

Primljen / Received: 13.11.2013.

Ispravljen / Corrected: 17.1.2014.

Prihvaćen / Accepted: 13.2.2014.

Dostupno online / Available online: 10.4.2014.

# Modeliranje lebdećeg nanosa pomoću SVM-a i valića

## Autori:



**Maedeh Sadeghpour Haji**

Islamsko sveučilište Azad  
Zavod za ekološko inženjerstvo,  
okoliš i energetiku  
[maedeh\\_sadeghpour@yahoo.com](mailto:maedeh_sadeghpour@yahoo.com)



Prof. **Seyed Ahmad Mirbagheri**

Tehnološko sveučilište K.N. Toosi  
Zavod za građevinarstvo i ekološko  
inženjerstvo  
[mirbagheri@kntu.ac.ir](mailto:mirbagheri@kntu.ac.ir)



Izv.prof. **Amir H. Javid**

Islamsko sveučilište Azad  
Odjel za znanost i straživanje  
[ahjavid@gmail.com](mailto:ahjavid@gmail.com)



Izv.prof. **Mostafa Khezri**

Islamsko sveučilište Azad  
Fakultet za okoliš i energetiku  
[khezri@sharif.edu](mailto:khezri@sharif.edu)



Prof. **Ghasem D. Najafpour**

Tehnološko sveučilište Babol Noshirvani  
Istraživački centar za biotehnologiju  
[najafpour8@gmail.com](mailto:najafpour8@gmail.com)

Prethodno priopćenje

[Maedeh Sadeghpour Haji, Seyed A. Mirbagheri, Amir H. Javid, Mostafa Khezri, Ghasem D. Najafpour](#)

## Modeliranje lebdećeg nanosa pomoću SVM-a i valića

Napredak koji danas bilježimo u primjeni umjetne inteligencije za predviđanje hidroloških događaja doveo je do brojnih promjena u sferi predviđanja. Valićni model baziran na metodi potpornih vektora (WSVM) dobiven je spajanjem valićne analize i metode potpornih vektora (SVM). Za učenje i testiranje korišteni su podaci o lebdećem nanosu (SS) i dnevnom protoku (Q) izmjereni na rijeci Iowa u SAD-u. Provedene analize su pokazale da se valićni model WSVM može koristiti za aproksimaciju količine lebdećeg nanosa.

### Ključne riječi:

diskretna valićna analiza, kumulativni lebdeći nanos, dnevni protok, visoke vrijednosti lebdećeg nanosa, metoda potpornih vektora (SVM)

Scientific paper - Preliminary note

[Maedeh Sadeghpour Haji, Seyed A. Mirbagheri, Amir H. Javid, Mostafa Khezri, Ghasem D. Najafpour](#)

## Suspended sediment modelling by SVM and wavelet

Present-day advances in artificial intelligence, as a forecaster for hydrological events, have led to numerous changes in forecasting. The wavelet support vector machine (WSVM) model is achieved by conjunction of the wavelet analysis and the support vector machine (SVM). The suspended sediment (SS) and daily stream flow (Q) data from the Iowa River in the USA were used for training and testing. The WSVM could logically be used for approximation of the suspended sediment load.

### Key words:

Discrete wavelet analysis, Cumulative SS, Daily stream flow, High suspended sediment, Support vector machine

Vorherige Mitteilung

[Maedeh Sadeghpour Haji, Seyed A. Mirbagheri, Amir H. Javid, Mostafa Khezri, Ghasem D. Najafpour](#)

## Modellierung von Schwebstoffsedimenten mittels SVM und Wavelets

Fortschritte bezüglich der Anwendung künstlicher Intelligenz Vorhersagen hydrologischer Vorgänge haben zu zahlreichen Änderungen in diesem Bereich geführt. Das Modell der Wavelet-Support-Vektor-Maschine (WSVM) beruht auf der Verbindung von Wavelet Analysen und Support-Vektor-Maschinen (SVM). Zur Einführung und Prüfung sind Daten hinsichtlich der Schwebstoffmengen (SS) und des täglichen Stromflusses (Q) aus Messungen am Fluss Iowa in den USA angewandt worden. Das Modell WSVM kann daher für die Approximation von Schwebstoffmengen angewandt werden.

### Schlüsselwörter:

diskrete Wavelet Analyse, kumulative Schwebstoffsedimente, täglicher Stromfluss, hohe Schwebstoffsedimente, Support-Vektor-Maschine

## 1. Uvod

Kod većine rijeka glavina nanosa transportira se u lebdećem stanju. Sve veće se značenje pridaje točnom predviđanju nanosa, i to naročito u poplavnim područjima [1]. Ispravna procjena količine lebdećeg nanosa (eng. *suspended sediments* - SS) od ključnog je značenja za korištenje i projektiranje kanala, brana i derivacijskih kanala. Predviđanje riječnog nanosa složen je posao koji se obavlja u okviru upravljanja vodnim resursima u području ekološkog inženjerstva i hidrologije [2]. U modeliranju SS nanosa, projektanti se susreću s velikim brojem nepoznatih faktora. Teoretske jednadžbe nisu uvijek prikladne za dobivanje podataka u čitavom procesu jer one jednostavno ne mogu u cijelosti obuhvatiti nelinearnosti i nestacionarnosti ekoloških i hidroloških podataka.

U posljednjih desetak godina sve veća se važnost pridaje primjeni umjetne inteligencije u području ekološkog inženjerstva i upravljanja vodnim resursima. Izrađeno je i nekoliko studija koje su razvile metode bazirane na umjetnoj inteligenciji, a u svrhu modeliranja procesa s ograničenim brojem poznatih parametara [3-6]. U radu su prikazane neke pouzdane tehnike, bazirane na odgovarajućoj literaturi, za modeliranje vodnih resursa i lebdećeg riječnog nanosa kao što su valični postupak, umjetna neuronska mreža (ANN) i metode potpornih vektora (eng. *support vector machines* - SVM).

Sposobnost umjetnih neuronskih mreža (ANN) da pronađu nelinearne odnose između ulaznih i izlaznih podataka pokazuje nam da su te mreže itekako pogodne za modeliranje hidrauličkih i hidroloških pojava [7]. Simulacije pomoću ANN-a sve više se koriste u mnogim državama, a nedavno je ustanovljeno da se mogu koristiti i za modeliranje vremenskih serija. Valično transformirani podaci promatranih vremenskih serija povećavaju sposobnost predviđanja registriranjem vrijednih informacija na raznim razinama rezolucije [8]. Uspoređuje se i ponašanje višeslojne neuronske mreže usmjerene prema naprijed (eng. *multi layer feed forward* - MLFF) i mreže s radijalnim funkcijama (eng. *radial basis function* - RBF) u pogledu predviđanja pronosa lebdećeg nanosa [9]. U mnogim se radovima istražuje primjena ANN-a za predviđanje pronosa lebdećeg nanosa [10, 11]. Sljedeći su modeli korišteni na dvije vlagomjerne stanice u svrhu simuliranja pronosa SS za idući dan: ANN, višeznačajna neuronska metoda (eng. *neuro-fuzzy* - NF), višeslojna regresija (eng. *multi layer regression* - MLR) i funkcija pronosa nanosa (eng. *sediment rating curve* - SRC). Uspoređivanjem rezultata modeliranja ustanovljeno je da je model NF pogodniji za predviđanje SS-a [12]. Model ANN predlaže se za simuliranje mjesečnih vrijednosti pronosa sedimenata u Kini [9]. U spomenutom se modelu protok lebdećeg nanosa povezuje s temperaturom, prosječnom količinom padalina, intenzitetom padalina te protokom. Rezultati pokazuju da se model ANN može koristiti za simulaciju mjesečnog pronosa lebdećeg nanosa [13].

Drugi istraživači definirali su model kombiniranjem valične transformacije i višeznačajne neuronske metode (NF) u svrhu predviđanja dnevnog transporta lebdećeg nanosa [14]. Pristup ANN korišten je za modeliranje koncentracije SS-a na dvije lokacije duž rijeke Mississippi. Dobiveni rezultati pokazuju da je tehnika ANN prikladnija od tradicionalnih metoda [15].

Novi model valične neuronske mreže korišten je za dnevna predviđanja SS-a u rijeci Yadkin na stanici kod Yandkinskog koledža u SAD-u. Valična je transformacija povezana s umjetnom neuronskom mrežom (ANN). Usporedbom točnosti predviđanja valične neuronske mreže (eng. *wavelet artificial neural network* - WANN) i ostalih modela ustanovljeno je da je predloženi model WANN pogodan za kvalitetno predviđanje SS-a. Najbolji su rezultati postignuti Meyerovom valičnom metodom s vrijednošću determinacijskog koeficijenta od 0,83 [16]. Kombinirani neuronski-valični model predložen je za predviđanje padalina na slivu Ligvanchai na lokalitetu Tabriz u Iranu. Glavna vremenska serija podijeljena je na nekoliko višefrekvencijskih vremenskih serija primjenom valične metode, nakon čega su vrijednosti unesene u model ANN radi predviđanja količine padalina mjesec dana unaprijed [17]. Za predviđanja vrijednosti SS predlaže se kombinirani ANN-valični model. Podaci o dnevnom protoku i vrijednostima SS registrirani na rijeci Iowa u SAD-u korišteni su za učenje i testiranje modela ANN, WANN, MLR i SRC. Na temelju dobivenih rezultata ustanovljeno je da je model WANN pogodniji od ostalih modela [18].

Odnos između vrijednosti SS i protoka određen je genetičkim algoritmom (GA). Taj se model pokazao boljim od modela SRC [19]. U drugom se istraživanju naglašava korisnost valične analize i sposobnosti tog alata za analizu vremenskih serija u kraškim hidrološkim sustavima [20]. Valična analiza i NF korišteni su za predviđanje dnevnih vrijednosti SS-a [21]. Metoda SVM je tehnika nadziranog učenja kojom se iz seta podataka za učenje dobivaju ulazno-izlazne funkcije [22]. Pri poučavanju pomoću metode potpornih vektora, granice odluka izravno se određuju iz podataka za učenje. Ova strategija učenja bazira se na statističkoj teoriji učenja, a pomoću nje se na minimum svode greške klasificiranja podataka za učenje i nepoznatih podataka [23]. Metoda SVM primjenjuje se i za predviđanje koncentracije klorofila u akumulacijama [24]. Istražuje se i pogodnost modela WSVR za predviđanje mjesečnih protoka i dnevnih padalina. Ti su modeli razvijeni povezivanjem dviju tehnika, diskretne valične analize i regresije s potpornim vektorima. Usporedbom rezultata ustanovljeno je da se primjenom metode WSVR poboljšava učinak modela [25, 26]. SVM se koristi kao sredstvo za predviđanje obrazaca ponašanja, a u svrhu simuliranja dnevnog, tjednog i mjesečnog otjecanja i transporta nanosa sa sliva u Indiji [27]. Istražuju se dvije metode za prethodnu obradu ulaznih varijabli za model SVM: analiza osnovnih komponenata i gama-ispitivanje (eng. *gamma test* GT). Predloženim se metodama dobivaju točniji rezultati za potrebe predviđanja mjesečnog protoka [28]. U zasebnom predviđanju podataka o nanosima u uzvodnim i

nizvodnim stanicama, metode potpornih vektora najmanjih kvadrata (eng. *least square support vector machine* - LSSVM) uspoređuje se s umjetnim neuronskim mrežama (ANN) i s krivuljom za ocjenjivanje sedimenta. Usporedbom modela ustanovljeno je da je model LSSVM učinkovitiji od modela ANN [29].

Modeli umjetne neuronske mreže i metode potpornih vektora korišteni su za predviđanje koncentracije lebdećeg nanosa u slivu rijeke Doiraj koja se nalazi u zapadnom dijelu Irana. Podaci o toku i padalinama korišteni su kao ulazne varijable te pri određivanju dužine niza podataka za učenje. Ustanovljeno je da se najbolja ulazna kombinacija ovih modela dobiva primjenom GT-a [30].

Metoda genetskog programiranja (GP) korištena je za određivanje dnevne količine SS-a u dvije stanice smještene na rijeci Cumberland u SAD-u. Rezultati pokazuju da je metoda GP prihvatljivija od drugih modela [31].

Ta nam istraživanja pokazuju da je valična analiza djelotvorna za određivanje višeskalnih svojstava klimatskih elemenata nepravilno razmještenih u prostoru i vremenu. Valična analiza kombinira se s tehnikom SVM kako bi se povećala točnost u predviđanju SS-a.

## 2. Metoda potpornih vektora (SVM)

U posljednjih desetak godina u području umjetne inteligencije razvijene su nove tehnike koje se mogu primijeniti u velikom broju područja. Jedna od njih je i metoda potpornih vektora (SVM) koja se koristi za klasificiranje i podjelu regresijskih algoritama. Regresije potpornih vektora, koje su dopuna metode potpornih vektora, iskazuju dobra svojstva generaliziranja kod rješavanja raznih problema aproksimacije funkcija i predviđanja vremenskih serija [23]. Do sada su obavljena brojna istraživanja o teoriji SVM-a [32-35]. Zbog toga se ovdje daje samo kratko objašnjenje modela  $\varepsilon$ -SVM. Pretpostavimo da smo dobili set podataka za učenje  $\{(x_1, y_1), \dots, (x_r, y_r)\} \subset X \times R$ , pri čemu  $x$  i  $y$  označavaju prostor ulaznih obrazaca ponašanja i ciljnih vrijednosti. Cilj SVM analize je pronaći funkciju  $f(x)$  koja ima najveće odstupanje  $\varepsilon$  od stvarnih ciljnih vrijednosti  $y_i$  za svaki set podataka za učenje, pri čemu bi ona trebala biti što je moguće ravnija. U ovom se radu obavlja regresija  $\varepsilon$ -SVM u svrhu predviđanja vrijednosti SS za sljedeći dan [36]. Drugim riječima, greške se ne razmatraju sve dok su manje od  $\varepsilon$ , ali se ne prihvaćaju odstupanja veća od  $\varepsilon$ . Linearne funkcije  $f(x)$  opisuju se kako slijedi:

$$f(x) = \langle w, x \rangle + b, \quad w \in X, b \in R \quad (1)$$

gdje  $\langle w, x \rangle$  označava skalarni umnožak u  $X$ . U slučaju jednadžbe (1) ravnost znači da se traži mala vrijednost  $w$ . Jedan od postupaka za dobivanje  $w$  jest svodenje norme na minimum, tj.  $\|w\|^2 = \langle w, w \rangle$ . Ovaj se problem može izraziti i kao problem konveksne optimalizacije:

$$\begin{aligned} & \text{minimalizirati } \frac{1}{2} \|w\|^2 + c \sum_{i=1}^l (\xi_i + \xi_i^*) \\ & \text{uz uvjete } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{cases} \end{aligned} \quad (2)$$

U jednadžbi (2) se pretpostavlja da takva funkcija  $f(x)$  kojom se aproksimiraju svi parovi  $(x_i, y_i)$ , s točnošću  $\varepsilon$  stvarno postoji, te da se problem konveksne optimalizacije može riješiti. U nekim slučajevima to nije moguće, ili se mora prihvatiti mogućnost pogrešaka. Da bi se razriješla inače nerješiva ograničenja u problemima optimalizacije, postoji mogućnost uvođenja dopunskih varijabli  $\xi_i, \xi_i^*$ , vidi jednadžbu 3. Tada se izraz može prikazati kako slijedi:

$$\begin{aligned} & \text{minimalizirati } \frac{1}{2} \|w\|^2 + c \sum_{i=1}^l (\xi_i + \xi_i^*) \\ & \text{uz uvjete } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (3)$$

Konstanta  $C > 0$  određuje kompromis između ravnosti  $f(x)$  i iznosa do kojeg se mogu tolerirati odstupanja veća od  $\varepsilon$ . To odgovara situaciji s takozvanom funkcijom gubitka neosjetljivosti  $|\xi|_\varepsilon$  koja se u jednadžbi (4) opisuje kako slijedi:

$$|\xi|_\varepsilon = \begin{cases} 0 & \text{ako je } |\xi| < \varepsilon \\ |\xi| - \varepsilon & \text{ina e} \end{cases} \quad (4)$$

Problem optimalizacije iz jednadžbe (3) može se riješiti njegovom dvojnomo formulacijom. Osnovni plan sastoji se u formuliranju Lagrangeove funkcije iz primarne funkcije i odgovarajućih ograničenja, i to uvođenjem dvojnog niza varijabli. Tada se rješenje nalazi u sedlastoj točki u odnosu na osnovne i dvojne varijable. Ova se funkcija iskazuje pomoću sljedećih izraza:

$$\begin{aligned} L := & \frac{1}{2} \|w\|^2 + c \sum_{i=1}^l (\xi_i + \xi_i^*) - c \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \\ & - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) \\ & - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b) \end{aligned} \quad (5)$$

Ovdje  $L$  znači "Lagrangeov", a  $\eta_i, \eta_i^*, \alpha_i, \alpha_i^*$  su faktori Lagrangeovih multiplikatora. Stoga u jednadžbi (6) dvojne varijable trebaju uzeti u obzir ograničenja.

$$\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0 \quad (6)$$

Iz uvjeta sedlaste točke proizlazi da se parcijalne derivacije  $L$  u odnosu na osnovne varijable  $(w, b, \xi_i, \xi_i^*)$  trebaju izjednačiti s nulom radi optimalnosti.

$$\frac{\partial L}{\partial b} = \sum_{i=1}^I (\alpha_i^* - \alpha_i) = 0$$

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^I (\alpha_i^* - \alpha_i) x_i = 0 \tag{7}$$

$$\frac{\partial L}{\partial \xi_i^*} = C - (\alpha_i^* - \eta_i^*) = 0$$

Zamjenom jednadžbe (5) s jednadžbom (7) dobivamo problem dvojne optimalizacije, a eliminiiraju se dvojne varijable. Jednadžbom (8) formulira se sljedeće:

$$w = \sum_{i=1}^I (\alpha_i - \alpha_i^*) x_i, \text{ tako da je } f(x) = \sum_{i=1}^I (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \tag{8}$$

Ovo je takozvana ekspanzija potpornog vektora. Vrijednost  $w$  može se objasniti kao linearni algoritam koji ovisi samo o skalarnim umnošcima između uzoraka za učenje  $w$ . Linearni model nije pogodan za mnoge hidrološke događaje. Međutim on može postati pogodan nakon što se jezgra prilagodi za unošenje podataka u prostor s više dimenzija, nakon čega se primjenjuje standardni regresijski algoritam s potpornim vektorima. Takve interpretacije prikladne su za formuliranje nelinearnog proširenja. To se može napraviti prethodnom obradom obrazaca učenja  $x_i$  pomoću preslikavanja  $\varphi: x \rightarrow \mathfrak{Z}$  u neki prostor značajki  $\mathfrak{Z}$ . Dakle, dovoljno je prepoznati jezgrenu funkciju  $k(x, x_i) := \langle \varphi(x), \varphi(x_i) \rangle$  umjesto eksplicitnog definiranja vrijednosti  $\varphi$ . Jezgrena funkcija omogućava korištenje nelinearne funkcije u ulaznom prostoru na način da postaje linearna funkcija u prostoru značenjki. Jezgrena funkcija ostvaruje eksplicitnu korist od netretiranog visoko-dimenzionalnog prostora značajki. Ovaj se postupak naziva "jezgrenim trikom" a može se prikazati na sljedeći način [22, 30, 36, 37]:

$$f(x) = \sum_{i=1}^I (\alpha_i - \alpha_i^*) k(x, x_i) + b \tag{9}$$

U tablici 1. prikazana je standardna konverzija jezgrene funkcije koja se najčešće koristi u regresiji i modeliranju [22].

Tablica 1. Jezgrena funkcija koja se najčešće koristi u regresiji i modeliranju

Jezgrene funkcije	Vrsta klasifikatora
$k(x, x_i) = (x^T x_i)$	linearni, skalarni umnožak, jezgra, CPD
$k(x, x_i) = \left[ (x^T x_i) + 1 \right]^d$	kompletni polinom stupnja d, PD
$k(x, x_i) = e^{-\gamma \ x - x_i\ ^2}$	Gaussov RBF, PD
$k(x, x_i) = \tanh \left[ (x^T x_i) + b \right]^*$	Višeslojni perceptron, CPD
$k(x, x_i) = \frac{1}{\sqrt{\ x - x_i\ ^2 + \beta}}$	Inverzna multikvadratna funkcija, PD

\* samo za neke vrijednosti b, (C) PD= (uvjetno) pozitivno konačno

Radikalna temeljna funkcija (RBF) tj. funkcija bazirana na radikalnoj temeljnoj funkciji sličnija Gaussovoj (zvonastog oblika), prikazana u tablici 1. kao funkcija ovisna o varijabli  $\gamma$ , uzima se u obzir u ovom radu zbog sljedećih razloga:

1. Za razliku od linearne jezgre, ona se može koristiti kada je odnos između oznaka klase i atributa nelinearan.
2. Ova jezgrena funkcija ima manji broj hiperparametara koji kontroliraju složenost odabira modela.
3. Ona ima manji broj numeričkih složenosti [38, 39].

### 3. Valična transformacija

#### 3.1. Kontinuirana valična transformacija (CWT)

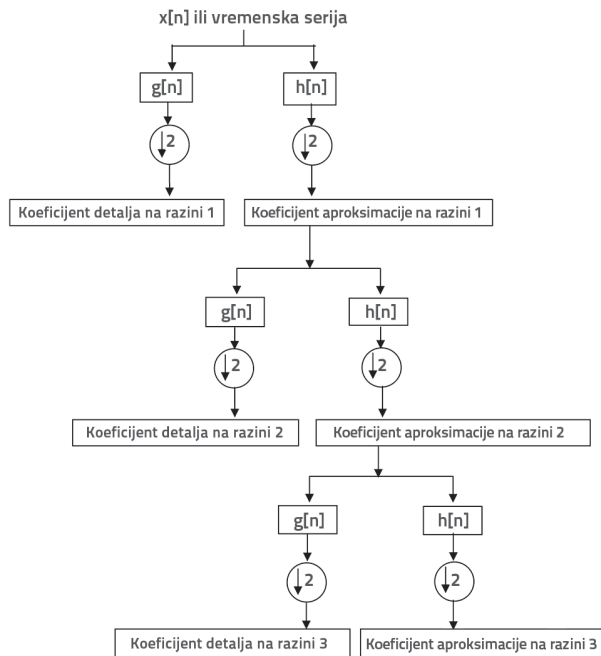
Teorija valične analize temelji se na Fourierovoj analizi [40]. Valična je dekompozicija savršena za razmatranje privremenih signala i za dobivanje kvalitetne karakterizacije i pouzdanije metode razlučivanja [41]. Signal se množi s funkcijom koja je bliska prozorskoj funkciji, a transformacija se izračunava za razne segmente signala iz vremenske domene. Kontinuirana valična transformacija opisuje se kako slijedi:

$$CWT_x^\psi(\tau, s) = \psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi\left(\frac{t-\tau}{s}\right) ds \tag{10}$$

Valična transformacija ovisi o dva parametra: translaciji ( $\tau$ ) i skali ( $s$ ).  $\Psi(\tau)$  je osnovni valič. Izraz valič označava mali val. Malenost podrazumijeva stanje u kojem je prozorska funkcija kompaktno pridržana. Riječ translacija odnosi se na položaj prozora, jer se prozor mijenja od početka do kraja signala. Parametar skale ( $s$ ) definira se kao  $s = 1 / \text{frekvencija}$  [42].

#### 3.2. Diskretna valična transformacija (DWT)

Koncept DWT-a sličan je konceptu kontinuirane valične transformacije (CWT). Predstavljanje digitalnog signala na vremenskoj skali postiže se pomoću metoda digitalnih filtera. CWT je korelacija između valiča na raznim skalama i signala sa skalom (ili frekvencijom) koja se koristi za mjerenje sličnosti. U diskretnom slučaju, filteri različitih graničnih frekvencija koriste se za analiziranje signala u različitim skalama. Signal se propušta kroz seriju visokopropusnih filtera za analizu visokih frekvencija, te prolazi kroz seriju niskopropusnih filtera radi analize niskih frekvencija. Smanjivanjem razlučivosti pomoću faktora  $n$  smanjuje se broj uzoraka u signalu za  $n$  puta. Povećanjem razlučivosti signala povećava se brzina uzimanja uzoraka signala tako da se signalu dodaju novi uzorci. Kako je signal diskretna vremenska funkcija, izrazi funkcija i slijed koristit će se kao izrazi istog značenja. Ovaj slijed označava se kao  $x[n]$ , gdje je  $n$  cijeli broj. Postupak počinje s propuštanjem signala kroz polupojasni niskopropusni filter s impulsnim odzivom  $h[n]$ . Filtriranje signala povezano je s numeričkom operacijom konvolucije signala s impulsnim odzivom filtra.



Slika 1. Razlaganje početnog signala s niskopropusnim i visokopropusnim filtrima

Jednadžba je definirana kako slijedi:

$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k]h[n-k] \tag{11}$$

Prolazom kroz polupojasni niskopropusni filter eliminišu se sve frekvencije koje su više od polovice najviše frekvencije u signalu. Prolazom kroz niskopropusni filter razlučivost se smanjuje za polovicu ali skala ostaje nepromijenjena. Signalu se zatim razlučivost smanjuje za 2 jer jedna polovica uzoraka postaje nepotrebna. Takvim se postupcima udvostručuje mjerilo što se može izraziti na sljedeći način:

$$y[n] = \sum_{k=-\infty}^{\infty} h[k]x[2n-k] \tag{12}$$

Diskretnom valičnom transformacijom (DWT) signal se pretvara u aproksimaciju i detaljnu informaciju. Početni signal primarno prolazi kroz polupojasni visokopropusni filter  $g[n]$  i kroz niskopropusni filter  $h[n]$ . Te se jednadžbe mogu izraziti na sljedeći način:

$$y_{high}[k] = \sum_n x[n]g[2k-n] \tag{13}$$

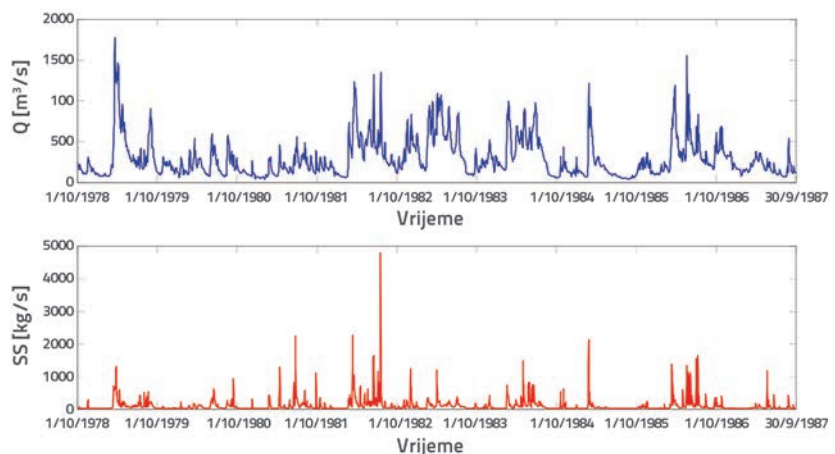
$$y_{low}[k] = \sum_n x[n]h[2k-n] \tag{14}$$

gdje su  $y_{high}[k]$  i  $y_{low}[k]$  izlazne vrijednosti kod visokopropusnih i niskopropusnih filtera nakon smanjenja razlučivosti za 2. Prethodni sustav koji se može označiti kao potpojasno razlaganje može se ponoviti radi dodatne dekompozicije. Metoda je prikazana na slici 1. gdje je  $x[n]$  originalni signal, dok su  $h[n]$  i  $g[n]$  niskopropusni tj. visokopropusni filteri. Dekompozicija (razlaganje) početnog signala na tri razine prikazana je kako slijedi [43]:

#### 4. Mjerna stanica i statistička analiza podataka

Za učenje i testiranje modela korišteni su podaci koji su prikupljeni u razdoblju od devet godina (tj. od 1.10.1978. do 30.9.1987.) na rijeci Iowa u Wapellou, mjerna stanica NC (stanica USGS br. 05465500, površina bazena (u kvadratnim miljama): 12.499, geografska dužina: 091°10'57" i geografska širina 41°10'48"), kojom upravlja uprava SAD-a za geološka istraživanja, USGS. Za modeliranje su bile potrebne neprekinute vremenske serije kao što su Q i SS. Za nizove podataka za učenje i provjeru korišteni su podaci prikupljeni u razdoblju od 1. listopada 1978. do 30. rujna 1985. (sedam godina) te od 1. listopada 1985. do 30. rujna 1987. (dvije godine). Vremenske serije podataka za dnevne vrijednosti Q i SS prikazane su na slici 2.

Statistički parametri za protok (Q) i lebdeći nanos (SS), kao što su maksimum, minimum, srednja vrijednost, prosječna



Slika 2. Devetogodišnje vremenske serije protoka (Q) i lebdećeg nanosa (SS)

Tablica 2. Statistički parametri za protok rijeke i kretanje lebdećeg nanosa

Niz podataka	Razdoblje	Maksimum	Minimum	Srednja vrijednost	Standardno odstupanje
Lebdeći nanos SS [kg/s]	Učenje	4780	0,06	96,65	206,94
	Testiranje	1631,94	0,85	86,91	181,65
	Sve	4780	0,06	94,49	201,6
Protok Q [m <sup>3</sup> /s]	Učenje	1770	39,6	292,78	247,11
	Testiranje	1550	64,3	274,32	194,90
	Sve	1770	39,6	288,69	236,62

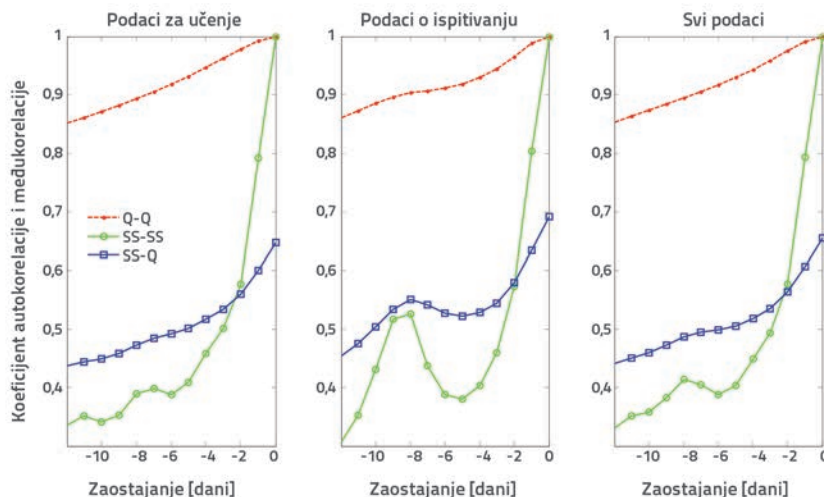


vrijednost i standardno odstupanje (SD), iskazani su u tablici 2. Iz te se tablice vidi da su vrijednosti protoka (Q) i lebdećeg nanosa (SS) široko raspoređene. U razdoblju ispitivanja također su korištene i maksimalne eksperimentalne vrijednosti Q i SS. Tim su statističkim parametrima detaljno obuhvaćeni trendovi protoka i kretanja lebdećeg nanosa.

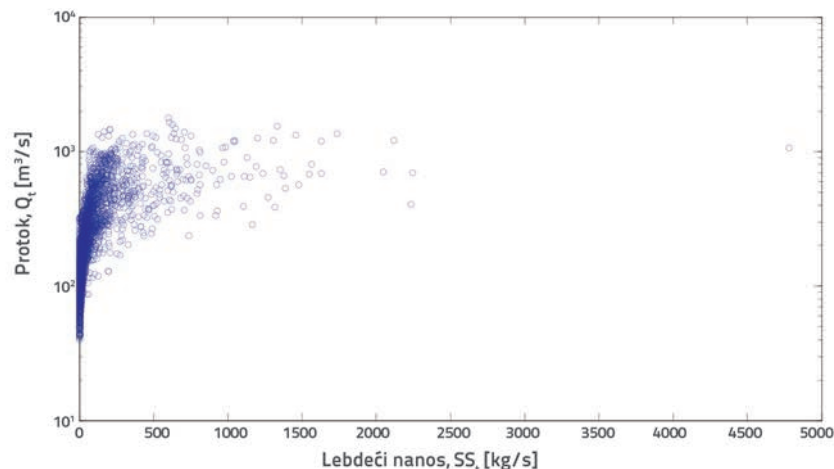
Odabir odgovarajuće kombinacije ulaznih faktora prije samog procesa smatra se jednim od složenijih postupaka u procesu modeliranja. Ispitivane su autokorelacije i međukorelacije vrijednosti Q i SS u svrhu predviđanja dnevne vrijednosti SS. Ovaj postupak je korišten u nekoliko radova [14, 16, 18, 21, 26, 29, 30]. Slika 3. prikazuje koeficijente međukorelacije između promatranih  $SS_t$  i vremenskih serija protoka ( $Q_t, Q_{t-1}, Q_{t-2}, \dots, Q_{t-10}$ ) te koeficijente autokorelacije, kao što su koeficijent autokorelacije sa zakašnjenjem od jednog dana ( $R_1$ ), koeficijent autokorelacije sa zakašnjenjem od dva dana ( $R_2$ ), koeficijent autokorelacije sa zakašnjenjem od tri dana ( $R_3$ ) te koeficijent autokorelacije s pomakom od deset dana ( $R_{10}$ ). Iz slike se može vidjeti da su koeficijenti autokorelacije protoka rijeke veći od koeficijenata autokorelacije za lebdeći nanos, i to kako u nizovima za učenje tako i u nizovima za testiranje. Autokorelacija između  $SS_t$  i  $SS_{t-4, t-5, t-6, \dots}$  prilično je niska, kao i kod koeficijenata međukorelacije između  $SS_t$  i  $Q_{t-4, t-5, t-6, \dots}$ .

Stoga su ispitani modeli u kojima su ulazni podaci bile vrijednosti SS i Q za tri prethodna dana. Kao ulazni podaci usvojene su različite vremenske serije protoka i SS koje su uključivale najviše tri vremenska koraka u prošlost. Podaci s mjernih stanica, iskazani u obliku dijagrama razmještaja, prikazani su na slici 4. Može se uočiti nelinearan i složen odnos između protoka rijeke i transporta lebdećeg nanosa. Na ovoj se slici uočava i postojanje netipične vrijednosti u rasponu podataka. Registrirana je koncentracija SS u iznosu od 4780 kg/s, dok su druge vrijednosti koncentracije bile niže od 2245,37 kg/s. Te su vrijednosti dobivene dodatnim složenim proračunima na modelima.

Razmatrana je mogućnost primjene nekoliko tradicionalnih metoda kao što su koeficijent determinacije ( $R^2$ ), suma kvadrata pogreške (eng. *sum of square error* - SSE) i korijen srednje kvadratne pogreške (eng. *root mean square error* - RMSE) [44, 45]. U ovoj je studiji učinkovitost modela provjerena pomoću metoda  $R^2$ , RMSE, srednje greške i greške standardnog odstupanja (eng. *error standard deviation* - Error STD). Te su jednadžbe opisane kako slijedi:



Slika 3. Autokorelacija za Q i SS, međukorelacija SS i Q



Slika 4. Dijagram razmještaja vrijednosti  $SS_t, Q_t$ .

$$Error_i = SS_{i(measured)} - SS_{i(predicted)} \tag{15}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Error_i)^2}{\sum_{i=1}^n (SS_{i(measured)} - SS_{i(mean)})^2} \tag{16}$$

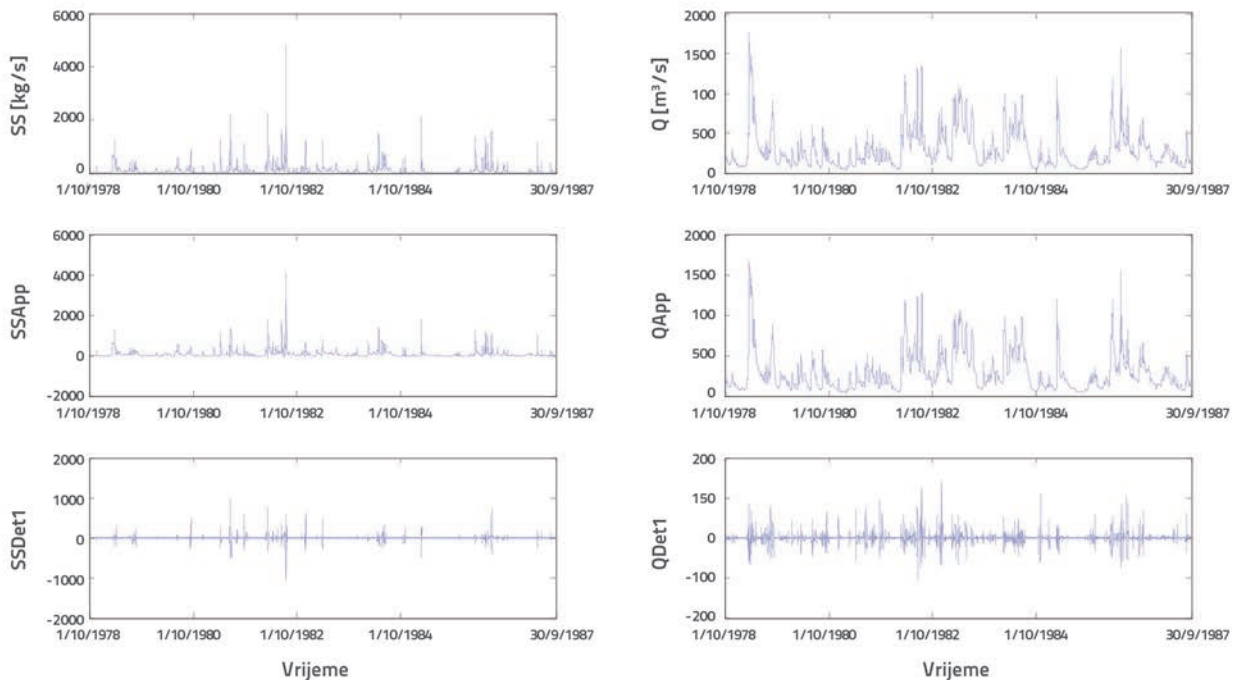
$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Error_i)^2}{n}}$$

$$ErrorSTD = \sqrt{\frac{\sum_{i=1}^n (Error_i - Error_{i(mean)})^2}{n}} \tag{17}$$

pri čemu  $n$  predstavlja broj podataka.

### 5. Primjena i rezultati

Vremenske serije lebdećeg nanosa i protoka raspoređene su (valičnom analizom) u nekoliko višefrekvencijskih vremenskih serija detalja (različite razine razlučivosti) i aproksimacija. One su povezane s metodom SVM gdje su korištene kao ulazni podaci za vrijednosti SS sljedećeg dana. Broj čvorova u ulaznom sloju iznosi  $(\#1) \times 2$  jer se u kombinacijskoj metodi WSVM primjenjuju dvije varijable (transport lebdećeg nanosa



Slika 5. Detaljni podsignali i aproksimacija valića sym3 (prva razina)

i protok rijeke). Svaka vremenska serija podijeljena je na vremenske serije s detaljima  $i, i = (1, 2, 3)$  i na jednu vremensku seriju s aproksimacijom. Valičnom se metodom mogu istovremeno podijeliti svojstva vremenske serije SS na razne skale valične transformacije. Drugačiji osnovni valiće podijeljen je na Q i SS, na raznim razinama, od 1 do 3. Ustanovljeno je da je valiće najučinkovitiji s tim podacima, tj. s podjelom na jednoj razini za signale SS i Q što dovodi do dva podsignala pomoću sym3. Detalji o podsignalima prikazani su na slici 5.

Na ovoj su slici SSApp i QApp valićni koeficijenti za SS i Q u postupku aproksimacije, dok su SSDet1, QDet1 valićni koeficijenti za SS i Q u detaljnom postupku na razini 1. Vremenske serije SS i Q podijeljene su na raznim razinama pomoću valične analize te su primijenjene kao ulazni podaci u metodi SVM za predviđanje vrijednosti SS sljedećeg dana. U toj je podjeli u obzir uzeto periodičko svojstvo SS nanosa. Podsignal svaki put preuzima različitu funkciju u početnoj vremenskoj seriji, i ponašanje svakog signala je različito. U studiji se provjeravaju različite kombinacije Q i SS s najviše tri vremenska koraka u prošlost, kao ulazni podaci za modele. Ispitane su sljedeće ulazne kombinacije:

1.  $Q_{t-1}, Q_{t-2}, Q_{t-3}, SS_{t-1}, SS_{t-2}, SS_{t-3}$
2.  $Q_{t-1}, Q_{t-2}, SS_{t-1}, SS_{t-2}$
3.  $Q_{t-1}, SS_{t-1}$
4.  $SS_{t-1}, SS_{t-2}$
5.  $Q_{t-1}, SS_{t-1}, SS_{t-2}$

Optimalni parametri modela SVM definirani su minimaliziranjem objektivne pogreške (RMSE) i to uspoređivanjem izračunanih i registriranih vrijednosti SS u razdoblju ispitivanja za svaku ulaznu kombinaciju. Prilikom

analize pomoću SVM-a, vrijednosti  $C$  i  $\varepsilon$  bili su parametri čija se vrijednost trebala odrediti. U stvari, ako se ne pazi pri odabiru parametara, rezultirajući regresijski model mogao bi imati puno grešaka u predviđanju budućih vrijednosti [46]. U alatu za odabir parametara pretpostavlja se korištenje RBE (Gaussove) jezgre iako se lako može napraviti i proširenje na druge jezgre i SVR. Vrijednosti  $C, \varepsilon$  i  $\gamma$  bile su potrebne za izradu modela  $\varepsilon$ -SVM na bazi podataka dobivenih učenjem, a korištena je jezgrena funkcija RBF [47]. Izraz  $\gamma$  koji se spominje u tablici 1. bio je značajan u modelu RBF, i mogao je dovesti do prevelikog ili nedovoljnog podudaranja tijekom predviđanja [48].

U ovom istraživanju zadana vrijednost parametra  $\gamma$  jednaka je  $1/\text{num-svojstvu}$  u računalnom programu LIBSVM. Za parametre  $C$  i  $\varepsilon$  postavljeno je nekoliko vrijednosti, te su razvijeni razni SVM modeli. Optimalni parametri za svaku kombinaciju u modelu WSVM prema Symlet (Sym3) valiće prikazani su u tablici 3., a kao optimalan odabran je parametar koji se odlikuje najmanjom greškom RMSE, najmanjom srednjom greškom i greškom standardnog odstupanja te s najvećom vrijednošću  $R^2$  u razdoblju ispitivanja. Prije primjene WSVM modela, ulazne i izlazne vrijednosti seta podataka za učenje su normalizirani pomoću logaritamske funkcije.

Prema ovoj tablici 3., WSVM model iskazuje kriterije najbolje učinkovitosti za kombinaciju  $2 Q_{t-1}, Q_{t-2}, SS_{t-1}, SS_{t-2}$ . Iz tablice je jasno vidljivo da minimalni RMSE iznosi 70,8 kg/s, dok je najviša vrijednost  $R^2$  od 0,847 dobivena kad su odabrane vrijednosti  $C = 6$  i  $\varepsilon = 0,07$ . Da bi se okarakterizirala periodička svojstva, promatrane vremenske serije Q i SS podijeljene su na nekoliko multifrekvencijskih vremenskih serija pomoću valične transformacije. Svaki je podsignal

Tablica 3. Ocjena učinkovitosti WSVM-a u predviđanju vrijednosti SS u razdoblju ispitivanja

Kombinacija	1	2	3	4	5
C	1	6	3	2	1
$\epsilon$	0,001	0,07	0,2	0,001	0,001
R <sup>2</sup>	0,765	0,847	0,735	0,821	0,83
RMSE [kg/s]	87,86	70,83	93,34	76,66	74,66
Srednja greška [kg/s]	5,51	2,15	6,09	2,42	2,53
STD greška [kg/s]	87,74	70,86	93,21	76,68	74,67

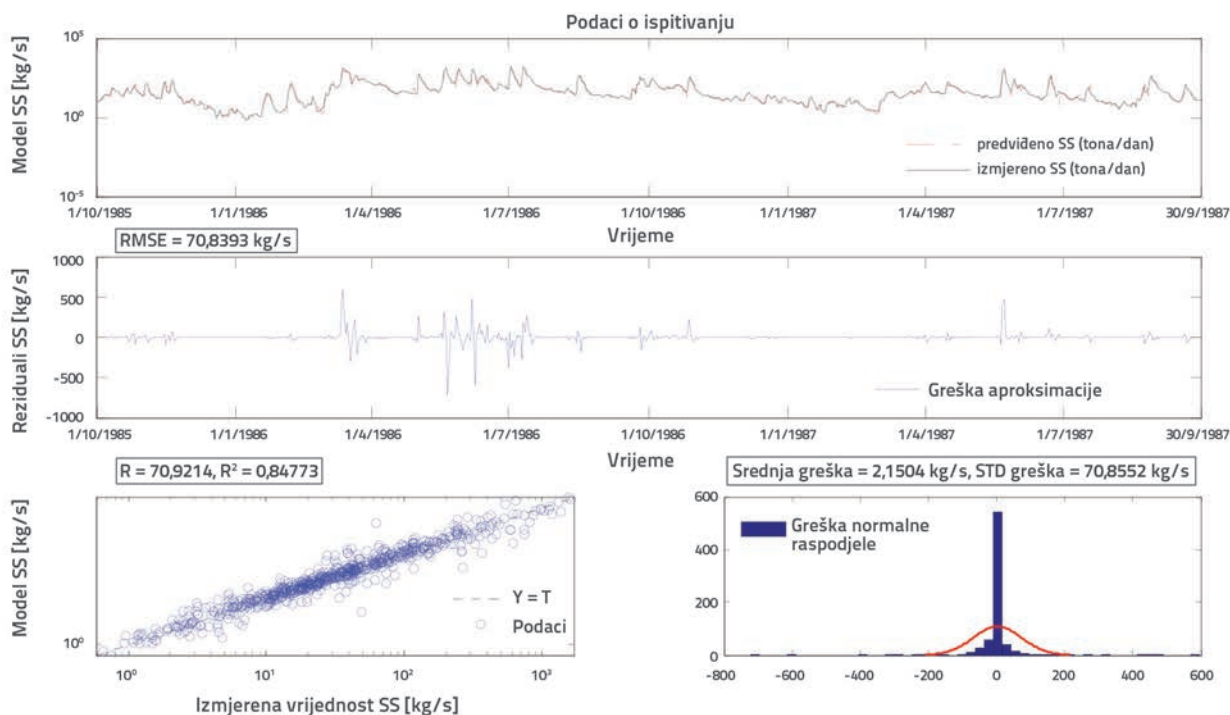
Tablica 4. Ocjena učinkovitosti SVM-a u predviđanju vrijednosti SS u razdoblju ispitivanja

Kombinacija	1	2	3	4	5
C	1	2	1	2	1
$\epsilon$	0,001	0,001	0,001	0,3	0,01
R <sup>2</sup>	0,678	0,636	0,588	0,674	0,61
RMSE [kg/s]	102,96	109,38	116,5	103,52	109,34
Srednja greška [kg/s]	11,67	9,26	14,83	8,9	10,02
STD greška [kg/s]	102,37	109,06	115,63	103,21	108,95

sudjelovao s različitim i zasebnim ponašanjem u prvobitnim vremenskim serijama. Te su vremenske serije definirane kao ulazni podaci za predviđanje vrijednosti SS za sljedeći dan tehnikom SVM. Rezultati dobiveni primjenom modela WSVM pokazuju da se učinkovitost povećava kada se razine dekompozicije vremenskih serija protoka rijeke i transporta lebdećeg nanosa smatraju jednakima, a učinkovitost

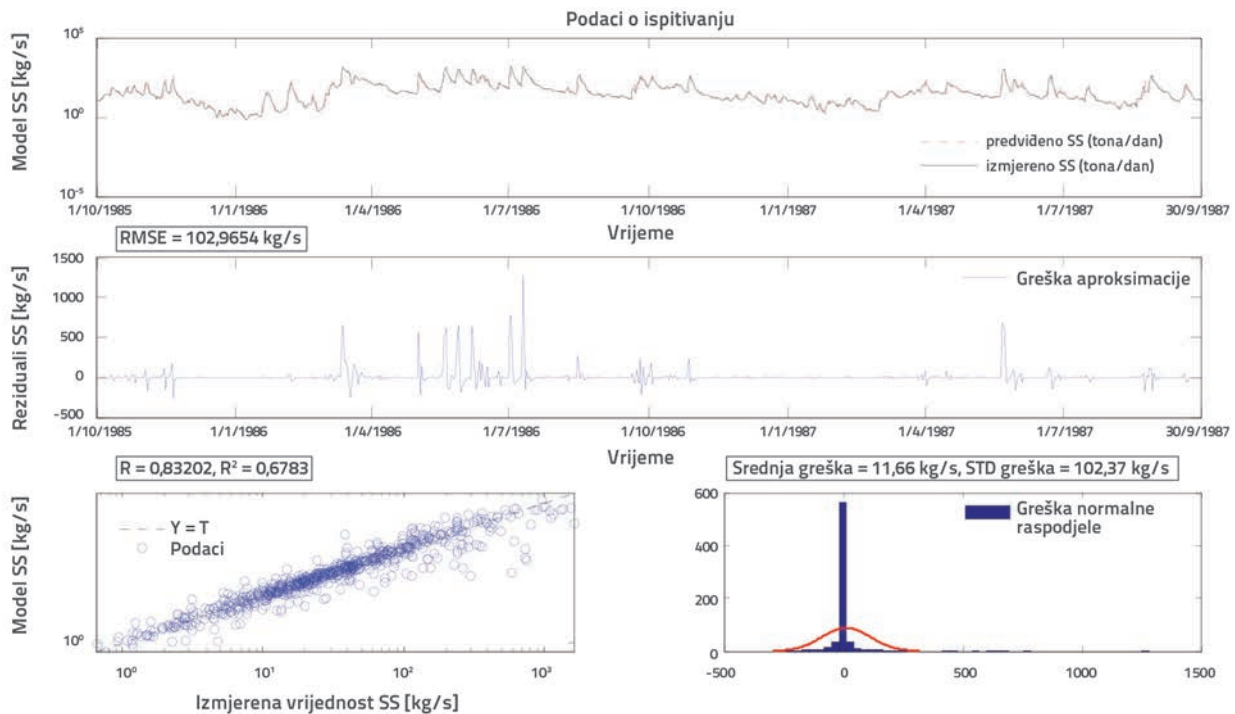
modela se smanjuje povećanjem razine dekompozicije na razine veće od 1. Ovo je ispitivanje obavljeno kako bi se odredili utjecaji osnovne valične funkcije i razine dekompozicije na učinkovitost projektiranog modela WSVM. Dakle, vremenske serije Q i SS podijeljene su na jednu, dvije i tri razine pomoću šest različitih vrsta valičnih transformacija: Daubechies-2 (db2) valič, Haar valič, Bioortogonalni valič (Bior1.1), Coif1 valič i Symlet valiči (Sym2, Sym3). Najbolji su rezultati postignuti valičem Sym3, pa je on i odabran. Optimalni parametri za svaku kombinaciju modela SVM prikazani su u tablici 4. Na ovoj stanici, najbolji kriteriji postignuti su modelom SVM za kombinaciju 1, a odgovarajuće vrijednosti RMSE i R<sup>2</sup> iznosile su za taj model 102,96 kg/s, tj. 0,678 u razdoblju ispitivanja.

U usporedbi s najboljim modelom SVM, optimalni model WSVM ima veću vrijednost R<sup>2</sup> (za gotovo 20 %), dok je vrijednost RMSE manja za 31,2 %. Da bi se vizualno iskazali gore navedeni rezultati, na slikama 6. i 7. prikazane su semilog vremenske serije izmjerenih i predviđenih vrijednosti SS te reziduali grešaka i to primjenom modela SVM i WSVM za razdoblje ispitivanja. Također su prikazani i logaritamski dijagrami razmjesta registriranih i procijenjenih vrijednosti SS i normalne raspodjele pogrešaka.



Slika 6. Semilog vremenske serije i log dijagrami razmjesta izmjerenih i predviđenih vrijednosti SS, reziduali i normalna raspodjela grešaka dobiveni u razdoblju ispitivanja pomoću najboljeg modela WSVM





Slika 7. Semilog vremenske serije i log dijagrami razmještaja izmjerenih i predviđenih vrijednosti SS, reziduali i normalna raspodjela grešaka dobiveni u razdoblju ispitivanja pomoću najboljeg modela SVM

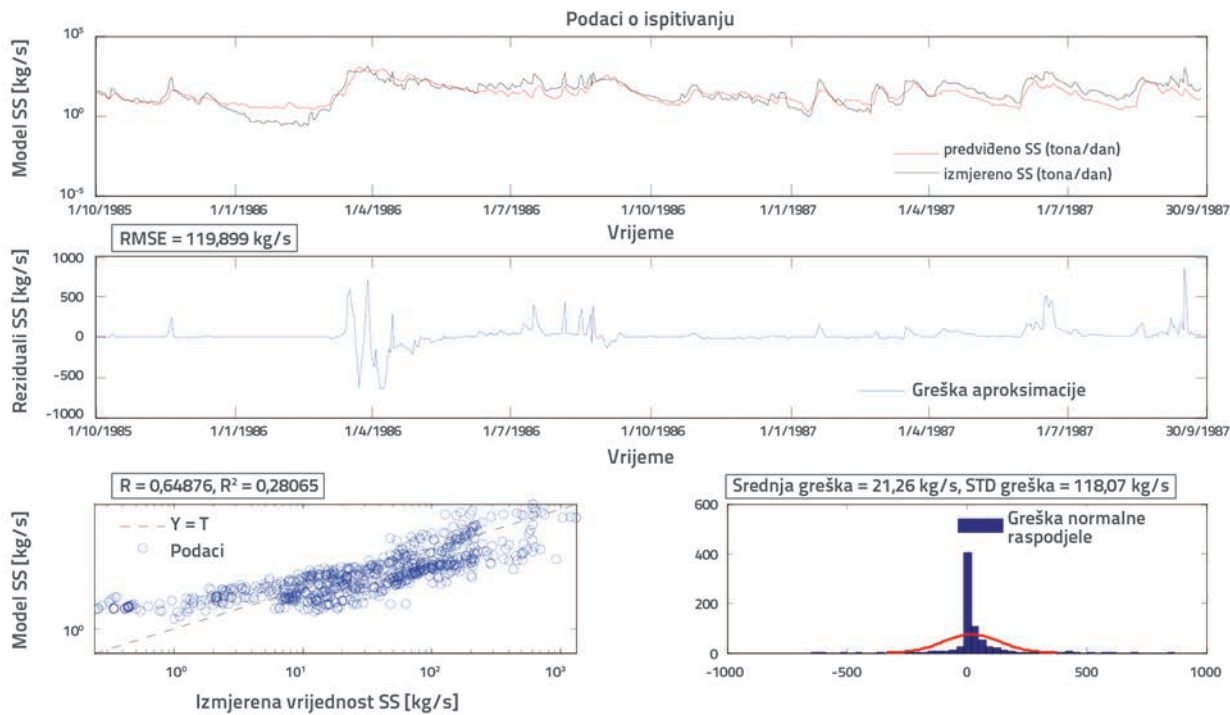
Na slici 6. vidimo dobru podudarnost između registriranih (izmjenjenih) i predviđenih vrijednosti. Modelom WSVM bolje se predviđaju visoke i niske vrijednosti SS. Predviđene vrijednosti bile su bliske izmjerenim vrijednostima a rezultati su bili bliži pravcu od  $45^\circ$  na dijagramima razmještaja u usporedbi s drugim modelom. Tome je razlog činjenica da se posebne značenjke podvremenskih serija mogu uočiti jasnije nego kod prvobitnog signala.

Na slikama 6. i 7. vidi se točnost svakog modela, tj. mogućnost izračunavanja pogreške u standardnoj raspodjeli. Kod modela WSVM, greška u standardnoj raspodjeli iznosila je oko  $70,85 \text{ kg/s}$  a zvonasta krivulja bila je strma. Kada je primijenjena druga metoda, krivulja standardne raspodjele bila je spljoštenija a primjeri su bili raštrkaniji. Tu je greška iznosila otprilike  $102,3 \text{ kg/s}$ . Jasno se može uočiti da su predviđanja poboljšana kada se te metode usporede s primitivnijom metodom kao što je npr. funkcija pronosa nanosa (SRC). Općenito uzevši, krivulja SRC može se izraziti kao  $SS = aQ^b$ , gdje su vrijednosti  $a$  i  $b$  konstante. Krivulja SRC bitno utječe na točno određivanje vrijednosti SS. Eksponencionalnim izrazom pokriva se utjecaj povećane snage riječnog toka pri većim vrijednostima  $Q$ , isto kao i mjera u kojoj su novi izvori SS-a dostupni u vremenskim uvjetima koji dovode do visokih vrijednosti  $Q$ . Iako se ova metoda često koristi, uočeni su i neki problemi koji se odnose na točnost povezane krivulje i na fizičko značenje njenih regresijskih koeficijenata [49]. Krivulja SRC povezana je na ovoj stanici sa setom podataka za učenje pa je dobivena sljedeća jednadžba:

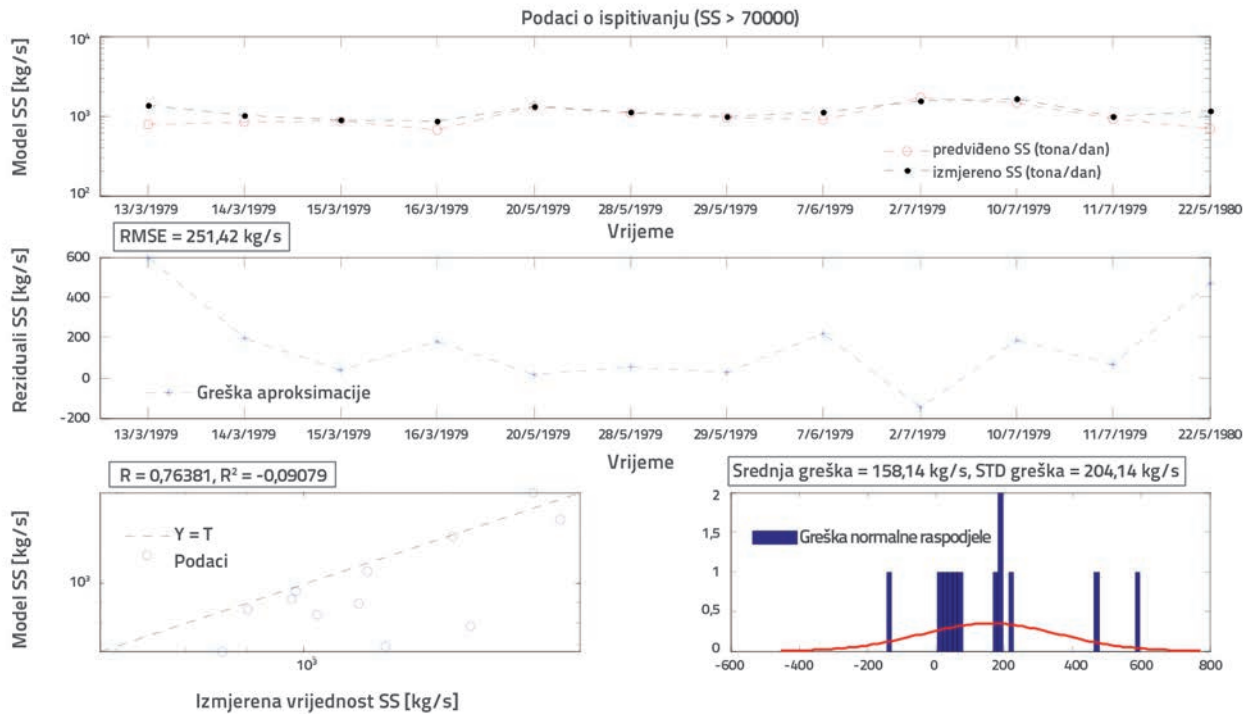
$$SS = 3 \times 10^{-11} Q^{1,9}$$

Predviđajuća sposobnost modela SRC ispitana je na nizovima podataka koji su korišteni za ispitivanje modela SVM i WSVM, pa je tako omogućeno uspoređivanje rezultata. Dobiveni rezultati ilustrirani su grafički na slici 8. gdje su za razdoblje ispitivanja prikazane semilog vremenske serije izmjerenih i predviđenih vrijednosti SS, te reziduali grešaka ustanovljeni pomoću modela SRC. Za taj su model vrijednosti RMSE i  $R^2$  iznosile  $119,89 \text{ kg/s}$  tj.  $0,28$ . Dokazano je da je modelom SVM ostvarena veća podudarnost sa stvarnim vrijednostima SS nego što je to bio slučaj kod modela SRC. Međutim, greške pokazuju da u obzir nisu uzeti neki fizikalni parametri. Stoga se može zaključiti da je model WSVM djelotvorniji od modela SRC i SVM i da omogućuje bolja predviđanja.

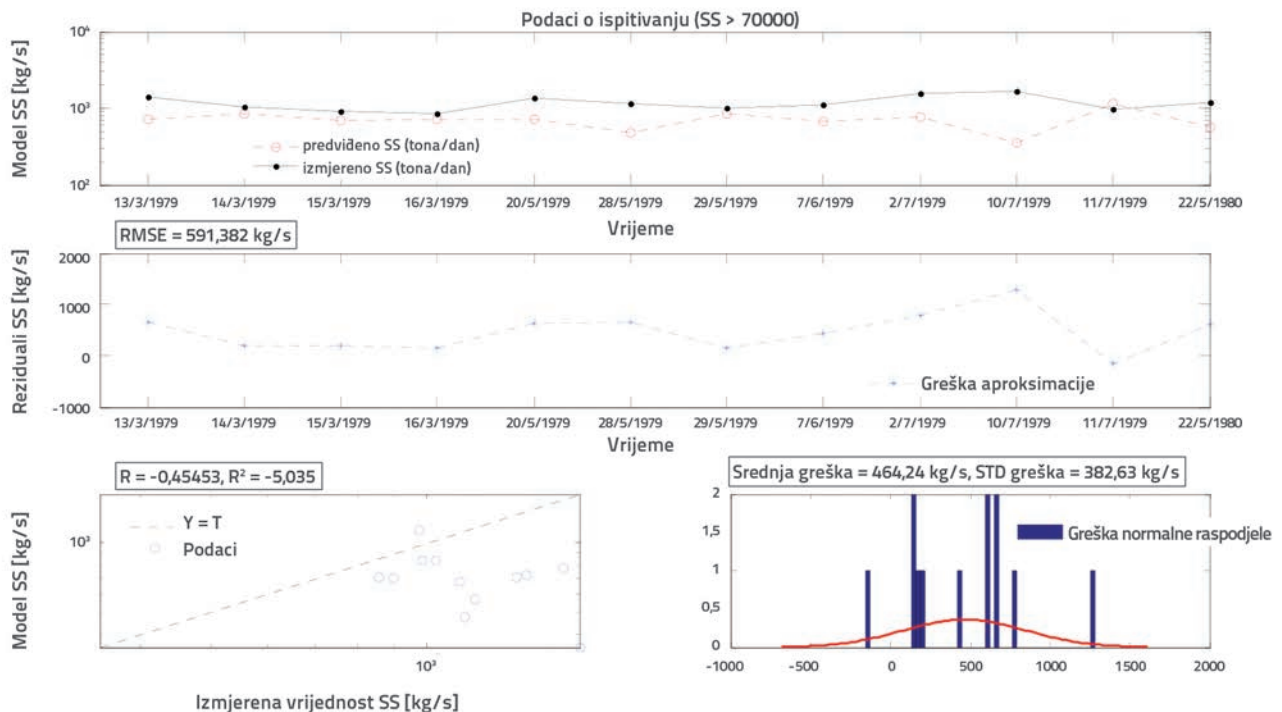
Proračun vrijednosti SS značajan je za rješavanje problema vezanih uz sve vrste akumulacija. Osim toga, točna procjena vrijednosti SS potrebna je i u razdoblju projektiranja i korištenja kanala, brana i derivacijskih kanala. Kumulativna vrijednost SS određena je pomoću opisanih modela za razdoblje ispitivanja. Metodama WSVM i SVM podcijenjena je kumulativna vrijednost SS za otprilike  $2,48 \%$  tj.  $13,4 \%$ . U radu je obavljeno predviđanje vrijednosti SS većih od  $810,18 \text{ kg/s}$ . Dvanaest slučajeva visokih vrijednosti SS odabrano je za analizu u razdoblju ispitivanja, a svi vremenski podaci prikazani su na slikama 8. i 9. Rezultati dobiveni modelom WSVM bliži su linijskom modelu od 1:1. Za ovaj model, vrijednosti RMSE i  $R^2$  iznose  $251,42 \text{ kg/s}$  tj.  $-0,09$ . Vrijednost RMSE umanjena je za  $57 \%$  u odnosu na najbolji model SVM. Kada je korišten



Slika 8. Semilog vremenske serije i log-dijagrami razmještaja izmjerenih i predviđenih vrijednosti SS, reziduali i normalna raspodjela grešaka dobiveni u razdoblju ispitivanja pomoću najboljeg modela SRC



Slika 9. Semilog vremenske serije i log-dijagrami razmještaja izmjerenih i predviđenih vrijednosti SS za vrijednosti veće od 810,18 kg/s, reziduali i normalna raspodjela grešaka dobiveni u razdoblju ispitivanja pomoću najboljeg modela WSVM



Slika 10. Semilog vremenske serije i log-dijagrami razmještaja izmjerenih i predviđenih vrijednosti SS za vrijednosti veće od 810,18 kg/s, reziduali i normalna raspodjela grešaka dobiveni u razdoblju ispitivanja pomoću najboljeg modela SVM

model SVM, u većini je slučajeva dolazilo do podcjenjivanja vrijednosti SS. Semilog i log-dijagrami razmještaja izmjerenih i predviđenih vrijednosti SS za vrijednosti veće od 810,18 kg/s, te reziduali i normalna raspodjela grešaka, prikazani su na slikama 9. i 10.

## 6. Zaključak

U ovom su istraživanju korišteni modeli WSVM i SVM za predviđanje dnevne količine lebdećeg nanosa. Vremenske serije protoka rijeke i količine lebdećeg nanosa podijeljene su u nekoliko multifrekvencijskih vremenskih serija pomoću valićne transformacije. Svaki podsignal sudjelovao je s različitim i zasebnim ponašanjem u prvobitnim vremenskim serijama. Izmjerene vrijednosti Q i SS usvojene su kao ulazne varijable, a najbolje ulazne kombinacije modela ustanovljene su autokorelacijom i međukorelacijom. Usporedba učinkovitosti ovih modela obavljena je pomoću postupaka  $R^2$ , RMSE, srednje greške te greške standardne raspodjele.

U ovom je istraživanju usvojeno da su jezgrene funkcije RBF logičnije i djelotvornije u usporedbi s ostalim jezgrenim funkcijama. Zaključci su pokazali da je model WSVM učinkovitiji u kombinaciji 2 ( $Q_{t-1}$ ,  $Q_{t-2}$ ,  $SS_{t-1}$ ,  $SS_{t-2}$ ) od drugih modela, te da je postignuta minimalna vrijednost RMSE = 70,83 kg/s a najviša vrijednost  $R^2 = 0,847$  kada su odabrane vrijednosti  $C = 6$  i  $\varepsilon = 0,07$ . Općenito uzevši, modelima WSVM i SVM postižu se bolji rezultati predviđanja nego u slučaju modela SRC, pri čemu treba napomenuti da je predviđanje modelom WSVM pouzdanije. Poboljšanja u predviđanju jasno se mogu vidjeti uspoređivanjem tih inteligentnih metoda s krivuljom pronosa nanosa. Primjenom metoda WSVM i SVM, kumulativne vrijednosti SS podcijenjene su za otprilike 2,48 % tj. 13,4 %. U ovom je radu obavljeno i predviđanje visokih vrijednosti SS, a visoke vrijednosti SS (većih od 810,18 kg/s) uspoređene su s izmjerenim vrijednostima. Rezultati pokazuju da se model WSVM može realno koristiti za ocjenjivanje kumulativnih i visokih vrijednosti opterećenja lebdećim nanosom.

## LITERATURA

- [1] Yang, C.T.: Sediment transport.: theory and practice: McGraw-hill New York, 1996.
- [2] Kisi, O.: Suspended sediment estimation using neuro-fuzzy and neural network approaches/Estimation des matières en suspension par des approches neurofloues et à base de réseau de neurones, Hydrological Sciences Journal, 50 (2005) 4, pp. 683-696, DOI: 10.1623/hysj.
- [3] Maheswaran, R., Khosa, R.: Wavelet-Volterra coupled model for monthly stream flow forecasting, Journal of Hydrology, 450, pp. 320-335, 2012.
- [4] Lin, G.-F., Chou, Y.-C., Wu, M.-C.: Typhoon flood forecasting using integrated two-stage Support Vector Machine approach, Journal of Hydrology, pp. 334-342, 2013.

- [5] Nayak, P., Venkatesh, B., Krishna, B., Jain, S.K.: Rainfall runoff modelling using conceptual, data driven and wavelet based computing approach, *Journal of Hydrology*, pp. 57-67, 2013.
- [6] He, J., Valeo, C., Chu, A., Neumann, N.F.: Prediction of event-based stormwater runoff quantity and quality by ANNs developed using PMI-based input selection, *Journal of Hydrology*, 400, pp.10-23, 2011.
- [7] Govindaraju, R.S.: Artificial neural networks in hydrology. II: hydrologic applications, *Journal of Hydrologic Engineering*, 5, pp. 124-137, 2000.
- [8] Kim, T.-W., Valdés, J.B.: Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks, *Journal of Hydrologic Engineering*, 8, pp. 319-328, 2003.
- [9] Mustafa, M., Isa, M., Rezaur, R.: A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River - A Case Study in Malaysia, *World Academy of Science, Engineering and Technology*, 81, pp. 372-376, 2011.
- [10] Nagy, H., Watanabe, K., Hirano, M.: Prediction of sediment load concentration in rivers using artificial neural network model, *Journal of Hydraulic Engineering*, 128, pp. 588-595, 2002.
- [11] Raghuvanshi, N., Singh, R., Reddy, L.: Runoff and sediment yield modelling using artificial neural networks: Upper Siwane River, India, *Journal of Hydrologic Engineering*, 11, pp. 71-79, 2006.
- [12] Rajaei, T., Mirbagheri, S.A., Zounemat-Kermani, M., Nourani, V.: Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models, *Science of the total environment*, 407, pp. 4916-4927, 2009.
- [13] Zhu, Y.-M., Lu, X., Zhou, Y.: Suspended sediment flux modelling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China, *Geomorphology*, 84, pp.111-125, 2007.
- [14] Rajaei, T.: Wavelet and Neuro-fuzzy Conjunction Approach for Suspended Sediment Prediction, *CLEAN-Soil, Air, Water*, 38, pp. 275-286, 2010.
- [15] Jain, S.K.: Development of integrated sediment rating curves using ANNs, *Journal of Hydraulic Engineering*, 127, pp. 30-37, 2001.
- [16] Rajaei, T.: Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers, *Science of the total environment*, 409, pp. 2917-2928, 2011.
- [17] Nourani, V., Alami, M.T., Aminfar, M.H.: A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation, *Engineering Applications of Artificial Intelligence*, 22, pp. 466-472, 2009.
- [18] Rajaei, T., Nourani, V., Zounemat-Kermani, M., Kisi, O.: River suspended sediment load prediction: Application of ANN and wavelet conjunction model, *Journal of Hydrologic Engineering*, 16, pp. 613-62, 2010.
- [19] Pour, O.M.R., Shui, L.T., Dehghani, A.A.: Genetic Algorithm Model for the Relation Between Flow Discharge and Suspended Sediment Load (Gorgan River in Iran), *Electronic Journal of Geotechnical Engineering*, 16, pp. 539-553, 2011.
- [20] Massei, N., Dupont, J.-P., Mahler, B., Laignel, B., Fournier, M., Valdes, D., Ogier, S.: Investigating transport properties and turbidity dynamics of a karst aquifer using correlation, spectral, and wavelet analyses, *Journal of Hydrology*, 329, pp. 244-257, 2006.
- [21] Rajaei, T., Mirbagheri, S., Nourani, V., Alikhani, A.: Prediction of daily suspended sediment load using wavelet and neuro-fuzzy combined model, *International Journal of Environmental Science Technology*, 7, pp. 93-110, 2010.
- [22] Wang, L.: *Support Vector Machines: theory and applications*. 177. Springer, 2005.
- [23] Abe, S.: *Support vector machines for pattern classification*: Springer, 2010.
- [24] Rogers, L.L., Dowla, F.U.: Optimization of groundwater remediation using artificial neural networks with parallel solute transport modelling, *Water Resources Research*, 30, pp. 457-481, 1994.
- [25] Kisi, O., Shiri, J.: Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models, *Water resources management*, 25, pp. 3135-3152, 2011.
- [26] Kisi, O., Cimen, M.: A wavelet-support vector machine conjunction model for monthly streamflow forecasting, *Journal of Hydrology*, 399, pp. 132-140, 2011.
- [27] Misra, D., Oommen, T., Agarwal, A., Mishra, S.K., Thompson, A.M.: Application and analysis of support vector machine based simulation for runoff and sediment yield, *Biosystems engineering*, 103, pp. 527-535, 2009.
- [28] Noori, R., Karbassi, A., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M., Farokhnia, A., Gousheh, M.G.: Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction, *Journal of Hydrology*, 401, pp. 177-189, 2011.
- [29] Kisi, O.: Modelling discharge-suspended sediment relationship using least square support vector machine, *Journal of Hydrology*, 456, pp. 110-120, 2012.
- [30] Kakaei Lafdani, E., Moghaddam Nia, A., Ahmadi, A.: Daily Suspended Sediment Load Prediction Using Artificial Neural Networks and Support Vector Machines Machine, *Journal of Hydrology*, pp. 50-62, 2012.
- [31] Kisi, O., Dailr, A.H., Cimen, M., Shiri, J.: Suspended sediment modelling using genetic programming and soft computing techniques, *Journal of Hydrology*, 450, pp. 48-58, 2012.
- [32] Theodoridis, S., Pikrakis, A., Koutroumbas, K., Cavouras, D.: *Introduction to Pattern Recognition: A Matlab Approach: A Matlab Approach: Access Online via Elsevier*, 2010.
- [33] Cherkassky, V., Ma, Y.: Practical selection of SVM parameters and noise estimation for SVM regression, *Neural networks*, 17, pp. 113-126, 2004.
- [34] Cristianini, N., Shawe-Taylor, J.: *An introduction to support vector machines and other kernel-based learning methods*: Cambridge university press, 2000.
- [35] Kecman, V.: *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*: MIT press, 2001.
- [36] Vapnik, V., Golowich, S.E., Smola, A.: Support vector method for function approximation, regression estimation, and signal processing, *Advances in neural information processing systems*, pp. 281-287, 1997.
- [37] Smola, A.J., Schölkopf, B.: *A tutorial on support vector regression*, *Statistics and computing*, 14, pp. 199-222, 2004.

- [38] Liu, Z., Wang, X., Cui, L., Lian, X., Xu, J.: Research on water bloom prediction based on least squares support vector machine. in Computer Science and Information Engineering, WRI World Congress on. 2009. IEEE, 2009.
- [39] Xu, Y., Chen, X., Li, Q.: INS/WSN-Integrated Navigation Utilizing LS-SVM and  $H_{\infty}$  filtering, Mathematical Problems in Engineering, 2012, pp. 1-19, 2012. doi:10.1155/2012/707326.
- [40] Kucuk, M., Ađirali-super, N.: Wavelet regression technique for streamflow prediction, Journal of Applied Statistics, 33, pp. 943-960, 2006.
- [41] Youssef, O.A.: A wavelet-based technique for discrimination between faults and magnetizing inrush currents in transformers, Power Delivery, IEEE Transactions on, 18, pp. 170-176, 2003.
- [42] Polikar, R.: The wavelet tutorial part iii, IOWA State University, USA, 1996
- [43] Polikar, R.: The Wavelet Tutorial Part IV, Multiresolution Analysis: The Discrete Wavelet Transform, ww. cs. ucf. edu/courses/cap5015/WTPart4. pdf, 2008.
- [44] Legates, D.R., McCabe, G.J.: Evaluating the use of "goodness of fit" measures in hydrologic and hydroclimatic model validation, Water Resources Research, 35, pp. 233-241, 1999.
- [45] Nash, J., Sutcliffe, J.: River flow forecasting through conceptual models part I, A discussion of principles, Journal of Hydrology, 10, pp. 282-290, 1970.
- [46] Xie, Z., Lou, I., Ung, W.K., Mok, K.M.: Freshwater algal bloom prediction by support vector machine in macau storage reservoirs, Mathematical Problems in Engineering, 2012.
- [47] Chang, C.-C., Lin, C.-J.: LIBSVM: a library for support vector machines, ACM Transactions on Intelligent Systems and Technology (TIST), 2:3, article no. 27, 2011. doi: 10.1145/1961189.1961199.
- [48] Han, D., Chan, L., Zhu, N.: Flood forecasting using support vector machines, Journal of hydroinformatics, 9, pp. 267-276, 2007.
- [49] Asselman, N.: Fitting and interpretation of sediment rating curves, Journal of Hydrology, 234, pp. 228-248, 2000.