpolaciju podataka slučajno raspoređenih u prostoru. U ovom je radu upotrijebljena linearna geostatistika primjenom Krigeove tehnike za procjenu vrijednosti parametra u točkama bez mjerenja na osnovu postojećih podataka (Journel i Hjugregts, 1978). Krigeova metoda optimalna je metoda interpolacije jer omogućuje najbolju procjenu nepomaknute vrijednosti parametra u promatranoj točki pa se naziva i točni interpolator, gdje interpolirane vrijednosti, odnosno najbolji lokalni srednjaci, odgovaraju vrijednostima parametra u točkama s obavljenim mjerenjima. Kod izrade karata prostornih polja parametra podatci se interpoliraju u čvorovima kvadratne mreže gustoća koje je nešto veća od točaka u kojima su obavljena mjerenja.

Općenito se prostorna raspodjela vrijednosti pojedinih oceanografskih parametara u moru može prikazati kao složena statistička površina (slika 3). Za analizu strukturnih osobina tih površina u radu je upotrijebljen variogram ili točnije, poluvariogram (slika 4) koji predstavlja mjeru različitosti između pojedinih točaka kao funkciju udaljenosti između njih. U slučaju povećavanja vrijednosti poluvariograma s povećanjem udaljenosti između parova točaka proizlazi da su vrijednosti parametra u međusobno bližim točkama sličnije nego među udaljenim točkama, odnosno među njima postoji strukturna ovisnost. Ako poluvariogram prestaje rasti, odnosno postaje ravan, vrijednosti parametra u pojedinim parovima točaka međusobno ne ovise pa među njima ne postoji strukturna ovisnost. U slučaju kada ne postoji izotropnost, poluvariogram se može računati u nekoliko smjerova (slika 4) da bi se interpolacijom, koja se često naziva objektivna analiza, dobili bolji rezultati.

U homogenim uvjetima unutar prostornog polja poluvarijanca $\gamma(h)$, odnosno eksperimentalni variogram (slika 4) može se izračunati iz mjerenih podataka s pomoću jednadžbe:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n \{V(x_i) - V(x_i + h)\}^2,$$

gdje je n broj parova postaja s mjerenjima međusobno udaljenih za vrijednost h . U radu je upotrijebljeno nekoliko matematičkih modela (Gaussov, eksponencijalni, sferni itd.) za prikaz variograma iz podataka dobivenih mjerenjima kako bi se lakše mogla

odrediti promjena poluvariograma s povećanjem udaljenosti među postajama.

Krigeova metoda interpolacije služi za procjenu vrijednosti parametara u čvorovima pravilne mreže na osnovi podataka izmjerenih na postajama slučajno raspoređenima u prostoru. Kao i druge interpolacijske metode, Krigeova metoda omogućuje analizu podataka u točno određenim točkama u prostoru s pomoću kojih se automatski mogu dobiti grafički prikazi. Krigeova metoda omogućuje procjenu vrijednosti promatranog parametra u čvorovima interpolacijske mreže tako da procijenjene vrijednosti odgovaraju srednjim vrijednostima slučajne funkcije. Za interpolaciju u čvorovima mreže koriste se izmjereni podatci samo s postaja smještenih unutar unaprijed određenog polumjera udaljenosti, koji se određuje iz variograma. Pritom se računa tzv. Krigeova težinska vrijednost za svaku postaju s mjerenim podacima, koja ovisi o prostornoj strukturi promatranog parametra, njezinu odnosu s obzirom na poziciju u kojoj se procjenjuje vrijednost parametra te odnosu s ostalim susjednim postajama s mjerenim podacima. Izračunane Krigeove težinske vrijednosti ovise o vrijednosti poluvariograma i međusobnom položaju postaja.


Uz pretpostavku homogenih uvjeta unutar polja za prostornu procjenu (interpolaciju) podataka može se upotrijebiti linearna geostatistika. Prethodno definirani poluvariogram može se upotrijebiti za određivanje težinskih vrijednosti λ_i potrebnih za interpolaciju Krigeovom metodom u jednadžbi:

gdje je $V(x_0)$ procijenjena vrijednost u točki x_0 , a $V(x_i)$

$$V(x_0) = \sum_{i=1}^n \lambda_i V(x_i)$$

poznata vrijednost u točki.

Težinske vrijednosti λ_i uzimaju se tako da su procijenjene vrijednosti varijable $V(x_0)$ u točkama x_0 nepomaknute, a procijenjena varijanca manja nego za bilo koju drugu linearnu kombinaciju izmjerenih vrijednosti. Najmanja varijanca varijable u točki



Slika 5. Udaljenost (δh) i kut tolerancije ($\delta \theta$) između slučajno raspoređenih prostornih podataka

Fig. 5 Distance (δh) and angle ($\delta \theta$) tolerance among randomly distributed spatial data

With assumptions of field homogeneity a linear and stationary geostatistics can be used for spatial interpolation of data. Above defined semivariogram can be used to determine the weights λ_i needed for interpolation by kriging method in the equation:

$$V(x_0) = \sum_{i=1}^n \lambda_i V(x_i)$$

where $V(x_0)$ is estimated value in point x_0 and $V(x_i)$ known value in point x_i .

The weights λ_i are chosen so that the estimate value of variable $V(x_0)$ in point with estimating values x_0 is unbiased and the estimated variance is less than for any other linear combination of the observed values. The minimum variance of the variable in point of interpolation $V(x_0)$ is obtained in case:

$$\sum_{j=1}^n \lambda_j \gamma(x_i, x_j) + \Psi = \gamma(x_i, x_0), \quad \forall i = 1, \dots, n$$

$$\sum_{i=1}^n \lambda_i = 1$$

and it is

$$\sigma_e^2 = \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \Psi$$

where $\gamma(x_i, x_j)$ is semivariance of $V(x)$ between sampling points x_i and x_j , $\gamma(x_i, x_0)$ is semivariance between sampling points x_i and point with estimation x_0 , and Ψ is Lagrange multiplier required for minimising.

3. RESULTS AND DISCUSSION

After QC procedure and harmonisation of data, numerous unique and correct data profiles were included in statistical calculations, e.g. more than one hundred thousand of temperature data (Tab. 1). Importance of QC procedure and harmonisation of classical oceanographic is shown on Fig. 6. Spatial field of temperature gathered from original data looks very artificial, while field of temperature gathered from QC data looks more realistic.

Generally, results obtained were quite satisfactory except in some areas where the unrealistic values of oceanographic parameters have been obtained. Examination of these features indicated that some of them are due to large spatial and interannual variability in a region where scattered sampling in time has occurred, existing of springs and river mouths in coastal area, and sparse of measuring data (Fig. 6 and 7). We had these facts in mind when accepting the results of objective analysis because the distribution of data in some regions was unrealistic with high gradients or bulls-eyes.

Based on QC and harmonised data profiles 41 standard levels were defined in the Adriatic Sea. Additionally, two maximum depth difference criteria (inner and outer) were defined for each standard level as proposed by Dadić (2001). The first criterion defined a maximum distance from standard level to the adjacent shallower and deeper measured level, and the second criterion, that was less strict, defined maximum distance to the second shallower and deeper measured level. If the inner and outer distance criteria were violated, no standard level value was calculated, but if only outer maximum depth distance was violated the linear interpolated one was used.

As there was anisotropy in spatially distributed data in transversal and longitudinal axes of the Adriatic Sea, different radius influence and grid mesh were used. So, influence radius of 7.5 km and interpolated data on a 5×5 km grid were used in transversal direction of the Adriatic Sea and in the coastal area and influence radius of 12 km and 7.5×7.5 km grid in longitudinal direction at the open sea during kriging interpolations. These parameters allowed the analysis of climatology of all randomly distributed oceanographic parameters in the space at every standard oceanographic level in the same way.

Some results of geostatistical analysis obtained by GIS tools are shown on Fig. 7 and 8.

The analysis of data with different parameters shows that the Adriatic Sea is the basin with the largest coast in the Mediterranean Sea. Therefore, there is strong variability in the classical oceanographic parameters both in space and time that has great influence on biological aspects.

Generally, climatological maps show a great seasonal variability of analyzed oceanographic parameters, especially temperature (Fig. 7) and salinity.

Hence, the sea surface temperature shows higher thermal gradient along the longitudinal axis of basin in winter, while it is almost flat in summer. There are higher temperatures in the shallow northern part and along western coast and lower temperatures in the southern part and along eastern coast.

In the winter season there is no stratification of the water masses, and the magnitude of thermal gradient is almost the same both in surface and bottom layers along longitudinal axis. During winter season, water masses are cooler in northern part and along western coast than those along eastern coast and in southern part.

Season variations of temperature in surface layer of the Adriatic Sea ranges from 5°C in winter and 27°C in summer. Variations in temperature are the greatest in

interpolacije $V(x_0)$ dobije se u slučaju kada su zadovoljeni uvjeti:

$$\sum_{j=1}^n \lambda_j \gamma(x_i, x_j) + \Psi = \gamma(x_i, x_0), \quad \forall i = 1, \dots, n$$

$$\sum_{i=1}^n \lambda_i = 1 \quad i$$

$$\sigma_e^2 = \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \Psi$$

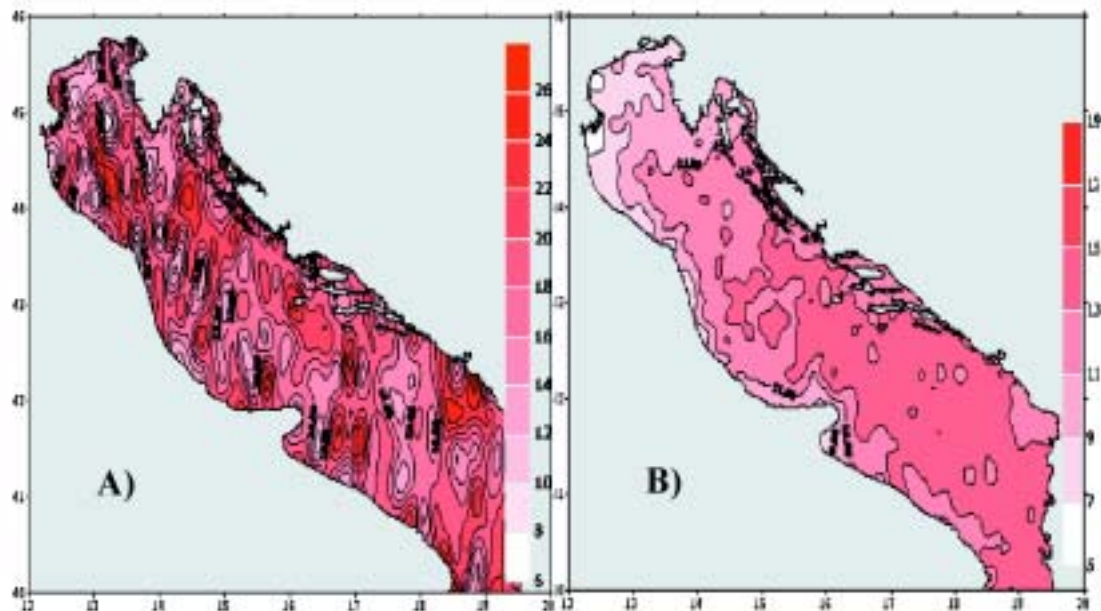
gdje je $\gamma(x_i, x_j)$ poluvarijanca varijable $V(x)$ između točaka x_i i x_j , $\gamma(x_i, x_0)$ poluvarijanca između točaka x_i i x_0 , u kojoj se procjenjuje vrijednost, a Ψ je Lagrangeov množitelj koji je potrebno uvesti pri rješavanju sustava jednadžbi.

3. REZULTATI I RASPRAVA

Nakon provjere kvalitete podataka i njihove harmonizacije veliki broj jedinstvenih i točnih podataka uključen je u statističke proračune, kao npr. više od sto tisuća nizova podataka o temperaturi mora (tablica 1). Važnost provjere kvalitete i harmonizacije podataka klasičnih oceanografskih parametara pokazana je na slici 6, na kojoj prostorno polje temperature dobiveno iz izvornih podataka izgleda nestvarno za razliku od polja dobivenog iz provjerenih i harmoniziranih podataka čiji je izgled znatno bliži očekivanim vrijednostima.


Općenito su rezultati interpolacije zadovoljavajući, osim u onim područjima Jadrana gdje su vrijednosti prostornih polja oceanografskih parametara nestvarni. Analiza osobina prostornih polja pojedinih parametara pokazuje da su nestvarne vrijednosti nastale kao rezultat znatnih višegodišnjih promjena u područjima s neravnomjernim rasporedom mjernih postaja, velikoga gradijenta u vrijednostima parametara zbog postojanja vrulja u moru, riječnih utoka u obalnom području kao i nedovoljnog broja postaja u prostoru i vremenu (slike 6 i 7). Pri analizi i prihvaćanju rezultata objektivne analize u područjima s nestvarnim izgledom prostornog polja, velikim gradijentom i tzv. volovskim očima te je čimbenike prijeko potrebno uzeti u obzir.

Na osnovi provjerenih i harmoniziranih podataka, u Jadranskom moru određena je 41 standardna oceanografska razina. Osim toga za svaku su standardnu razinu uzeta dva kriterija (unutarnji i vanjski) kao što je preporučio Dadić (2001). Unutarnji kriterij najveća je udaljenost od standardne razine do susjedne pliče i dublje razine s obavljenim mjerenjima, a drugi kriterij, koji je manje ograničavajući, najveća je udaljenost između standardne razine i druge susjedne pliče i dublje razine s mjerenjima. Ako nisu zadovoljeni unutarnji i vanjski kriteriji, interpolacija se na standardnoj oceanografskoj razini ne računa, a ako nije zadovoljen samo vanjski kriterij, upotrebljava se linearna interpolacija.



Slika 6. Interpolirano polje srednjih vrijednosti temperatura u površinskom sloju mora dobiveno iz izvornih podataka (A) i nakon provjere njihove kvalitete i harmonizacije (B)

Fig. 6 Interpolated field of mean value of temperature at the sea surface layer gathered from the original data (A) and the data passed through quality control and harmonisation (B)



Slika 7. Karte srednjih temperatura ($^{\circ}\text{C}$) u površinskom sloju tijekom zime (A), proljeća (B), ljeta (C) i jeseni (D) za razdoblje 1900–2000. godine

Fig. 7 Maps of averaged temperature ($^{\circ}\text{C}$) at surface layer during winter (A), spring (B), summer (C), and autumn (D) for the period 1900–2000

coastal area and northern Adriatic, and more limited in open sea and southern Adriatic.

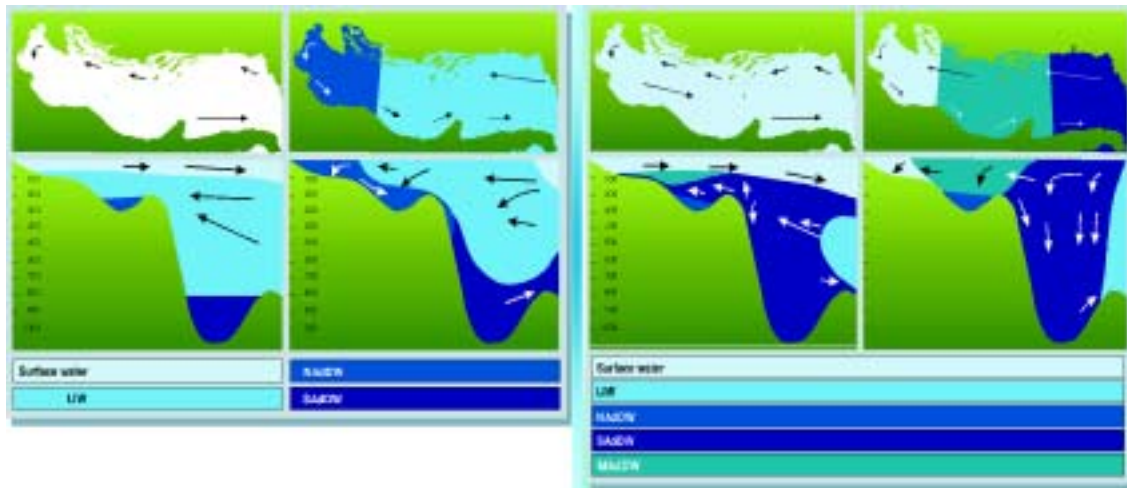
Salinity variations are also greater in coastal area and northern Adriatic than in the open sea because of seasonal variations in runoff of the Adriatic rivers.

Concerning oceanographic properties, the Adriatic Sea can be divided in four different areas: 1) channel area along Croatian coastline, 2) northern basin with shallow mean depth, 3) south basin with the deepest part of the Adriatic Sea, and 4) middle transition zone between north and south basin located around the line Split-Monte Gargano (Fig. 8). Water masses with different

properties assigned with different color (LIW – Levantin intermedial water, NaDW – North Adriatic Deep water, SaDW – South Adriatic deep water, MAdW – Middle Adriatic deep water).

4. CONCLUSION

ORACLE RDBMS and ArcView GIS tools organized as an automatic system for capturing different layers of oceanographic data and their overlaying with basic cartographic layers performed various sophisticated analyses related to marine environment, especially in climatological domain.



Slika 8. Cirkulacija najčešćih tipova vodenih masa u Jadranskomu moru izračunana s pomoću prostorne i vremenske raspodjele temperature i slanosti mora izmjerenih u razdoblju 1900–2000. godine
Fig. 8 The most often water masses circulation in the Adriatic Sea derived from temperature and salinity data collected in the period 1900–2000

Kako je računanje usmjerenih variograma u različitim smjerovima pokazalo da ne postoje uvjeti izotropnosti u smjeru uzdužne i okomite osi Jadranskoga mora, u tim su smjerovima upotrijebljeni različiti polumjeri područja utjecaja kod interpolacije. Proračunom je ustanovljeno da su rezultati interpolacije dobiveni Krigeovom metodom zadovoljavajući za izabrani promjer utjecaja od 7,5 km i kvadratnu mrežu interpolacije od 5x5 km u smjeru okomitom na obalu Jadranskoga mora i obalna područja i za promjer utjecaja od 12 km i kvadratnu mrežu od 7,5x7,5 km u smjeru njegove uzdužne osi u otvorenim vodama. Tako definirane veličine omogućuju proračun relativno pouzdanih klimatoloških osobina slučajno raspoređenih klasičnih oceanografskih parametara u prostoru na svim oceanografskim razinama.

Neki rezultati dobiveni geostatističkom analizom oceanografskih podataka prikazani su alatima GIS-a na slikama 7 i 8.

Analize podataka različitih oceanografskih parametara pokazuju da je od svih dijelova Mediteranskog mora Jadransko more najviše pod utjecajem aktivnosti na kopnu jer u njemu postoje znatno veće prostorne i vremenske promjene klasičnih oceanografskih parametara koje utječu na biološke uvjete u moru.

Općenito, klimatološke karte pokazuju velike sezonske promjene analiziranih oceanografskih parametara, posebno temperature mora (slika 7) i slanosti. Tako npr. tijekom zime temperatura u površinskom sloju pokazuje veći gradijent u smjeru uzdužne i poprečne osi Jadranskoga mora, dok su one mnogo manje tijekom

ljeta. Također je ljeti temperatura mora viša u plitkome sjevernom dijelu i uzduž zapadne obale, a niža je u njegovu južnom dijelu te uzduž istočne obale.

Tijekom zime ne postoji raslojavanje vodenih masa u vodenom stupcu, a veličina gradijenta temperature praktično je ista u površinskom i pridnom sloju u smjeru uzdužne osi Jadranskoga mora. U tom su razdoblju vodene mase hladnije u sjevernom dijelu i uzduž zapadne obale nego u njegovu južnom dijelu i uzduž istočne obale.


Sezonske promjene temperature u površinskom su sloju Jadranskoga mora u granicama 5°C tijekom zime i 27°C tijekom ljeta. Promjena je temperature najveća u obalnom području i sjevernom dijelu Jadrana, a mnogo je manja u otvorenim dijelovima mora i njegovu južnom dijelu.

Promjene slanosti također su veće u obalnim područjima i sjevernom Jadranu nego u otvorenim dijelovima mora zbog sezonskih promjena dotoka rijeka koje se ulijevaju u Jadransko more.

Rezultati analize prostornih polja pokazuju da se oceanografske osobine Jadranskoga mora mogu podijeliti na četiri osnovna područja: 1) kanalno područje uzduž hrvatske obale, 2) sjeverni bazen s plitkom srednjom dubinom mora, 3) južni bazen s najdubljim dijelom jadranskoga mora i 4) srednja prijelazna zona između sjevernog i južnog bazena koja se nalazi u području spojne linije Split – planina Gargano (slika 8). Vodene mase različitih osobina označene su različitim kraticama: LIW – levantinska

References

- Artegiani, A., D. Bregant, E. Paschini, N. Pinardi, F. Raicich and A. Russo (1997): The Adriatic Sea General Circulation. Part I: Air Sea interactions and water mass structure. *Journal of Physical Oceanography*, Vol. 27, No. 8: 1492-1514.
- Boyer, T. and S. Levitus (1994): QC and Processing of Historical Oceanographic Temperature, Salinity and Oxygen Data. USA-NOAA Technical Report NESDIS, No. 81.
- Dadić, V. (2000): An Interpolation of Oceanographic Data at Standard Oceanographic Levels. Proc. of 42nd International Conference ELMAR' 2000, Zadar, 42: 189-194.
- Dadić, V. (2001): Procedures for Acquisition, Analysis and Presentation of Oceanographic Data. Thesis. University of Zagreb, 189 pp.
- Davis, J. C. (1978): *Statistics and Data Analysis in Geology*. John Wiley & sons: 410 pp.
- Journel A. G., Huijbregts, C. J. (1978): *Mining Geostatistics*. Academic Press. 600 pp.
- Ratray, M. (1962): Interpolation errors and oceanographic sampling. *Deep-Sea Research*, Vol: 9: 25-37.
- Reiniger R. F., Ross, C. K. (1968): A method of interpolation with application to oceanographic data. *Deep-Sea Research*, Vol 15, pp: 185-193.
- Zore-Armanda, M., M. Bone, V. Dadić, M. Morović, D. Ratković, L. Stojanovski and I. Vukadin (1991): Hydrographic Properties of the Adriatic Sea in the Period from 1971 through 1983. *Acta Adriat.* 32 (1): 1-547.
- Zore-Armanda, M., M. Bone, V. Dadić, M. Gačić, V. Kovačević and Z. Vučak (1996): Ecological Study of Gas Fields in the Northern Adriatic, 4th Circulation. *Acta Adriat.* 37(1/2): 35-68.



srednjodubinska voda, NAdDW – sjevernojadranska duboka voda, SAdDW – južnojadranska duboka voda i MadDW – srednojadranska duboka voda.

4. ZAKLJUČAK

Sustav ORACLE za upravljanje bazama podataka i GIS-ov alat ArcView ustrojeni kao automatski sustav za prihvat različitih slojeva oceanografskih parametara i njihova preklapanja s osnovnim kartografskim slojevima (batimetrijom i obalnom linijom), omogućuju različite složene analize morskog okoliša, a posebno su pogodni za analizu klimatoloških osobina oceanografskih parametara na sezonskoj skali.

Literatura

Artegiani, A., Bregant, D., Paschini, E., Pinardi, N., Raicich, F.

and Russo, A. (1997): The Adriatic Sea general circulation. Part I: Air Sea interactions and water mass structure. *Journal of Physical Oceanography*, Vol. 27, No. 8: 1492-1514.

Boyer, T. and Levitus, S. (1994): QC and processing of historical oceanographic temperature, salinity and oxygen data. USA-NOAA technical report NESDIS, No. 81.

Dadić, V. (2000): An interpolation of oceanographic data on standard oceanographic levels. *Proc. of 42nd International Conference ELMAR 2000, Zadar*, 42, 189-194.

Dadić, V. (2001): Procedures for acquisition, analysis and presentation of oceanographic data. Thesis. University of Zagreb, 189 pp.

Davis, J. C. (1978): *Statistics and Data Analysis in Geology*. John Wiley & Sons, 410 pp.

Journel A. G., Huijbregts, C. J. (1978): *Mining Geostatistics*. Academic Press. 600 pp.

Ratray, M. (1962): Interpolation errors and oceanographic sampling. *Deep-Sea Research*, Vol: 9: 25-37.

Reiniger R. F., Ross, C. K. (1968): A method of interpolation with application to oceanographic data. *Deep-Sea Research*, Vol 15, pp: 185-193.

Zore-Armanda M., Bone, M., Dadić, V., Morović, M., Ratković, D., Stojanovski, L., Vukadin, I. (1991): Hydrographic properties of the Adriatic Sea in the period from 1971 through 1983. *Acta Adriat.* 32 (1): 1-547.

Zore-Armanda, M., Bone, M., Dadić, V., Gačić, M., Kovačević, V., Vučak, Z. (1996): Ecological study of gas fields in the northern Adriatic, 4. Circulation. *Acta Adriat.* 37(1/2): 35-68.

