

DOWNSCALING MODEL IKLIM (NCEP/NCAR REANALYSIS) SEBAGAI ALAT BANTU DALAM MEMPREDIKSI CURAH HUJAN AKIBAT PERUBAHAN IKLIM

Gusfan Halik¹, Nadjadji Anwar², dan Budi Santosa³

¹*Mahasiswa Program Studi Doktor Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan,
Institut Teknologi Sepuluh Nopember, Email: gusfan@gmail.com*

²*Staf Pengajar, Fakultas Teknik Sipil dan Perencanaan, Institut Teknologi Sepuluh Nopember,
Email: nadjadji@ce.its.ac.id*

³*Staf Pengajar, Fakultas Teknik Industri, Institut Teknologi Sepuluh Nopember,
Email: budi_s@ie.its.ac.id*

ABSTRAK

Pemanasan global telah memicu terjadinya perubahan iklim. Salah satu dampak perubahan iklim adalah berubahnya pola curah hujan secara spasial-temporal. Penelitian ini bertujuan untuk memanfaatkan data sirkulasi atmosfer dari satelit NOAA (NCEP/NCAR *reanalysis*) dalam memprediksi curah hujan bulanan akibat perubahan iklim. Data luaran NCEP/NCAR *reanalysis* mempunyai resolusi spasial yang kasar ($2.5^\circ \times 2.5^\circ$), sehingga tidak dapat digunakan untuk pemodelan hidrologi skala DAS (Daerah Aliran Sungai). Oleh karena itu diperlukan model *statistical downscaling*. Model *statistical downscaling* (SD) yang diusulkan merupakan penggabungan antara transformasi Wavelet dan *Support Vector Machine* (WSVM). Uji kalibrasi dan validasi model dilakukan di DAS Brantas Hulu dengan titik kontrol di Bendungan Sutami. Kalibrasi (training WSVM) dilakukan pada data curah hujan bulanan periode 1991-2007, sedangkan uji validasi (testing WSVM) dilakukan pada periode 2008-2012. Hasil running model WSVM menunjukkan bahwa prediksi curah hujan bulanan di DAS Brantas Hulu memiliki tingkat keandalan model yang berbeda antar stasiun pengamat hujan. Efek spasial letak stasiun hujan juga menentukan terhadap keandalan model SD. Dengan demikian dapat dinyatakan bahwa model SD luaran NCEP/NCAR *reanalysis* dengan WSVM dapat dimanfaatkan sebagai alat bantu untuk memprediksi curah hujan bulanan di DAS Brantas Hulu.

Kata kunci: : statistical downscaling, NCEP/NCAR reanalysis, WSVM, Brantas Hulu

PENDAHULUAN

Pemanasan global (*global warming*) yang disebabkan oleh peningkatan konsentrasi gas rumah kaca telah memicu terjadinya perubahan iklim. Perubahan iklim ini berdampak pada perubahan pola hujan secara spasial-temporal. Berdasarkan laporan ke-empat dari *Inter-governmental Panel on Climate Change* (IPCC 2007), pola hujan dan kejadian hujan ekstrim di negara Asia Tenggara akan mengalami perubahan seiring terjadinya perubahan iklim. Di Wilayah Indonesia, pola hujan juga mengalami perubahan signifikan secara spasial-temporal akibat perubahan iklim. Beberapa daerah di Indonesia telah terjadi pergeseran waktu kejadian bulan basah dan bulan kering (Lilik dan Berliana, 2007). Perubahan iklim juga memberikan pengaruh terhadap perubahan tren atau pola hujan pada skala Daerah Aliran Sungai (DAS) di Wilayah DAS Brantas Jawa Timur (Aldrian dan Jamil, 2008).

Kajian perubahan iklim dalam skala global dapat dimodelkan dengan menggunakan model sirkulasi atmosfir dari *National Oceanic and Atmospheric Administration, National Center for Environmental Prediction / National Center for Atmospheric Research - NOAA* (NCEP/NCAR *Reanalysis*). Data luaran NCEP/NCAR yang dihasilkan ini tidak dapat langsung dimanfaatkan dalam pemodelan hidrologi skala DAS, karena memiliki kelemahan (gap) pada resolusi spasialnya yang sangat rendah (kasar) (Wilby dkk., 2004 ; Fowler dkk., 2007). Resolusi spasial data luaran NCEP/NCAR sekitar $2.5^\circ \times 2.5^\circ$ lintang-bujur atau mempunyai ukuran grid sekitar dua ratus tujuh puluh kilometer. Ketidaksesuaian resolusi spasial GCM dengan skala lokal dapat dijembatani dengan mengembangkan teknik downscaling (Tolika dkk., 2007).

Teknik downscaling dapat dikelompokkan menjadi dua model pendekatan, yaitu : *Dynamic Downscaling (DD)* dan *Statistical Downscaling (SD)*. Pendekatan model DD merupakan *Regional Climate Model* (RCM) yang merujuk pada kondisi batas secara fisik GCM pada skala regional. Pendekatan ini memerlukan desain yang kompleks dan biaya komputasi yang sangat tinggi (Crane dan Hewitson, 1998 ; Tripathi dkk., 2006). Pendekatan model SD merupakan pendekatan yang relatif sederhana dan murah, dengan cara menentukan fungsi transfer (empiris) yang menghubungkan antara variabel sirkulasi atmosfer (prediktor) dengan variabel iklim lokal (prediktan). Ada tiga asumsi yang digunakan dalam model SD (Hewitson dan Crane, 1996), yaitu : a). prediktor adalah variabel luaran GCM yang relevan dan realistik, b. hubungan empiris ini berlaku juga pada kondisi iklim yang berubah, c). prediktor yang digunakan sepenuhnya mewakili signal iklim.

Berbagai model SD telah dikembangkan oleh beberapa peneliti, diantaranya : menggunakan model regresi linier berganda (Kidson dan Thompson, 1998 ; Kysely J., 2002), analisis korelasi kanonikal (Busuioc dkk., 2001), jaringan saraf tiruan (Coulibaly dan Dibike 2004 ; Tolika dkk., 2007) dan support vector machine (Tripathi dkk., 2006). Keuntungan model SD ini adalah tidak diperlukannya komputer yang banyak dan peralatan penunjang real time lainnya. Disamping itu, model SD ini telah memberikan kontribusi terhadap kemampuan RCM dalam menghasilkan prediktor yang relevan (Goodess dkk., 2006).

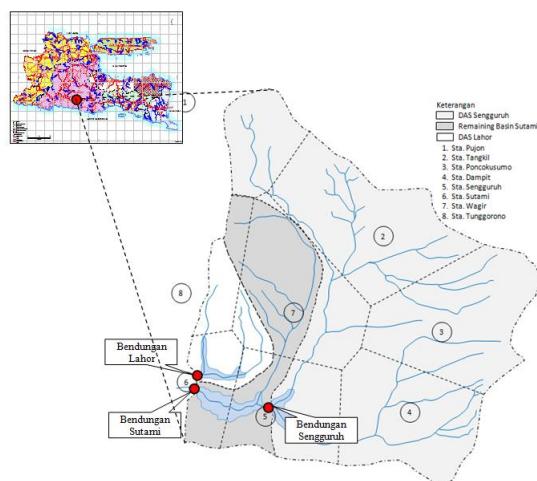
Penelitian ini bertujuan untuk memprediksi curah hujan bulanan menggunakan model SD luaran NCEP/NCAR yang sesuai dengan karakteristik iklim daerah tropis. Model SD yang dikembangkan merupakan gabungan antara transformasi wavelet (multiscale principal component analysis) dengan support vector machine. Uji kalibrasi dan validasi model SD dilakukan di DAS Brantas Hulu (Bendungan Sutami) Kabupaten Malang.

BAHAN DAN METODE

Bahan dan Lokasi Penelitian

Bahan penelitian untuk pemodelan SD curah hujan didapatkan dari luaran GCM dan data satelit NOAA (NCEP/NCAR *reanalysis*). Variabel prediktor data luaran NCEP/NCAR *reanalysis* terdiri dari : precipitation water (prwtr), sea level pressure (slp), relative humidity at 500 hPa (rhum500), specific humidity at 500 hPa (shum500), zonal velocity component (uwnd), meridional velocity component (vwnd), zonal velocity component at 850 hPa (uwnd850) dan meridional velocity component at 850 hPa (vwnd850).

Uji kalibrasi dan verifikasi model SD dilakukan stasiun penakar hujan yang terletak di DAS Brantas Hulu (Bendungan Sutami). Luas DAS keseluruhan sebesar 2052 Km², dengan 8 (delapan) stasiun penakar hujan. Secara administratif lokasi penelitian terletak di Desa Karangkates, Kecamatan Sumberpucung, Kabupaten Malang. Secara geografis, DAS Brantas Hulu terletak di koordinat antara 7° 44' 29" sampai 8° 19' 47" LS (Lintang Selatan) dan antara 112° 27' 25" sampai 112° 55' 23" BT (Bujur Timur). Lokasi penelitian ditunjukkan pada Gambar 1.



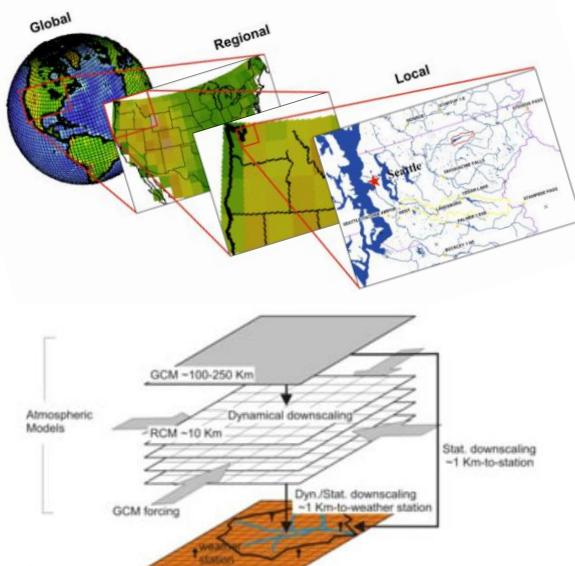
Gambar 1. Lokasi Penelitian

Konsep Dasar Downscaling

Downscaling didefinisikan sebagai upaya untuk menghubungkan antara sirkulasi skala global (variabel prediktor) dengan skala lokal (variabel prediktan). Downscaling lebih menunjukkan pada proses perpindahan dari prediktor ke prediktan, yaitu perpindahan dari skala besar (resolusi rendah) ke skala kecil (resolusi tinggi). Von Storch (1999) menyatakan bahwa *downscaling* didasarkan pada asumsi bahwa iklim regional dipengaruhi oleh iklim skala global (benua).

Teknik *downscaling General Circulation Model* (GCM) dapat dibedakan dalam dua pendekatan, yaitu : model *Dynamic Downscaling Model (DD)* dan model *Statistical Downscaling (SD)*. Pendekatan model DD merupakan proses *downscaling* berdasarkan pendekatan proses (*process based*) yang dirunning secara terus menerus, yang dilakukan pada grid dengan skala yang lebih kecil mengikuti perubahan variabel prediktor yang sama pada grid berskala besar (GCM). Pendekatan ini memerlukan desain yang kompleks dan biaya komputasi yang tinggi (Crane dan Hewitson, 1998; Tripathi dkk., 2006). Pendekatan model SD merupakan proses *downscaling* berdasarkan persamaan empiris (*empirical techniques*) yang dilakukan secara statik pada grid berskala besar pada periode jangka waktu tertentu sebagai dasar penentuan data pada grid yang berskala lebih kecil. Menurut Uvo dkk. (2001), teknik SDSM ini menduga nilai variabel meteorologis dalam selang waktu tertentu berdasarkan karakteristik sirkulasi atmosfer yang berskala besar (GCM) ke variabel lokal yang berskala lebih kecil. model SD merujuk pada upaya mencari informasi skala lokal berdasarkan skala global melalui hubungan inferensi dengan acak atau deterministik. Ilustrasi *downscaling* ditunjukkan pada Gambar 2.

Dalam kajian klimatologi jangka panjang, GCM merupakan suatu model yang berorientasi secara spasial dan temporal serta mampu menghasilkan ciri sirkulasi global pada skala besar (skala benua). Besarnya skala besar ini menyebabkan tingkat resolusi GCM menjadi rendah, sehingga informasi GCM ini tidak dapat langsung digunakan dalam skala lokal. Namun demikian, GCM masih dapat dipakai untuk memperoleh informasi skala lokal atau regional dengan menggunakan model *statistical downscaling*.



Gambar 2. Konsep Downscaling

Data luaran GCM mempunyai resolusi spasial (grid domain) yang kasar. Model SD dapat menghubungkan antara data luaran GCM yang berskala global pada grid domain tertentu dengan data pengukuran pada skala lokal. Penentuan grid domain GCM akan mempengaruhi keberhasilan prediksi curah hujan dalam pemodelan SD (Wilby dan Wigley, 2000). Prediksi curah hujan akan menjadi lebih akurat, apabila pemilihan grid domain dilakukan secara tepat, baik ukuran luasan maupun lokasinya (Wigena dkk., 2006).

Principal Component Analysis (PCA)

PCA pada dasarnya bertujuan untuk menyederhanakan variabel yang diamati dengan cara menyusutkan (mereduksi) dimensinya. Hal ini dilakukan dengan cara menghilangkan korelasi diantara variabel bebas melalui transformasi beberapa variabel bebas asal ke variabel baru yang tidak berkorelasi sama sekali atau yang biasa disebut dengan komponen utama (*principal component*). PCA dapat dibentuk dengan dua cara, yaitu dengan matrik kovarian dan matrik korelasi (Jolliffe, 2002).

Transformasi Wavelet

Transformasi wavelet merupakan metode prapemrosesan yang dilakukan dalam mereduksi dimensi variabel bebas (prediktor) dalam pemodelan regresi, sehingga akan dihasilkan model regresi yang mempunyai ukuran kebaikan model yang relatif baik untuk prediksi. Berbagai penelitian perkembangan transformasi wavelet yang telah dilakukan, diantaranya : penggabungan metode transformasi wavelet dengan metode pemodelan kalibrasi peubah ganda (Sunaryo dkk. 2005), reduksi dimensi data spektra dengan fourier dan wavelet (Sunaryo dan Notodipuro 2004), dekomposisi dan rekonstruksi data deret berkala (*time series*) debit aliran sungai menggunakan wavelet (Guo dkk. 2011, Kisi dan Cimen 2011).

Kelebihan transformasi wavelet jika dibandingkan PCA dalam mereduksi dimensi data adalah kemampuan kombinasi linier kurva-kurva lain yang dikenal dengan fungsi basis. Fungsi basis ini diperoleh dengan dilatasi dan translasi dua jenis fungsi wavelet, yaitu : *father wavelet* (ϕ) dan *mother wavelet* (ψ) (Sunaryo dkk., 2005).

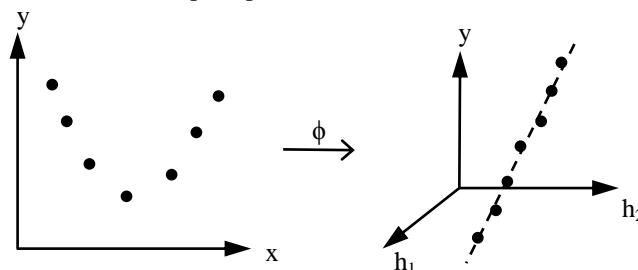
Multiscale Principal Component Analysis (MSPCA)

Hasil reduksi dimensi dengan metode transformasi wavelet ini masih dimungkinkan terjadi multikolinieritas, sehingga diperlukan analisis PCA. Penggabungan reduksi dimensi data metode transformasi wavelet dan PCA dikenal dengan metode MSPCA (*Multiscale Principal Component Analysis*). MSPCA menggabungkan kemampuan PCA dalam mengekstraksi hubungan antar variabel (korelasi silang) dengan wavelet ortogonal untuk memisahkan fitur deterministik dari proses stokastik yang mempunyai autokorelasi antar variabel. Dalam MSPCA, pengukuran setiap variabel didekomposisikan menggunakan koefisien wavelet orthonormal yang sama, sehingga akan dihasilkan matrik transformasi dari matrik data X menjadi matrik WX , dengan W merupakan matrik $n \times n$ transformasi wavelet orthonormal dengan operator koefisien filter. Metode MSPCA sangat sesuai untuk prapemrosesan data yang mengandung efek spasial dimana data pada lokasi spasial yang berbeda akan mempunyai lokalisasi waktu dan frekuensi berbeda pula (Bakshi 1998).

Support Vector Machine (SVM)

Dalam beberapa dekade sebelumnya, metode pembelajaran tradisional pada *Artificial Neural Networks* (ANN) seperti : *Multi Layer Back Propagation* (MLBP) dan *Radial Basis Function* (RBF) telah digunakan secara intensif dibidang pemodelan hidrologi. Permasalahan lokal optima (*overfitting*) sering dihadapi dalam pemodelan dengan ANN (Suyken 2001). Untuk mengatasi permasalahan ini, Vapnik dkk. 1998 mengembangkan algoritma baru yang dikenal dengan *support vector machine* (SVM). SVM merupakan metode yang dapat mengatasi *overfitting* sehingga dapat menghasilkan performa yang lebih baik jika dibandingkan ANN (Santosa, 2007).

Hubungan pola data (x_i, y_i) dalam SVM merupakan transformasi non linier ϕ dari ruang vektor input (*input space*) dengan ruang vektor baru yang berdimensi lebih tinggi (*feature space*). Transformasi non linier dalam SVM diilustrasikan seperti pada Gambar 3 (Hsieh, 2009).



Gambar 3. Transformasi Non Linier ϕ dari Input Space ke Feature Space

Hubungan non linier ini dapat dinyatakan dalam persamaan berikut :

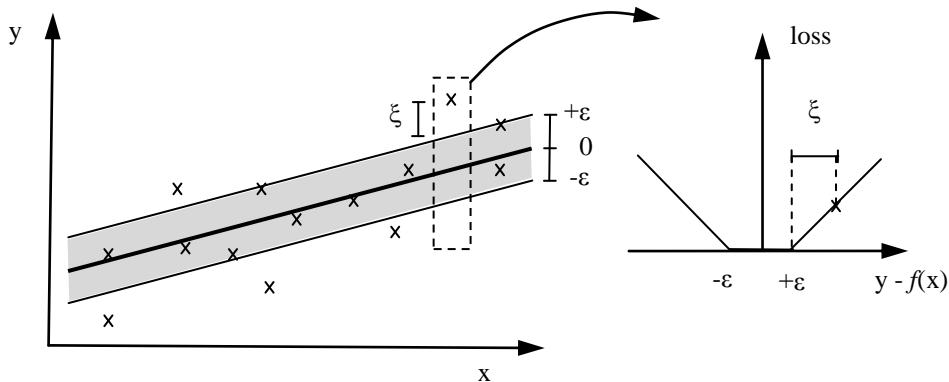
$$\hat{y} = f(x) = w^T \phi(x) + b \quad (1)$$

Dengan \hat{y} merupakan prediksi luaran model dan koefisien w ; b merupakan estimasi parameter model. Nilai parameter w dan b dalam persamaan (1), dapat diestimasi dengan cara meminimalkan fungsi sasaran berikut (Haykin 2003, Smola dan Scholkopf 2004) :

$$\text{Minimize : } \psi(w, \xi, \xi^*) = \frac{1}{2} w^T w + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (2)$$

$$\begin{aligned} \text{Subject to : } & y_i - \hat{y}_i \leq \varepsilon + \xi_i & i = 1, 2, \dots, n \\ & -y_i + \hat{y}_i \leq \varepsilon + \xi_i^* & i = 1, 2, \dots, n \\ & \xi_i \geq 0 & i = 1, 2, \dots, n \\ & \xi_i^* \geq 0 & i = 1, 2, \dots, n \end{aligned}$$

Dengan ξ_i dan ξ_i^* merupakan variabel slack positif dan C merupakan konstanta real. Tahap penyelesaian pertama dari fungsi sasaran ini adalah mencari nilai w yang sesuai untuk meningkatkan generalisasi model. Tahap kedua menyelesaikan fungsi penalti diatas dengan menggunakan fungsi kehilangan. Menurut Smola dan Scholkopf (2004), setting softmargin dalam SVM ditunjukkan pada Gambar 4.



Gambar 4. Setting Softmargin SVM

Optimasi penyelesaian beberapa kendala diatas dapat diselesaikan dengan menggunakan metode *langrange multiple* (Haykin 2003), yang dinyatakan dalam persamaan berikut :

$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \cdot \phi(x_i) \quad (3)$$

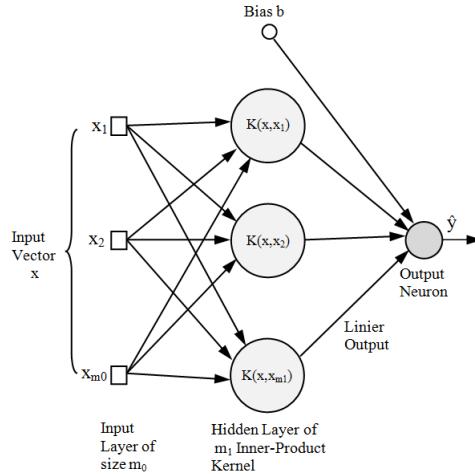
Dengan α_i dan α_i^* adalah *langrange multiple* yang merupakan bilangan real positif. Data point yang tidak bernilai nol pada $(\alpha_i - \alpha_i^*)$ disebut dengan *support vector*. Dari persamaan (3) didapatkan estimasi fungsi non linier SVM yang dinyatakan dalam persamaan :

$$\hat{y} = f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (4)$$

Dengan $K(x_i, x_j)$ merupakan fungsi kernel berdasarkan Teori Mercer dan b adalah bias. Nilai fungsi kernel dinyatakan dalam persamaan :

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (5)$$

Beberapa fungsi kernel yang dapat dipakai diantaranya : polinomial, Gaussian atau Radian Basis Function (RBF) dan sigmoid. Arsitektur SVM untuk regresi dapat dilihat pada Gambar 5 (Haykin, 2003).



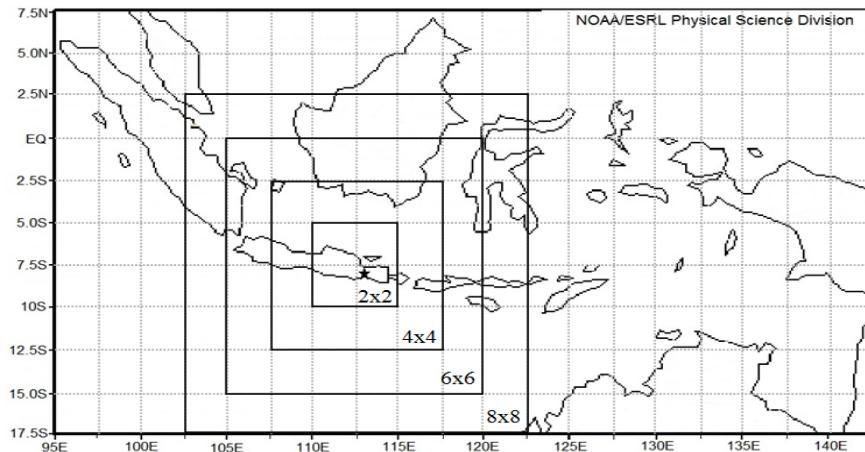
Gambar 5. Arsitektur SVM

Keandalan Model SD

Keandalan model SD dievaluasi dengan cara membandingkan antara curah hujan luaran model dengan curah hujan hasil observasi dari masing-masing stasiun penakar hujan. Kriteria keandalan model dievaluasi menggunakan *Root Mean Square Error* (RMSE), *Mean Absolut Error* (MAE) dan koefisien korelasi (R).

HASIL DAN PEMBAHASAN

Data sirkulasi atmosfer luaran NCEP/NCAR reanalysis (variabel prediktor) mempunyai dimensi yang tinggi, saling berkorelasi dan resolusi spasial yang kasar. Penentuan grid domain baik ukuran maupun lokasinya akan menentukan tingkat akurasi model SD. Ukuran grid domain NCEP/NCAR reanalysis dapat dilihat pada Gambar 6.



Gambar 6. Ukuran Grid Domain NCEP/NCAR reanalysis

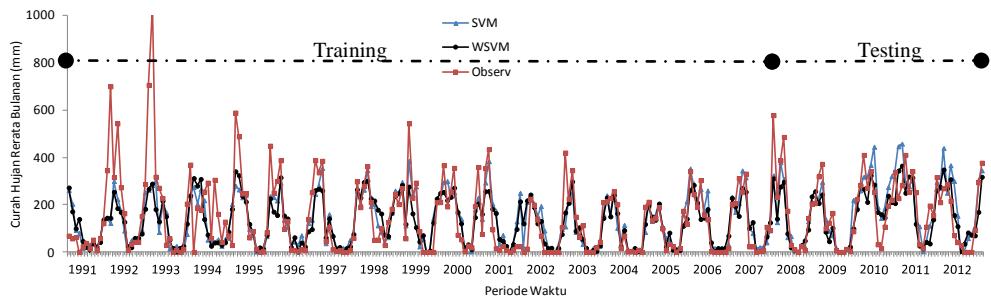
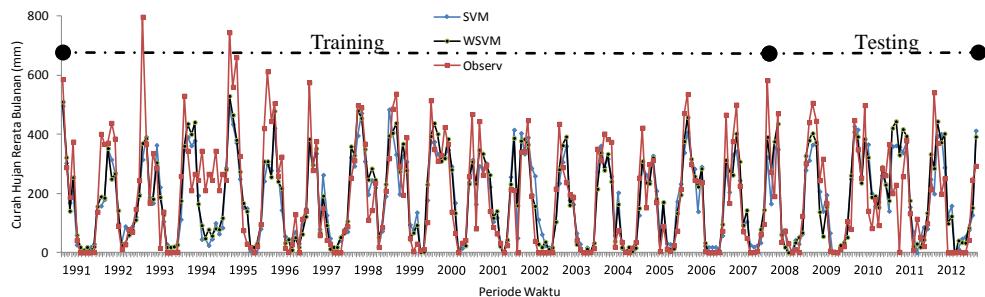
Penggunaan grid domain yang terlalu kecil akan mengurangi informasi pengaruh regional/global, sedangkan penggunaan grid domain yang terlalu besar akan mengakibatkan informasi lokal yang akan berkurang. Oleh karena itu, diperlukan grid domain yang optimal. Pemilihan grid domain yang sesuai di lokasi penelitian didasarkan pada nilai koefisien korelasi dari masing-masing grid domain. Nilai koefisien korelasi untuk berbagai grid domain NCEP/NCAR reanalysis ditunjukkan pada Tabel 1.

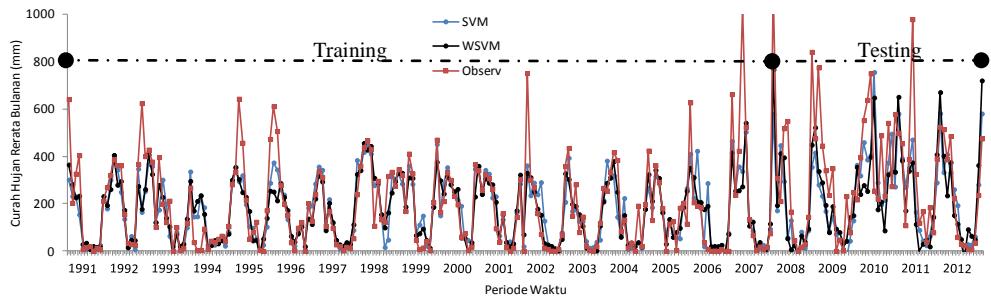
Tabel 1. Nilai Koefisien Korelasi pada Berbagai Grid Domain

No.	Ukuran Grid Domain	Korelasi
1	2 x 2	0.744
2	4 x 4	0.781
3	6 x 6	0.818
4	8 x 8	0.758
5	10 x 10	0.768
6	12 x 12	0.743
7	14 x 14	0.766

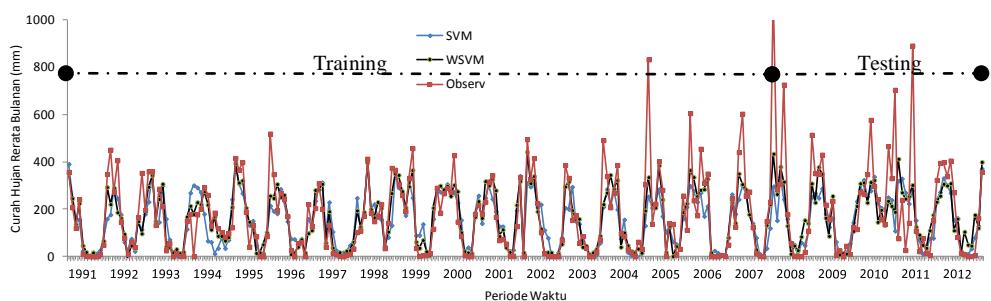
Berdasarkan Tabel 1, dapat ditentukan bahwa grid domain 6 x 6 merupakan grid yang optimal untuk pemodelan SD curah hujan di DAS Brantas Hulu Kabupaten Malang.

Setelah grid domain yang optimal didapatkan, selanjutnya dilakukan pemodelan SD curah hujan pada berbagai stasiun penakar hujan di DAS Brantas Hulu menggunakan model non linier SVM. Input model SVM diambil berdasarkan hasil reduksi dimensi prediktor luaran NCEP/NCAR reanalysis dengan metode PCA (SVM) dan metode MSPCA berbasis transformasi wavelet (WSVM). Kalibrasi (training) model SD dilakukan pada data curah hujan pengamatan mulai tahun 1991 sampai 2007, sedangkan validasi (testing) model SD dilakukan pada periode 2008 sampai 2012. Training model SVM dilakukan untuk mendapatkan parameter model yang optimal, meliputi : nilai C, tipe kernel dan parameter kernel. nilai parameter optimal model didapatkan pada tipe kernel *Radial Basis Function* (RBF) dengan nilai gamma = 0 dan parameter C = 10. Hasil running model SD hujan bulanan dengan SVM dan WSVM pada tahap training dan testing untuk berbagai lokasi stasiun penakar hujan dapat dilihat pada Gambar 7 sampai Gambar 14.

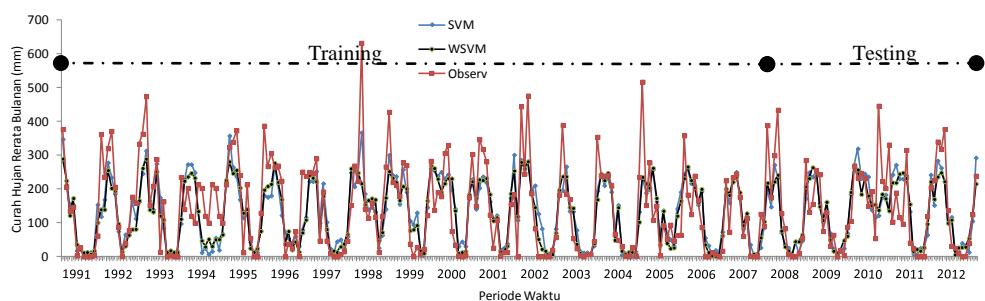
**Gambar 7. Hasil Running Model SD Hujan Bulanan di Stasiun Pujon****Gambar 8. Hasil Running Model SD Hujan Bulanan di Stasiun Poncokusumo**



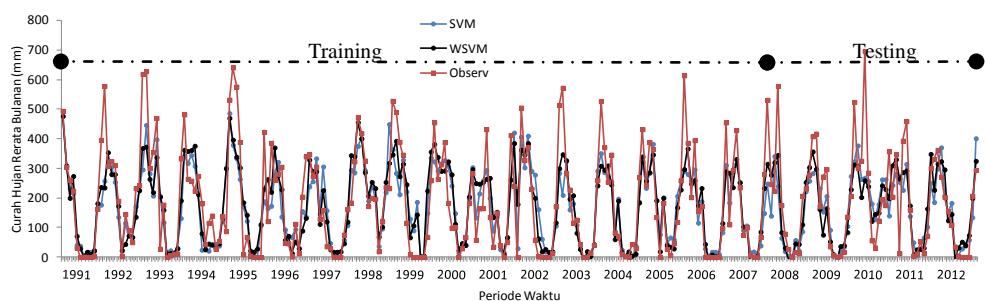
Gambar 9. Hasil Running Model SD Hujan Bulanan di Stasiun Dampit



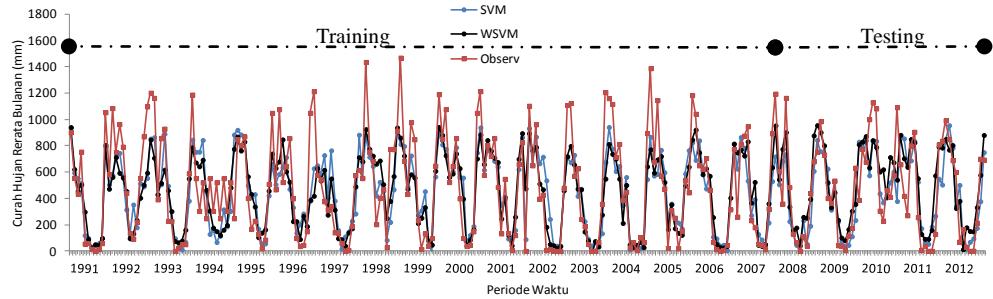
Gambar 10. Hasil Running Model SD Hujan Bulanan di Stasiun Sengguruh



Gambar 11. Hasil Running Model SD Hujan Bulanan di Stasiun Sutami



Gambar 12. Hasil Running Model SD Hujan Bulanan di Stasiun Wagir



Gambar 13. Hasil Running Model SD Hujan Bulanan di Stasiun Tunggorono

Prediksi curah hujan bulanan hasil model SD dengan SVM dan WSVM mempunyai pola atau tren yang mendekati pola observasinya pada masing-masing stasiun hujan (Gambar 7-13). Namun demikian, prediksi curah hujan terbesar (maksimum) antara hasil model SD (SVM dan WSM) masih terjadi deviasi (penyimpangan) yang cukup tinggi antara hasil luaran model SD (SVM dan WSVM) jika dibandingkan dengan curah hujan observasinya. Keandalan model SD dievaluasi menggunakan beberapa indikator, diantaranya : koefisien korelasi (R), *Root Mean Square Error* (RMSE) dan *Mean Absolut Error* (MAE). Nilai indikator keandalan model SD (SVM dan WSVM) ditunjukkan pada Tabel 2.

Tabel 2. Nilai Indikator Keandalan Model (R, RMSE dan MAE)

No.	Nama Stasiun	Training SVM			Testing SVM			Training WSVM			Testing WSVM		
		R	RMSE	MAE	R	RMSE	MAE	R	RMSE	MAE	R	RMSE	MAE
1	Pujon	0.727	112.14	62.33	0.794	89.34	66.40	0.723	114.81	67.55	0.822	78.35	60.69
2	Poncokusumo	0.834	103.65	71.74	0.732	111.85	79.83	0.859	95.12	65.65	0.771	109.03	78.81
3	Dampit	0.813	113.36	63.96	0.646	195.64	141.61	0.836	109.32	60.71	0.656	195.23	147.48
4	Sengguruh	0.740	114.64	66.86	0.652	159.02	95.95	0.848	90.44	48.56	0.675	152.21	98.71
5	Sutami	0.784	81.41	58.30	0.743	81.31	57.66	0.794	80.80	55.00	0.751	80.11	56.13
6	Wagir	0.822	100.70	68.32	0.748	111.55	79.44	0.839	95.47	66.58	0.789	102.88	70.28
7	Tunggorono	0.810	233.41	169.53	0.774	225.26	169.52	0.837	221.74	157.86	0.813	214.42	175.88

Model SD dengan WSVM dalam memprediksi hujan bulanan di DAS Brantas Hulu memiliki keandalan yang lebih baik jika dibandingkan dengan SVM. Hal ini ditunjukkan dari nilai korelasi WSVM yang lebih tinggi dibandingkan nilai korelasi SVM. Secara spasial, lokasi stasiun penakar yang terletak di daerah dataran tinggi (Sta. Pujon, Sta. Wagir dan Sta. Tunggorono) memberikan hasil prediksi hujan yang lebih baik daripada lokasi stasiun penakar hujan yang terletak di daerah dataran rendah (Sta. Poncokusumo, Sta. Dampit, Sta. Sengguruh dan Sta. Sutami). Disamping itu, prediksi hujan bulanan tidak dipengaruhi oleh tipe musim, tetapi dipengaruhi lokasi spasial stasiun penakar hujan. Hasil penelitian menunjukkan kesesuaian dengan hasil penelitian yang dilakukan oleh Wigena dkk (2006) dan Sutikno dkk (2008).

KESIMPULAN

Berdasarkan hasil dan pembahasan diatas dapat disimpulkan bahwa model SD luaran NCEP/NCAR *reanalysis* dengan WSVM dapat digunakan sebagai alat bantu dalam memprediksi curah hujan bulanan di DAS Brantas Hulu Kabupaten Malang. Efek spasial letak stasiun penakar hujan sangat menentukan terhadap kinerja atau keandalan model prediksi hujan yang dihasilkan. Penulis menyarakan untuk meningkatkan kinerja model SD terutama dalam memprediksi hujan ekstrim (tinggi).

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada DIKTI dan LP UNEJ yang telah membantu telah membantu pendanaan penelitian ini melalui skem penelitian desentralisasi Disertasi Doktor sumberdana BOPTN UNEJ 2014.

DAFTAR PUSTAKA

- Adrian E dan Y.S. Djamil. 2008. *Spatio-Temporal Climatic Change of Rainfall in East Java Indonesia*. International Journal of Climatology (28) : 435-448.
- Bakshi B.R., 1998. *Multiscale PCA with Application to Multivariate Statistical Process Monitoring*. AIChE Journal, 44, pp.1596-1610.
- Busuioc A, Deliang C, Hellstrom C. 2001. Performance of statistical Downscaling models in GCM validation and regional climate change estimates: application for Swedish precipitation. *International Journal of Climatology* 21: 557–578.
- Coulibaly P. dan Dibike Y.B., 2004. Downscaling Precipitation and Temperature with Temporal Neural Networks. *American Meteorology Society* (6) : 483-496.
- Crane R.G., Hewitson B.C., 1998. Doubled CO₂ Precipitation Change for the Susquehanna Basin : Downscaling from the Genesis General Circulation Model. *International Journal of Climatology* (18) : 65-76.
- Fowler H.J., S. Blenkinsop, dan C. Tebaldi. 2007. *Review Linking Climate Change Modelling to Impact Studies : Recent Advances in Downscaling Techniques for Hydrological Modelling*. International Journal of Climatology (27), pp. 1547-1578.
- Goodess CM, Anagnostopoulou C, B'ardossy A, Frei C, Harpham C, Haylock MR, Hundecha Y, Maher P, Ribalaygue J, Schmidli J, Schmitt T, Tolika K, Tomozeiu R, Wilby RL. 2006. An intercomparison of statistical downscaling methods for Europe and European regions-assessing their performance with respect to extreme temperature and precipitation events. *Climatic Research Unit Research Publication 11 (CRU RP11)*.
- Guo J., J. Zhou, H. Qin, Q. Zou, dan Q. Li. 2011. *Monthly Streamflow Forecasting Based on Improved Support Vector Machine Model*. Expert System with Applications (38), pp. 13073-13081.
- Haykin. 2003. *Neural Networks : A Comprehensive Foundation*. Fourth Indian Reprint, Pearson Education Singapore.
- Hewitson, B.C., dan R.G. Crane. 1996. *Climate Downscaling: Techniques and Application*. Climate Research (7), pp. 85–95.
- IPCC, 2007. *Climate change 2007: The physical science basis. Contribution of working group II to the fourth assessment report on the Intergovernmental Panel on Climate Change*. Cambridge University Press.
- Jolliffe 2002. Principal Component Analysis. Second Edition, Springer-Verlag.
- Kidson JW, Thompson CS. 1998. A comparison of statistical and model – based downscaling techniques for estimating local climate variations. *Journal of Climate* (11) : 735–753.
- Kisi O., dan M. Cimen. 2011. *A Wavelet Support Vector Machine Conjunction Model for Monthly Streamflow Forecasting*. Journal of Hydrology, 339, pp.132-140.
- Kysely J., 2002. Comparison of extremes in GCM-simulated downscaled and observed central – European temperature series. *Climate Research* 20: 211–222.
- Lilik Slamet S., dan S.S. Berliana. 2007. *Indikasi Perubahan Iklim dari Pergeseran Bulan Basah, Bulan Kering dan Lembab*, disajikan pada Seminar Nasional Pemanasan Global dan Perubahan Global - Fakta, Mitigasi dan Adaptasi, LAPAN, 15 Nopember 2007, Bandung, Jawa Barat.
- Santosa B., 2007. Data Mining : Teknik Pemanfaatan Data untuk Keperluan Bisnis. Penerbit Graha Ilmu - Yogyakarta.
- Smola A., dan B. Scholkopf. 2004. *A Tutorial on Support Vector Regression*. Statistic and Computing 14, pp 199-222. Kluwer Academic Publisher. Manufactured in The Netherlands.
- Sunaryo S., dan K.A. Notodipuro. 2004. *Reduksi Dimensi Data Spektra dengan Fourier dan Wavelet*. Seminar Nasional Statistika, Departemen Statistika IPB, Bogor, 4 September 2004.
- Sunaryo S., dan K.A. Notodipuro, L.K. Darusalam, dan I.W. Mangku. 2005. *Model Kalibrasi dengan Transformasi Wavelet Sebagai Metode Pra-Pemrosesan*. Desertasi – IPB.
- Sutikno, B. Rizaldi, A. Bey, K.A. Notodipuro, dan I. Las. 2008. *Statistical Downscaling Luaran GCM dan Pemanfaatannya untuk Peramalan Poduksi Padi*. Desertasi – IPB.
- Suykens, J.A.K., 2001. *Nonlinear modelling and support vector machines*. In: Proceedings of IEEE Instrumentation and measurement technology conference, Budapest, Hungary, pp. 287–294.
- Tolika K., P. Maher, M. Vafiadis, H.A. Flocas, dan A.A. Papadimitriou. 2007. *Simulation of Seasonal Precipitation and Raindays Over Greece: A Statistical Downscaling Technique Based on Artificial Neural Networks (ANNs)*. Int. J. Climatol. 27, pp. 861–881.
- Tripathi V., V. V. Srinivas, dan R. S. Nanjundiah. 2006. *Downscaling of Precipitation for Climate Change Scenarios : A Support Vector Machine Approach*. Journal of Hydrology 330, pp. 621-640.

- Uvo C.B. 2001. *Statistical Atmospheric Downscaling for Rainfall Estimations in Kyushu Island Japan*. Hydrol & Earth Sys. Sci. 5(2), pp 259-271.
- Von Stroch H., 1999. On the Use of Inflation in Statistical Downscaling. *Journal Of Climate* (12) : 3505-3506.
- Wigena A.H., Aunuddin, Barizi, dan R. Boer. 2006. *Pemodelan Statistical Downscaling dengan Regresi Projection Pursuit untuk Peramalan Curah Hujan Bulanan*. Kasus : Curah Hujan Bulanan di Indramayu. Desertasi – IPB.
- Wilby R.L., dan T.M. Wigley. 2000. *Precipitation Predictors for Downscaling : Observed and General Circulation Model Relationships*. Int. J. Climatol. 20 : 641-661.
- Wilby R.L., S.P. Charles, E. Zorita, B. Timbal, P. Whetton, dan L.O. Mearns. 2004. Guidelines for Use Climate Scenarios Develop from Statistical Downscaling Methods.