

## PREDIKSI TINGGI MUKA AIR (TMA) UNTUK DETEKSI DINI BENCANA BANJIR MENGUNAKAN SVR-TVIWPSO

Arief Andy Soebroto<sup>1</sup>, Imam Cholissodin<sup>2</sup>, Randy Cahya Wihandika<sup>3</sup>, Maria Tenika Frestantiya<sup>4</sup>, Ziya El Arief<sup>5</sup>

<sup>12345</sup> Program Teknologi Informasi dan Ilmu Komputer, Universitas Brawijaya  
Email: <sup>1</sup>ariefas@ub.ac.id, <sup>2</sup>imamcs@ub.ac.id, <sup>3</sup>rendicahya@ub.ac.id, <sup>4</sup>maria.tenika@gmail.com,  
<sup>5</sup>ziyaelarief@gmail.com

(Naskah masuk: 11 Juni 2015, diterima untuk diterbitkan: 22 Juli 2015)

### Abstrak

*Banjir merupakan salah satu jenis bencana alam yang tidak dapat diprediksi kedatangannya, salah satu penyebabnya adalah adanya hujan yang terus – menerus(dari peristiwa alam). Faktor penyebab banjir dari segi meteorologi yaitu curah hujan yang tinggi dan air laut yang sedang pasang sehingga mengakibatkan tinggi permukaan air meningkat. Analisis terhadap data curah hujan serta tinggi permukaan air setiap periodenya dirasa masih belum dapat menyelesaikan permasalahan yang ada. Oleh karena itu, pada penelitian ini diusulkan teknik integrasi metode Time Variant Inertia Weight Particle Swarm Optimization(TVIWPSO) dan Support Vector Regression(SVR). Implementasi memadukan metode Regresi yaitu SVR untuk forecasting TMA, sedangkan TVIWPSO digunakan untuk mengoptimalkan parameter – parameter yang digunakan di dalam SVR untuk memperoleh kinerja yang maksimal dan hasil yang akurat. Harapannya sistem ini akan dapat membantu mengatasi permasalahan untuk pendeteksian dini bencana banjir karena faktor cuaca yang tidak menentu. Hasil pengujian yang didapat dari 10 data bulanan yang berbeda menunjukkan bahwa didapatkan nilai error terkecil sebesar 0.00755 dengan menggunakan Mean Absolute Error untuk data Juni 2007 dengan menggunakan integrasi metode SVR-TVIWPSO.*

**Kata Kunci :** *Support Vector Regression, Tinggi Muka Air, Time Variant Inertia Weight Particle Swarm Optimization.*

### Abstract

*Flood is one type of natural disaster that can not be predicted its arrival, one reason is the rain that constantly occurs (from natural events). Factors that cause flooding in terms of meteorology are high rainfall and sea water was high, resulting in high water level increases. Analysis of rainfall data and water level in each period it is still not able to solve existing problems. Therefore, in this study the method proposed integration techniques Time Variant Inertia Weight Particle Swarm Optimization (TVIWPSO) and Support Vector Regression (SVR). Implementation combines regression method for forecasting TMA is SVR, while TVIWPSO used to optimize parameters that used in the SVR to obtain maximum performance and accurate results. Hope this system will be able to help solve the problems for the early detection of floods due to erratic weather. The result of forecasting experiment in water level forecasting from 10 monthly different data show that the smallest error rate is amount to 0.00755 using Mean Absolute Error for June 2007 with the integration method SVR-TVIWPSO.*

**Keywords:** *Support Vector Regression, water level, Time Variant Inertia Weight Particle Swarm Optimization.*

## 1. PENDAHULUAN

Bencana alam menjadi salah satu sorotan yang hangat diperbincangkan secara global, dan banjir merupakan salah satu bencana yang paling berpengaruh paling luas dan menyebabkan kerugian yang tidak kecil (Ma, 2010). Banjir merupakan salah satu jenis bencana alam yang tidak dapat diprediksi kedatangannya dan menjadi permasalahan umum di banyak Negara. Sejauh ini banjir diakibatkan oleh proses yang berhubungan dengan tinggi permukaan laut dan arus air (Meesuk, 2012, Wadey, 2015). Pemerintah Kota Surabaya mulai melakukan analisis terhadap data curah hujan serta tinggi permukaan air setiap periodenya (Saud, 2007). Namun upaya tersebut dirasa masih belum dapat menyelesaikan

permasalahan yang ada. Berangkat dari hal tersebut, dibutuhkan solusi yang rasional dari berbagai sudut pandang. Selain dari sisi manusia nya sendiri, solusi dari sisi teknologi juga diharapkan dapat penyelesaian permasalahan ini.

Objek yang digunakan dalam penelitian ini adalah Tinggi Muka Air (TMA). Semakin tinggi muka air tentu menjadi salah satu faktor yang menyebabkan potensi banjir. Sebuah banjir besar-besaran terjadi di Thailand karena tropis badai "Nock-ten" dan "Heima". Banjir turun dari bagian utara Thailand selama lima bulan dari Juli sampai November 2011, hal ini mendorong Youngjoo untuk melakukan penelitian mengenai estimasi volume air pada sungai tersebut (Youngjoo, 2012). Sedangkan di Negara China, dalam 20 tahun terakhir di Sungai

Huahei (sungai terbesar ke-6 di China) terjadi 3 kali banjir yang benar – benar dahsyat pada tahun 1991, 2003 dan 2007. Kenaikan muka air di sungai ini menyebabkan banjir yang parah dan genangan air bencana, sehingga mendorong penelitian untuk melakukan monitoring terhadap banjir pada Sungai Huahei (Zheng, 2012), penelitian serupa juga dilakukan oleh Zhao (2011), untuk infiltrasi volume air pada Sungai Moleng di Negara Mongolia.

Teknologi saat ini telah berkembang dalam berbagai aspek kehidupan manusia, salah satunya teknologi di bidang komputer dimana sistem yang terkomputerisasi saat ini banyak dikembangkan sebagai alternatif untuk membantu menyelesaikan permasalahan serta membantu dalam proses pengambilan keputusan guna meningkatkan kinerja instansi yang baru saja berkembang, dengan menggunakan teknologi di bidang komputer tentunya pengolahan data dan pemberian informasi dapat diperoleh secara akurat dengan lebih efisien dan efektif. Estimasi batas air penting untuk menentukan bahaya mendasar dalam resiko datangnya banjir (Youngjoo, 2012). Oleh sebab itu adanya teknologi untuk deteksi dini bencana banjir akan dibutuhkan oleh berbagai banyak pihak guna memperoleh kondisi cuaca yang lebih cepat dan akurat.

Berbagai metode *forecasting* telah dikembangkan hingga saat ini. Pendekatan yang dikembangkan meliputi pendekatan stokastik dan deterministik. Model *forecasting* sebagian besar menggunakan pendekatan deterministik, yaitu kondisi saat  $t$  atau  $t-1$  dan  $t+1$ , dengan periode harian (Sutikno, 2013). metode yang digunakan untuk meramalkan data non-linear yaitu *Threshold Autoregressive* (TAR), *Autoregressive Conditional Heteroscedastic* (ARCH), *Artificial Neural Networks* (ANN) dan *Support Vector Regression* (SVR) (Alwee, 2013).

Pada penelitian sebelumnya adalah penelitian yang menggunakan komparasi dua metode yaitu *Multivariate Adaptive Regression Splines* (MARS) dengan *Support Vector Regression* (SVR) untuk memprediksi penjualan produk IT, SVR memberikan *Root Mean Squared Error* (RMSE) yang lebih kecil yaitu sebesar 9.36 dalam penjualan *Notebook*, dibanding metode MARS yang memberikan nilai RMSE sebesar 293.3 (Lu, 2010). Selain itu menurut penelitian yang dilakukan Liu (2010), studi komparasi terhadap Metode *K-Means* dan SVR membuktikan bahwa pada 6 sektor opini penggunaan internet hotspot, SVR memberikan hasil yang jauh lebih baik pada 5 sektor dibanding *K-Means*.

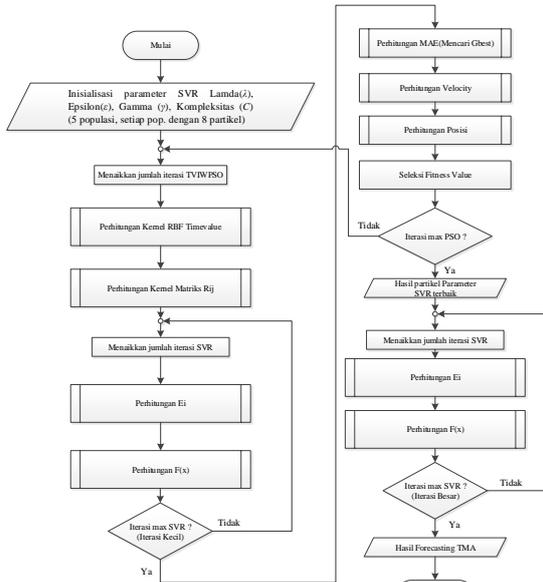
Guna memperoleh kinerja SVR yang lebih optimal, telah banyak metode yang digunakan untuk melakukan optimasi terhadap SVR. Beberapa metode pengoptimalan variabel tersebut adalah algoritma *Cross Entropy*, *Bee Colony*, *Ant Algorithm*, dan *Particle Swarm Optimization* (PSO). Sebuah penelitian dengan metode *Adaptive Fuzzy K-Nearest*

*Neighbor* yang dioptimalkan dengan metode *Time Variant Inertia Weight Particle Swarm Optimization* untuk prediksi kebangkrutan secara otomatis terbukti memiliki keakuratan yang lebih tinggi, yaitu sebesar 81.67% dibanding menggunakan metode FKNN saja yaitu sebesar 78.75% (Chen, 2011). Dimana pendekatan TVIWPSO ditujukan untuk pengoptimalan pencarian koefisien – koefisien dalam perhitungan SVR. Guo (2009) menyebutkan dalam penelitiannya bahwa *Hybrid SVR-PSO* dapat memilih secara tepat masukan fitur diskriminatif, mengurangi waktu rata – rata eksekusi dan meningkatkan akurasi peramalan. Oleh karena itu, pada penelitian ini diusulkan teknik integrasi metode *Time Variant Inertia Weight Particle Swarm Optimization* (TVIWPSO) dan *Support Vector Regression* (SVR). Disini kami mengusulkan penambahan TVIW tanpa menggunakan TVAC dikarenakan dari TVIW sendiri sudah dapat meningkatkan performa PSO untuk *global search* dan *local search* secara adaptif serta lebih terarah. Karena pada TVIW, konsep keseimbangan antara eksplorasi (*global search*) dan eksploitasi (*local search*) tidak dilakukan untuk setiap iterasi seperti yang ada pada TVAC, melainkan memiliki focus mulai dari iterasi di awal untuk eksplorasi, dan sampai mendekati iterasi akhir untuk eksploitasi. Inilah konsep TVIW yang kami sebut lebih terarah karena memastikan terlebih dahulu proses eksplorasinya maksimal, setelah itu baru proses eksploitasi, sehingga dapat lebih memperbesar peluang untuk mendapatkan solusi yang lebih optimal dan tidak mudah terjebak pada konvergensi dini. Konsep TVIW ini memang agak berlawanan dengan TVAC (ketika dilihat dari sudut pandang perlakuan pada saat iterasinya berjalan). Namun TVIW ini memiliki kesamaan dengan TVAC (ketika dilihat dari sudut pandang pengaturan keseimbangan antara eksplorasi dengan eksploitasi). TVAC mengatur keseimbangan eksplorasi dan eksploitasi pada satu waktu atau setiap iterasi, yang lebih mengindikasikan adanya hasil eksplorasi maupun eksploitasinya menjadi prematur atau kurang optimal. Jadi di TVIW sebenarnya sudah terdapat proses yang mirip dengan TVAC dari sudut pandang konsep keseimbangan, dan karena TVIW memiliki keunggulan yaitu lebih terarah dari pada TVAC, maka prosesnya tidak perlu dibuat pengaturan keseimbangan dua kali yang melibatkan TVAC, namun cukup sekali saja dengan hanya menggunakan TVIW. Harapannya sistem ini akan dapat membantu mengatasi permasalahan untuk pendeteksian dini bencana banjir karena faktor cuaca yang tidak menentu.

## 2. METODE YANG DIUSULKAN

Dalam paper ini diusulkan metode SVR-TVIWPSO. Metode SVR yang dioptimasi menggunakan metode TVIWPSO digunakan untuk mencari partikel terbaik yang akan digunakan sebagai acuan dalam peramalan. Jadi untuk menjalankan SVR

digunakan parameter TVIWPSO yang paling baik (dengan nilai evaluasi yang paling kecil). Berikut adalah diagram alir metode SVR-TVIWPSO.



Gambar 2.1 Diagram Alir SVR-TVIWPSO

### 3. METODE KERNEL

Metode kernel adalah kelas algoritma untuk analisis atau pengenalan pola, yang mana elemen yang diketahui paling bagus adalah SVM. Tugas umum analisis pola adalah untuk menemukan dan mempelajari jenis umum dari relasi seperti kluster, klasifikasi, dan peringkat. Metode kernel memetakan data ke ruang dimensi yang lebih tinggi (Tonde, 2014) dengan harapan bahwa dalam ruang yang lebih tinggi, dimensi data dapat lebih terstruktur. Untuk SVR non-linear, sejumlah fungsi kernel terbukti memiliki kemampuan generalisasi yang baik, seperti linear, polynomial, fungsi basis radial (RBF) dan sigmoid. Jenis kernel yang paling sering digunakan adalah *Gaussian Kernel* yang merupakan salah satu implementasi dari *Radial Basis Function Kernel* (Javed, 2009).

$$k(x, y) = \exp\left(\frac{-\|x-y\|^2}{2\sigma^2}\right) \dots\dots\dots(1)$$

Parameter *sigma* ( $\sigma$ ) memainkan peran utama dalam kinerja kernel, dan harus dihitung secara hati-hati dalam masalah yang dihadapi. Jika terlalu diperhitungkan, eksponensial akan berperilaku hampir linear dan proyeksi dimensi yang lebih tinggi akan kehilangan nilai non linearnya. Di sisi lain jika terlalu diabaikan, fungsi akan mengalami kekurangan pengaturan dan batas keputusan akan sangat sensitif terhadap data *noise* pada data *training*. Selain *Gaussian kernel*, kernel lain yang sering digunakan adalah *Polynomial kernel* dengan penjabaran sebagai berikut (Sahak, 2011).

$$k(x, y) = (x^T y + c)^d \dots\dots\dots(2)$$

Parameter yang paling disesuaikan adalah konstanta *c*, dan polynomial derajat *d*.

### 4. SEQUENTIAL TRAINING SVR

SVR merupakan salah satu contoh paling terkemuka yang digunakan untuk regresi (Li, 2012). Salah satu metode paling sederhana yang digunakan untuk mendapatkan garis atau bidang *hyperplane* yang optimal dalam algoritma SVR yang sangat kompleks adalah metode sekuensial yang dikembangkan oleh Vijayakumar. berikut langkah-langkahnya (Sethu Vijayakumar dan Si Wu, 1999) :

- Pertama, inisialisasi nilai parameter yang digunakan. Misal set  $\lambda = 3.95$ ,  $\gamma = 0.23$  (*learning rate*),  $C = 9.44$  (*variabel slack*),  $IterMax=1000$  dan  $\epsilon = 0.000002$  (*epsilon*).
- Kedua, set  $\alpha_i = \alpha_i^* = 0$ , lalu hitung matrik *Rij*.  

$$R_{ij} = (K(x_i, x_j) + \lambda^2)$$
 dan  $i, j=1, \dots, l \dots\dots(3)$ 
 $l$  adalah banyaknya data.
- Ketiga, lakukan (a), (b) dan (c) berikut dengan  $i=1$  sampai  $N$ .

$$(a) E_i = y_i - \sum_{j=1}^l (\alpha_j^* - \alpha_j) R_{ij} \dots\dots\dots(4)$$

$$(b) \delta \alpha_i^* = \min\{\max[\gamma(E_i - \epsilon), -\alpha_i^*], C - \alpha_i^*\} \dots\dots\dots(5)$$

$$\delta \alpha_i = \min\{\max[\gamma(-E_i - \epsilon), -\alpha_i], C - \alpha_i\} \dots\dots\dots(6)$$

dan merupakan variabel tunggal, bukan bentuk  $\delta \alpha_i^*$  dan  $\delta \alpha_i$  dari perkalian  $\delta$  dan  $\alpha_i^*$  atau perkalian  $\delta$  dan  $\alpha_i$ .

$$(c) \alpha_i = \alpha_i + \delta \alpha_i \dots\dots\dots(7)$$

$$\alpha_i^* = \alpha_i^* + \delta \alpha_i^* \dots\dots\dots(8)$$

- Kembali ke langkah Ketiga, sampai pada kondisi  $IterMax$  atau  $\max(|\delta \alpha_i^*|) < \epsilon$  dan  $\max(|\delta \alpha_i^*|) < \epsilon$ .
- *Support* vektor, jika suatu data memiliki nilai  $(\alpha_i^* - \alpha_i) \neq 0$ .
- Fungsi regresinya adalah  

$$f(x) = \sum_{j=1}^l (\alpha_j^* - \alpha_j) (K(x_i, x_j) + \lambda^2) \dots\dots(9)$$
- Selesai.

### 5. TVIWPSO

PSO (*Particle Swarm Optimization*) adalah salah satu teknik optimasi yang didasarkan pada metafora sosial interaksi dan komunikasi seperti kelompok burung atau ikan yang mencari makan (Bu Hai, 2014). Konsep PSO sendiri terinspirasi dari perilaku sekelompok burung yang mencari makan, partikel akan mendapatkan solusi terbaik melalui kompetisi dan kolaborasi (Ning, 2010; Sengupta et.al, 2014). Di bawah ini adalah penjabaran pendekatan PSO (Chen, dkk, 2011):

$$v_{ij}^{n+1} = w \times v_{ij}^n + c_1 \times r_1 (p_{ij}^n - x_{ij}^n) + c_2 \times r_2 (p_{gj}^n - x_{ij}^n) \dots\dots\dots(10)$$

$$x_{ij}^{n+1} = x_{ij}^n + v_{ij}^{n+1}, j=1, 2, \dots, d \dots\dots\dots(11)$$

Dimana vektor *Pi* merepresentasikan posisi terbaik sebelumnya dari partikel ke *i* yang mana memberikan nilai terbaik, yang diketahui sebagai

pbest. Vektor  $P_g$  adalah vektor partikel terbaik diantara semua partikel pada populasi, yang mana diketahui sebagai gbest.  $r_1$  dan  $r_2$  adalah angka acak yang dihasilkan antara nilai 0 hingga 1.

Model TVIWPSO-SVR diusulkan untuk pengoptimalan variabel – variabel yang ada pada metode SVR yang digunakan untuk peramalan tinggi muka air, TVIW sendiri sudah dapat meningkatkan performa PSO untuk global search dan local search secara adaptif serta lebih terarah. Dimana proses perhitungan  $w$  akan dijelaskan pada Persamaan 12.

$$w = w_{min} + (w_{max} - w_{min}) \times \left(\frac{t_{max}-t}{t_{max}}\right) \dots (12)$$

Fitur yang didapatkan dari pengoptimisasian tersebut, digunakan sebagai input ke dalam model SVR lalu diterapkan secara parallel sehingga menjadi metode SVR yang teroptimisasi(Chen, dkk, 2011).

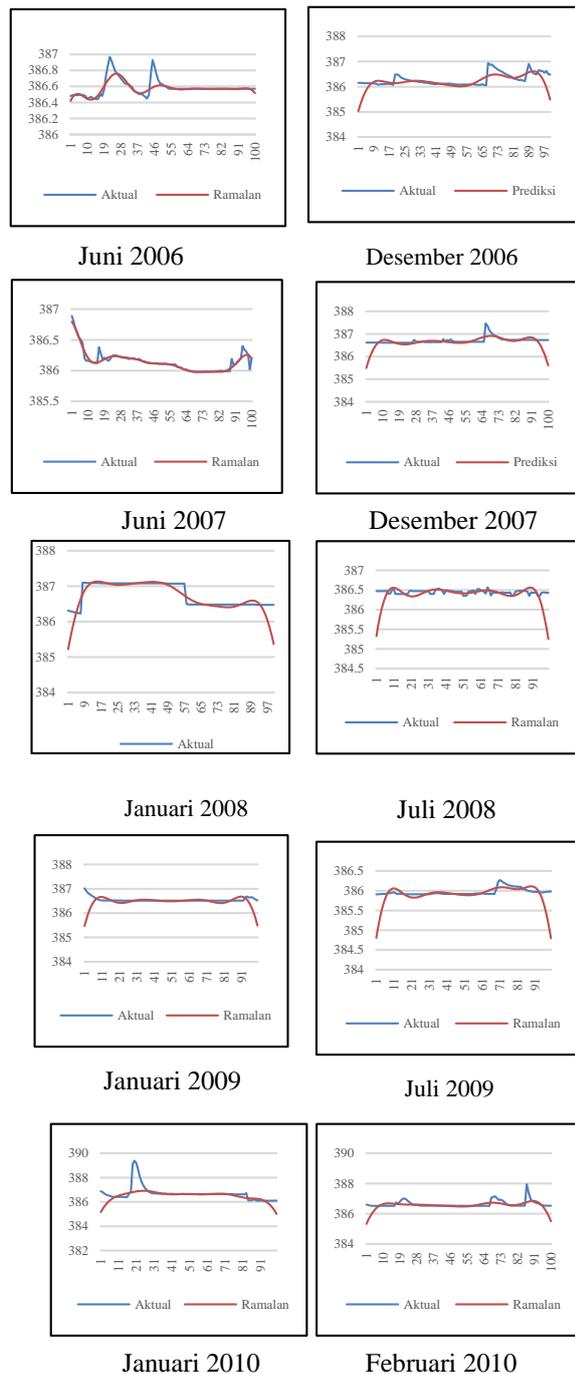
### 6. NILAI EVALUASI

Untuk mengecek besar kesalahan peramalan, dapat diketahui dengan menghitung selisih antara nilai asli dengan nilai peramalannya, yang biasa dikenal dengan nama error. Metode umum yang biasa digunakan dalam pengukuran akurasi peramalan ada beberapa macam, salah satunya adalah *Mean Absolute Error*(MAE), banyak peneliti lebih memilih menggunakan MAE dibanding metode pengukuran *error rate* lainnya untuk evaluasi statistik(Chai, 2014) di bawah ini merupakan penjabaran perhitungan *error rate* menggunakan MAE:

$$MAE = \frac{\sum(X_t - F_t)}{n} \dots (9)$$

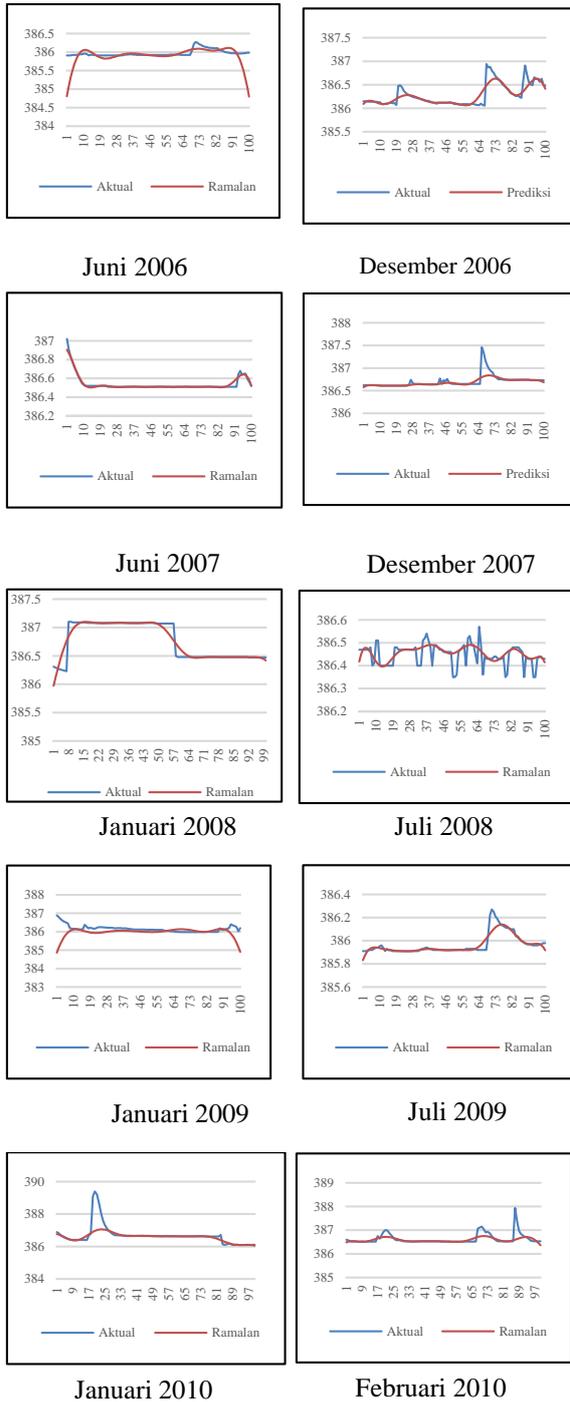
### 7. HASIL PERCOBAAN DAN ANALISIS

Pada bagian ini kami akan membandingkan hasil percobaan menggunakan metode SVR dan SVR-TVIWPSO. Menurut Deputy Bidang Klimatologi BMKG Widada Sulistyia menjelaskan bahwa, musim kemarau akan mulai merata pada Bulan Juni, dan musim kemarau yang terjadi pada 30 tahun terakhir tidak berubah. Oleh karena itu untuk percobaan menggunakan metode SVR, dipilih 10 data dengan rincian 6 grafik yang datanya berasal dari bulan pada musim penghujan yaitu Desember, Januari dan Februari(dengan tahun yang berbeda) serta 4 grafik lainnya diambil dari musim kemarau yaitu Juli dan Juni(dengan tahun yang berbeda). Iterasi yang digunakan sebesar 100000 iterasi. Rincian data yang digunakan adalah Tinggi Muka Air dari tahun 2006 hingga 2010 yaitu Juni 2006, Desember 2006, Juni 2007, Desember 2007, Januari 2008, Juli 2008, Januari 2009, Juli 2009, Januari 2010 dan Februari 2010 yang telah dilakukan normalisasi sebelumnya sehingga menghasilkan grafik SVR seperti pada Gambar 2, dimana garis biru menunjukkan nilai aktual dari Tinggi Muka Air dan garis merah menjelaskan nilai ramalan menggunakan metode SVR:



Gambar 7.1 Output Grafik Menggunakan SVR

Sedangkan untuk percobaan dengan metode SVR yang dioptimasi dengan metode TVIWPSO juga menggunakan data Tinggi Muka Air dari tahun 2006 hingga 2010 yang sudah dinormalisasi, data yang dipilih untuk uji coba SVR-TVIWPSO sama dengan data yang digunakan pada uji coba metode SVR, yaitu dipilih 10 data dengan rincian 6 grafik yang datanya berasal dari bulan pada musim penghujan yaitu Desember, Januari dan Februari(dengan tahun yang berbeda) serta 4 grafik lainnya diambil dari musim kemarau yaitu Juli dan Juni(dengan tahun yang berbeda) dengan hasil grafik seperti pada Gambar 3.



Gambar 3 Output Grafik Menggunakan SVR-TVIWPSO

Dapat dilihat dari grafik yang ada, bahwa hasil uji coba metode SVR-TVIWPSO lebih mendekati dibanding hasil uji coba metode SVR saja, untuk lebih jelasnya perbedaan nilai MAE yang dihasilkan akan dijelaskan pada Tabel 1 dengan pembulatan 5 angka di belakang koma.

Untuk percobaan metode SVR dengan jumlah iterasi sebesar 100000, dipilih data dengan nilai MAE SVR-TVIWPSO yang terbaik/paling kecil yang

terjadi pada bulan Juni 2007 dengan hasil sesuai dengan Tabel 1.

Tabel 1 Hasil Uji Coba Metode SVR

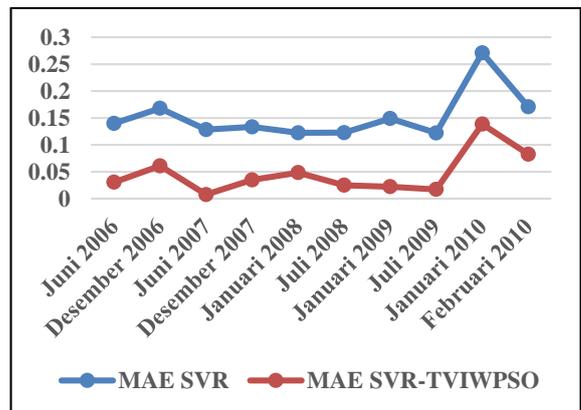
| I  | (λ)  | (ε)                | (γ)  | (C)  | MAE    | RT (m) |
|----|------|--------------------|------|------|--------|--------|
| 1  | 8.29 | 3.10 <sup>-6</sup> | 0.58 | 4.15 | 0.0069 | 3.5    |
| 2  | 3.62 | 5.10 <sup>-6</sup> | 0.03 | 6.62 | 0.0087 | 5.3    |
| 3  | 4.55 | 8.10 <sup>-6</sup> | 0.45 | 8.88 | 0.0068 | 7.2    |
| 5  | 3.95 | 2.10 <sup>-6</sup> | 0.23 | 9.44 | 0.0067 | 10.9   |
| 10 | 7.77 | 1.10 <sup>-6</sup> | 0.76 | 7.53 | 0.0073 | 20.8   |

I menyatakan jumlah iterasi yang terjadi dan RT merupakan waktu eksekusi dalam satuan menit. Untuk perbedaan nilai MAE metode SVR an SVR-TVIWPSO akan dijabarkan lebih rinci pada Tabel 2.

Tabel 2 Perbedaan Nilai MAE Metode SVR dan SVR-TVIWPSO

| BULAN         | MAE     |             |
|---------------|---------|-------------|
|               | SVR     | SVR-TVIWPSO |
| Juni 2006     | 0.13988 | 0.03055     |
| Desember 2006 | 0.16795 | 0.061       |
| Juni 2007     | 0.12827 | 0.00755     |
| Desember 2007 | 0.13338 | 0.03487     |
| Januari 2008  | 0.12241 | 0.04839     |
| Juli 2008     | 0.12267 | 0.02495     |
| Januari 2009  | 0.14884 | 0.02218     |
| Juli 2009     | 0.12203 | 0.0171      |
| Januari 2010  | 0.27094 | 0.13855     |
| Februari 2010 | 0.17075 | 0.08259     |

Perbedaan MAE antara metode SVR dan metode SVR-TVIWPSO akan dijabarkan dalam bentuk grafik pada Gambar 4.



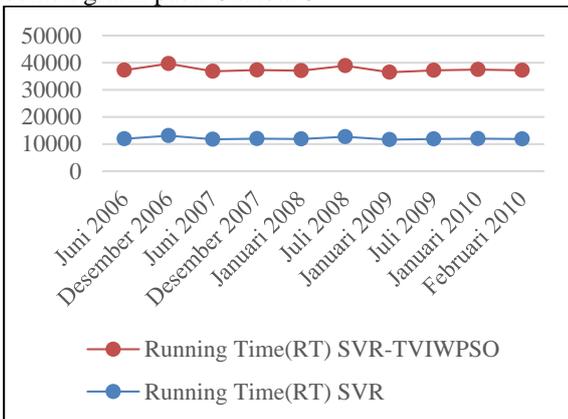
Gambar 4 Grafik Perbedaan Nilai Error Rate(MAE) antara Metode SVR dan SVR-TVIWPSO

Sedangkan untuk perbandingan *Running Time* antara metode SVR dan metode SVR-TVIWPSO akan disajikan pada Tabel 3.

Tabel 3 Perbedaan Nilai *Running Time* Metode SVR dan SVR-TVIWPSO

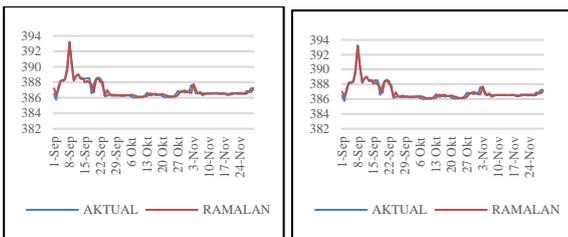
| Bulan         | Running Time(RT) |             | Selisih RT(ms) |
|---------------|------------------|-------------|----------------|
|               | SVR              | SVR-TVIWPSO |                |
| Juni 2006     | 11896            | 25305       | 13409          |
| Desember 2006 | 13126            | 26484       | 13358          |
| Juni 2007     | 11775            | 25038       | 13263          |
| Desember 2007 | 11956            | 25336       | 13380          |
| Januari 2008  | 11852            | 25210       | 13358          |
| Juli 2008     | 12694            | 26164       | 13470          |
| Januari 2009  | 11634            | 24792       | 13158          |
| Juli 2009     | 11882            | 25255       | 13373          |
| Januari 2010  | 11983            | 25453       | 13470          |
| Februari 2010 | 11892            | 25250       | 13358          |

Perbedaan *Running Time* antara metode SVR dan metode SVR-TVIWPSO akan dijabarkan dalam bentuk grafik pada Gambar 5.



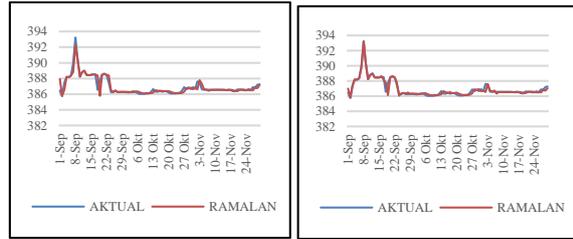
Gambar 5 Grafik Perbedaan Nilai *Running Time* antara Metode SVR dan SVR-TVIWPSO

Pada percobaan selanjutnya, adalah uji coba jumlah iterasi SVR, disini digunakan nilai *training* yang sama yaitu mulai bulan September hingga November di tahun 2010 dengan iterasi pada fase *training* dan fase *testing* yang berbeda – beda untuk setiap percobaannya, iterasi yang digunakan adalah iterasi yang kecil pada fase *training* dan iterasi yang besar pada fase *testing* percobaan tersebut menghasilkan hasil peramalan sesuai pada Gambar 6 berikut ini :



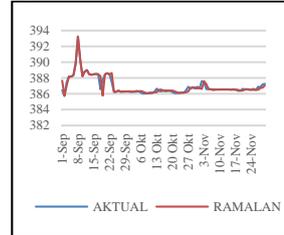
Iterasi 100; 10000

Iterasi 300; 30000



Iterasi 500; 50000

Iterasi 700; 70000



Iterasi 1000; 100000

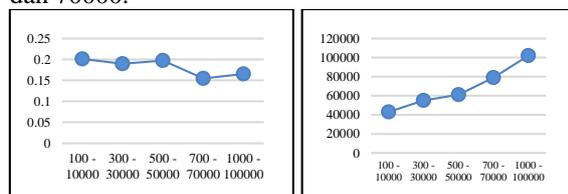
Gambar 6 Grafik Hasil Peramalan Uji Coba Iterasi SVR Skenario 1

Sedangkan untuk perbandingan nilai MAE dan *running time* dari masing – masing variasi uji coba tersebut akan dijabarkan pada Tabel 4 berikut :

Tabel 4 Nilai MAE dan *Running Time* Uji Coba Iterasi SVR Skenario 1

| Jumlah Iterasi |         | MAE         | RT (ms) |
|----------------|---------|-------------|---------|
| Training       | Testing |             |         |
| 100            | 10000   | 0.201126786 | 43000   |
| 300            | 30000   | 0.189821647 | 55000   |
| 500            | 50000   | 0.197452813 | 61000   |
| 700            | 70000   | 0.154503804 | 79000   |
| 1000           | 100000  | 0.165329364 | 102000  |

Untuk grafik nilai MAE dan *Running Time* pada metode ini akan dijabarkan pada Gambar 7 berikut, untuk SVR-TVIWPSO nilai MAE terkecil terdapat pada pasangan iterasi *training* dan *testing* sebesar 700 dan 70000.

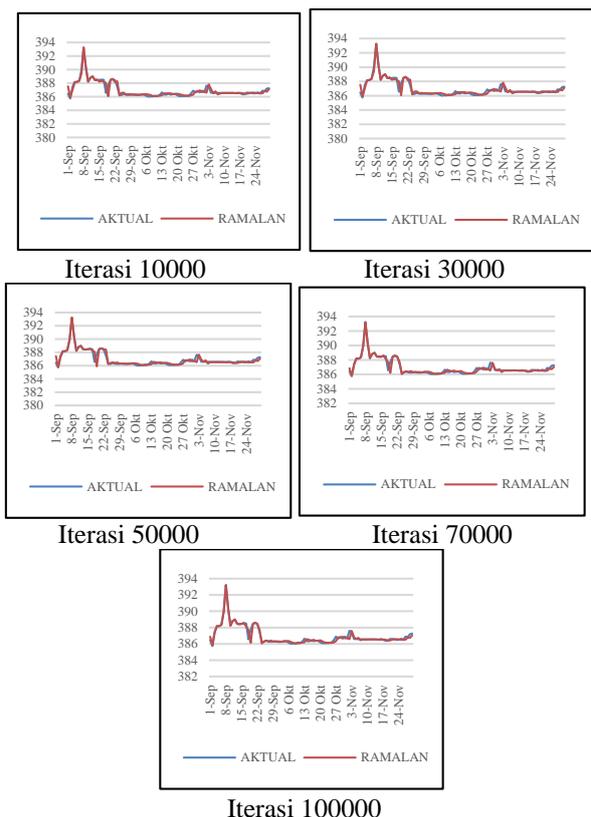


MAE

Running Time

Gambar 7 Grafik Nilai MAE dan *Running Time* untuk Uji Coba iterasi SVR pada SVR-TVIWPSO Skenario 1

Uji coba jumlah iterasi SVR yang selanjutnya masih menggunakan data *training* yang sama yaitu mulai bulan September hingga November di tahun 2010 dengan iterasi pada fase *training* dan fase *testing* yang sama besarnya, percobaan tersebut menghasilkan peramalan sesuai pada Gambar 8 :



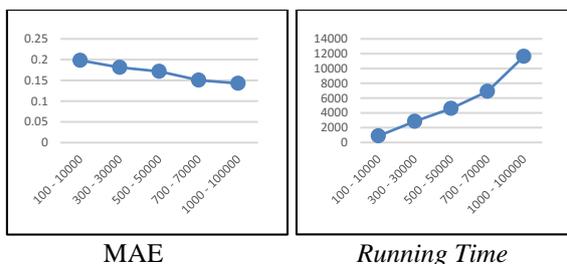
Gambar 8 Grafik Hasil Peramalan Uji Coba Iterasi SVR Skenario 2

Sedangkan untuk perbandingan nilai MAE dan *running time* dari masing – masing variasi uji coba tersebut akan dijabarkan pada Tabel 5 berikut :

Tabel 5 Nilai MAE dan *Running Time* Uji Coba Iterasi SVR Skenario 2

| Jumlah Iterasi |         | MAE         | RT (s) |
|----------------|---------|-------------|--------|
| Training       | Testing |             |        |
| 10000          | 10000   | 0.198293322 | 882    |
| 30000          | 30000   | 0.181245191 | 2837   |
| 50000          | 50000   | 0.171792325 | 4606   |
| 70000          | 70000   | 0.150324745 | 6910   |
| 100000         | 100000  | 0.142659943 | 11641  |

Untuk grafik nilai MAE dan *Running Time* pada metode ini akan dijabarkan pada Gambar 9 berikut :



Gambar 9 Grafik Nilai MAE dan *Running Time* untuk Uji Coba iterasi SVR pada SVR-TVIWPSO Skenario 2

Uji coba jumlah iterasi SVR pada metode SVR-TVIWPSO menghasilkan nilai MAE terkecil pada

pasangan iterasi *training* dan *testing* sebesar 100000, namun iterasi tersebut membutuhkan waktu komputasi yang paling besar dibandingkan seluruh uji coba iterasi yang pernah dilakukan. Indikasi nilai MAE paling kecil jatuh pada iterasi 100000 dikarenakan semakin banyak iterasi, maka semakin optimal pula proses *trade-off* dalam membentuk garis regresi, sehingga nilai *error rate* menjadi semakin kecil dan nilai  $\alpha$  dan  $\alpha^*$  juga akan semakin konvergen pada optimum global.

### 8. KESIMPULAN DAN SARAN

Metode SVR cukup akurat sebagai peramalan Tinggi Muka Air, dengan adanya integrasi SVR yang dioptimalisasi menggunakan TVIWPSO memberikan hasil yang jauh lebih akurat, semua nilai MAE pada 10 data bulanan yang digunakan dalam uji coba SVR-TVIWPSO lebih kecil dibanding MAE pada hasil uji coba SVR dengan kisaran nilai selisih MAE sebesar 0.07402 hingga 0.13239, nilai MAE terkecil didapatkan pada data Juni 2007 dengan nilai sebesar 0.00755 dengan SVR yang dioptimasi menggunakan TVIWPSO. Sedangkan untuk uji coba iterasi SVR nilai MAE paling kecil didapat pada jumlah iterasi *training* dan *testing* sebesar 100000 dengan nilai sebesar 0.142659943.

Penelitian ini masih belum sempurna sehingga masih perlu dilakukan pengembangan lebih lanjut, oleh karena itu penulis mengusulkan untuk pengembangan yang selanjutnya untuk :

1. Memberikan data histori yang lebih detail dari puluhan tahun sebelumnya agar pola datanya bisa dengan optimal dikenali oleh sistem.
2. Implementasi TVIWPSO ke depan tidak hanya untuk mengoptimasi parameter SVR, akan tetapi mengoptimasi juga banyaknya pola-pola data yang digunakan sebagai fitur, sehingga dapat diketahui berapa pola-pola data yang ideal untuk prediksi atau peramalan data uji pada ukuran waktu tertentu.

### 9. DAFTAR PUSTAKA

ALWEE, R., MARIYAM, S. & SALLEHUDDIN R. 2013. Hybrid Support Vector Regression and Autoregressive Integrated Moving Average Models Improved by Particle Swarm Optimization for Property Crime Rates Forecasting with Economic Indicators. *Hindawi Publishing Corporation The Scientific World Journal* 2013.

BU-HAI, S., LING, X., QI-PENG, W. & YOU LIANG, Z., 2014. Active Heave Compensation Prediction Research for Deep Sea Homework Crane based on SVR-KPSO. *Proceedings of the 33rd Chinese Control Conference, Nanjing, China* 2014.

CHAI, T. & DRAXLER R.R. 2014. Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? – Arguments Against

- Avoiding RMSE in The Literature. *Published by Copernicus Publications on behalf of the European Geosciences Union, Geosci. Model Dev.*, 7, 1247–1250, 2014.
- CHEN, H., YANG, B. & WANG, G. 2011. A Novel Bankruptcy Prediction Model Based on an Adaptive Fuzzy K-Nearest Neighbor Method. *College of Computer Science and Technology, Jilin University, Changchun 130012, China*.
- GUO, Y., 2009. An Integrated PSO for Parameter Determination and Feature Selection of SVR and its Application in SLTF. *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics, Baoding, 12-15 July 2009*
- JAVED, F., GREGORY, S.H.C. & SAVKIN A.V. 2009. RBF Kernel Based Support Vector Regression to Estimate The Blood Volume and Heart Rate Responses During Hemodialysis. *31st Annual International Conference of the IEEE EMBS Minneapolis, Minnesota, USA, September 2-6, 2009*.
- LIU, H. 2010. Internet Public Opinion Hotspot Detection and Analysis Based on KMEANS and SVM Algorithm. *2010 International Conference of Information Science and Management Engineering*.
- LI, Y. & CHEN, P. 2012. A Parallel SVR Model for Short Term Load Forecasting Based on Windows Azure Platform. *School of Control and Computer Engineering North China Electric Power University Bei Jing, China*.
- LU, C., LEE T. & LIAN, C. 2010. Sales Forecasting of IT Products using A Hybrid MARS and SVR MoDel. *2010 IEEE International Conference on Data Mining Workshops*
- MA, D., DING, N., WANG, J. & CUI J. 2010. Research on Flood Submergence Analysis System Based on ArcEngine Component Library. *Ministry of Construction P.R.China Science & Technology Planning Project(2010-K9-24)*.
- MEESUK, V., VOJINOVIC, Z. & MYNETT, A.E. 2012. Using Multidimensional Views of Photographs for Flood Modelling. *Hydro and Agro Informatics Institute, Ministry of Science and Technology, 978-1-4673-1975-1/12/\$31.00 ©2012 IEEE*
- NING, A. & ZHANG, X. 2010. A Speech Recognition System Based on Fuzzy Neural Network Optimized by Time Variant PSO. *2010 International Conference on Computational Aspects of Social Networks*.
- SAHAK, R., MANSOR, Y.K.L, ZABIDI, A. & YASSIN A.I.M. 2011. Orthogonal Least Square and Optimized Support Vector Machine with Polynomial Kernel for Classifying Asphyxiated Infant Cry. *2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA2011)*.
- SAUD, I. 2007. Kajian Penanggulangan Banjir di Wilayah Pematuan Surabaya Barat. *Jurnal Aplikasi Vol.3, No.1, ISSN : 1937-753X*.
- SENGUPTA, A. & MISHRA, V.K. 2014. Time Varying vs. Fixed Acceleration Coefficient PSO Driven Exploration during High Level Synthesis: Performance and Quality Assessment. *2014 13th International Conference on Information Technology*.
- SUTIKNO, BEKTI, R., SUSANTI, P. & ISTRIANA. 2010. Prakiraan Cuaca Dengan Metode Autoregressive Integrated Moving Average, Neural Network, dan Adaptive Splines Threshold Autoregression di Stasiun Juanda Surabaya. *Jurnal SAINS Dirgantara*.
- VIJAYAKUMAR, S. & WU S. 1999. Sequential Support Vector Classifiers and Regression. *RIKEN Brain Science Institute 1999, pp.610 – 619*.
- TONDE, C. & ELGAMMAL, A. 2014. Simultaneous Twin Kernel Learning using Polynomial Transformations for Structured Prediction. *2014 IEEE Conference on Computer Vision and Pattern Recognition*.
- WADEY, M.P., COPE, S.N., NICHOLLS, R.J. & MCHUGH, K. 2015. Coastal Flood Analysis and Visualisation for A Small Town. *Ocean & Coastal Management 116 (2015) 237e247*
- YOUNGJOO, K., JONGGEOL, P., ATSUHIRO Y. & KAZUHIKO F. 2012. Estimation Of Flood Volume in Chao Phraya River Basin, Thailand, From Modis Images Coupled with Flood Inundation Level. *International Centre for Water Hazard and Risk Management (ICHARM) under the auspices of UNESCO, Public Works Research Institute (PWRI), 978-1-4673-1159-5/12/\$31.00 ©2012 IEEE*.
- ZHAO, B., DING, X. & CAO, H. 2011. The Recognition of River Channel Flood Infiltration Capacity Based on Numerical Simulation. *Xi'an Research Institute of China Coal Technology & Engineering Group Corp Xi'an , China 978-1-61284-340-7/11/\$26.00 ©2011 IEEE*
- ZHENG, W. 2012. The Flood Monitoring Information System Framework Based on Multi-source Satellite Remote Sensing Data. *2012 International Conference on System Science and Engineering June 30-July 2, 2012, Dalian, China*.