

**MODEL DEBIT DAERAH ALIRAN SUNGAI JANGKOK  
BERDASARKAN HASIL PREDIKSI MODEL STATISTICAL DOWNSCALING  
NONPARAMETRIK KERNEL CURAH HUJAN DAN TEMPERATUR**

**Mustika Hadijati, Irwansyah**

Program Studi Matematika, FMIPA, Universitas Mataram

e-mail: [mustika.hadijati@unram.ac.id](mailto:mustika.hadijati@unram.ac.id)

**DOI: 10.14710/medstat.12.2.236-245**

---

**Article Info:**

Received: 7 November 2018  
Accepted: 29 December 2019  
Available Online: 30 December 2019

**Keywords:**

*Statistical Downscaling,  
GCM,  
CART, Kernel  
Nonparametric*

.

**Abstract:** River water discharge is important information for water resources management planning, so it is necessary to develop river water discharge model as basis of its predictions. In order to get the result of predictions of river water discharge with high accuracy, it is developed a model of river water discharge based on the predictions of local climate (local rainfall and temperature) that are influenced by global climate conditions. Prediction of local climate is based on the Kernel nonparametric statistical downscaling model by utilizing GCM data. GCM data is a high dimensional global data, so data pre-processing is needed to reduce data dimension. It is done by CART algorithm. Statistical downscaling model is used to predict local rainfall and temperature. The prediction results are quite good with relatively small RMSE value. They are used to develop model of river water discharge. Modeling river water discharge is carried out using the Kernel nonparametric approach. The model of river water discharge produced is quite good because it can be used to predict river water discharge with relatively small RMSE.

---

## 1. PENDAHULUAN

Debit air sungai merupakan informasi yang sangat diperlukan dalam perencanaan pengelolaan sumber daya air sebagai upaya mitigasi dan adaptasi terhadap bencana banjir dan kekeringan, demikian pula di Pulau Lombok yang rentan terhadap bencana banjir dan kekeringan. Oleh karena itu diperlukan pemodelan debit air sungai dengan ketepatan tinggi agar diperoleh prediksi debit yang tepat sebagai acuan dalam perencanaan pengelolaan sumber daya air tersebut. Model tersebut dikembangkan berdasarkan faktor-faktor yang mempengaruhi debit air sungai, seperti curah hujan dan temperatur.

Akhir-akhir ini telah banyak dikembangkan model debit air sungai dengan memanfaatkan data luaran *General Circulation Model* (GCM) yang berskala global agar mendapatkan prediksi debit air sungai yang lebih akurat (Gagnon *et al.*, 2005; Samadi *et al.*, 2012; Sachindra *et al.*, 2015). GCM merupakan model berbasis komputer yang terdiri

atas berbagai persamaan numerik dan deterministik yang terpadu dan mengikuti kaidah-kaidah fisika. GCM merupakan alat prediksi utama cuaca dan iklim secara numerik (Wigena, 2006). Namun, data luaran GCM kurang tepat digunakan untuk peramalan berskala lokal/regional karena masih berskala global. Untuk itu perlu dilakukan regionalisasi, salah satunya dengan menggunakan teknik *statistical downscaling* (SD). *Statistical downscaling* (SD) merupakan proses *downscaling* yang bersifat statik, dimana data pada grid-grid berskala besar dalam periode dan jangka waktu tertentu digunakan sebagai dasar untuk menentukan data pada grid berskala lebih kecil (Wigena, 2006). Dengan SD akan disusun model hubungan fungsional antara informasi luaran GCM dengan informasi variabel iklim lokal/regional.

Penentuan metode SD perlu mempertimbangkan sifat data luaran GCM dan data iklim yang pada umumnya bersifat nonstasioner, nonlinear, dan tidak berdistribusi normal. Data luaran GCM merupakan data spasial dan temporal yang bersifat *curse of dimensionality*, sehingga memungkinkan terjadinya korelasi spasial antara data pada grid yang berbeda dalam satu domain. Oleh karena itu dalam pemodelan SD diperlukan prapemrosesan data GCM dengan mereduksi dimensinya. Salah satu metode yang dapat digunakan adalah algoritma *Classification and Regression Tree* (CART) yang sesuai dengan sifat data GCM dan data iklim (Zorita and Storch, 1999; Kannan dan Ghosh, 2013; Hadijati et al., 2015). Adapun metode SD yang sesuai dengan sifat data luaran GCM dan data iklim adalah metode yang tidak mensyaratkan asumsi linear, stasioner, dan distribusi normal. Metode tersebut umumnya adalah metode regresi nonparametrik, salah satunya adalah regresi nonparametrik Kernel (Kannan dan Ghosh, 2013; Hadijati et al., 2016; Singh et al., 2016).

Berdasarkan uraian tersebut, penelitian ini bertujuan membuat model debit air sungai pada DAS Jangkok Pulau Lombok berdasarkan data prediksi curah hujan dan temperatur DAS Jangkok yang diperoleh berdasarkan model *statistical downscaling* nonparametrik Kernel dengan memanfaatkan data luaran GCM. Hal ini dilakukan sebagai alternatif pemodelan debit air sungai di Indonesia, khususnya di Pulau Lombok, yang selama ini umumnya dilakukan dengan memanfaatkan data berskala lokal. Selanjutnya dilakukan prediksi debit air sungai berdasarkan model yang diperoleh..

## 2. TINJAUAN PUSTAKA

### 2.1. Statistical Downscaling

Teknik *downscaling* merupakan proses transformasi data dari suatu grid dengan unit skala besar menjadi data pada grid-grid dengan unit skala yang lebih kecil. (Fernandez, 2005). Teknik ini digunakan untuk regionalisasi data GCM yang bersifat global agar dapat digunakan untuk peramalan berskala local atau regional. Ada dua pendekatan *downscaling*, yaitu *dynamic downscaling* dan *statistical downscaling*. *Statistical Downscaling* (SD) adalah suatu proses *downscaling* yang bersifat statik dimana data pada grid-grid berskala besar dalam periode dan jangka waktu tertentu digunakan sebagai dasar untuk menentukan data pada grid berskala lebih kecil (Wigena, 2006). Dengan pendekatan SD, dibangun hubungan fungsional antara data iklim skala local dengan data skala global GCM dimana bentuk hubungan tersebut secara umum dinyatakan sebagai berikut (Lembang, 2009)

$$\mathbf{Y} = f(\mathbf{X}) + \boldsymbol{\epsilon} \quad (1)$$

dengan  $\mathbf{Y}$  = variabel respon

$\mathbf{X}$  = variabel prediktor yang merupakan hasil reduksi variabel GCM

$\epsilon$  = error

Terdapat tiga kategori metode SD, yaitu fungsi transfer, *weather typing*, dan *weather generator*. Pemilihan metode SD umumnya memperhatikan sifat dari variabel prediktor (luaran GCM) dan sifat variabel respon (variabel iklim lokal). Luaran GCM biasanya bersifat *curse of dimensionality*, spasial temporal, nonlinear, nonnormal, dan multikolinearitas. Variabel iklim lokal umumnya bersifat nonlinear, nonnormal, nonstasioner (Wilby et al., 2004).

## 2.2. Classification and Regression Tree (CART)

*Classification and Regression Tree* (CART) adalah metode klasifikasi yang menggunakan data historis yang disebut *learning sample* untuk mengkonstruksi pohon keputusan (*decision tree*) sebagai dasar klasifikasi data baru (Timofeev, 2004). Dengan CART, data variabel respon Y diklasifikasikan menjadi kelompok-kelompok data baru yang lebih homogen berdasarkan sejumlah variabel predictor. Tujuan algoritma CART adalah mendapatkan model untuk memprediksi nilai Y berdasarkan nilai variabel prediktor yang baru (Loh, 2011).

Menurut Timofeev (2004), algoritma CART terdiri dari tiga tahapan, yaitu

1. Mengkonstruksi pohon maksimum (*maximum tree*), dimana setiap data waktu dibagi menjadi dua bagian dengan kehomogenan maksimum dari simpul-simpul anak. Berdasarkan aturan Gini (*Gini index*), kehomogenan maksimum dari simpul anak kanan dan kiri akan ekuivalen dengan memaksimumkan perubahan fungsi *impurity*  $\Delta i(t)$ , yaitu

$$\Delta i(t) = - \sum_{k=1}^K p^2(k|t_p) + P_l \sum_{k=1}^K p^2(k|t_l) + P_r \sum_{k=1}^K p^2(k|t_r) \quad (2)$$

dengan  $k = 1, 2, \dots, K$  = indeks *class*;

$p(k|t)$  = peluang bersyarat *class k* bila dalam simpul  $t$ ,

$P_l$  dan  $P_r$  adalah peluang simpul kiri dan simpul kanan.

2. Memilih ukuran pohon (*tree size*) yang tepat

Penentuan ukuran pohon yang tepat dapat dilakukan menggunakan metode *cross-validation* dengan meminimumkan fungsi *cost-complexity* berikut

$$R_\alpha(T) = R(T) + \alpha(\tilde{T}) \quad (3)$$

dengan  $R(T)$  = *misclassification error* pohon  $T$ ,

$\alpha(\tilde{T})$  = ukuran kompleksitas yang tergantung pada  $\tilde{T}$  (total banyaknya simpul terminal pada pohon).

3. Mengklasifikasikan data baru menggunakan pohon yang sudah dikonstruksi.

## 2.3. Regresi Nonparametrik Kernel Multivariabel

Model regresi nonparametrik Kernel dengan lebih dari satu prediktor (multivariabel) secara umum dituliskan sebagai berikut

$$Y_i = m(\mathbf{X}_i) + \epsilon_i, \quad i = 1, 2, \dots, n \quad (4)$$

dengan *error*  $\varepsilon_i$  dan memenuhi  $E(\varepsilon_i) = 0$ . Fungsi  $m(\cdot)$  diasumsikan tidak diketahui bentuknya tetapi *smooth*.  $\mathbf{X}_i = (X_{i1}, X_{i2}, \dots, X_{id})$  merupakan beberapa variabel prediktor yang bersifat acak, sedangkan  $Y_i$  adalah variabel respon. Kurva regresi  $m(\mathbf{X}_i)$  diestimasi dengan estimator Kernel, yaitu estimator *Nadaraya-Watson* untuk kasus variabel prediktor acak (Eubank, 1988). Estimator Nadaraya-Watson untuk kasus multivariabel dituliskan sebagai berikut (Härdle dan Müller, 1997)

$$\hat{m}_{\mathbf{H}}(\mathbf{x}) = \frac{\sum_{i=1}^n K_{\mathbf{H}}(\mathbf{X}_i - \mathbf{x}) Y_i}{\sum_{i=1}^n K_{\mathbf{H}}(\mathbf{X}_i - \mathbf{x})} \quad (5)$$

dengan  $K_{\mathbf{H}}(\mathbf{X}_i - \mathbf{x}) = \prod_{j=1}^d h_j^{-1} K\left(\frac{X_{ij} - x_j}{h_j}\right)$

Estimator Kernel ditentukan oleh fungsi Kernel  $K(u)$  dan parameter penghalus *bandwidth*,  $\mathbf{h} = (h_1, h_2, \dots, h_d)$ . *Bandwidth* yang terlalu kecil akan menyebabkan kurva terlalu kasar, sementara *bandwidth* yang terlalu besar akan menyebabkan kurva terlalu halus (*smooth*). Keadaan tersebut memberikan kesalahan yang cukup besar, untuk itu diperlukan pemilihan *bandwidth* optimum yang meminimumkan *error*. Menurut Eubank (1988), pemilihan *bandwidth* optimum dapat dilakukan berdasarkan kriteria *Generalized Cross Validation* (GCV) yang dirumuskan sebagai berikut

$$GCV(\mathbf{h}, \mathbf{x}) = \frac{n^{-1} \sum_{i=1}^n (Y_i - \hat{m}(\mathbf{X}_i))^2}{(n^{-1} \text{tr}[\mathbf{I} - \mathbf{H}(\mathbf{h}, \mathbf{x})])^2} \quad (6)$$

Adapun salah satu fungsi Kernel yang dapat digunakan adalah fungsi Kernel Kuartik, yaitu

$$K(u) = \frac{15}{16} (1 - u^2)^2, \quad -1 \leq u \leq 1 \quad (7)$$

### 3. METODE PENELITIAN

#### 3.1. Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data luaran GCM (presipitasi dan temperatur harian luaran GCM), data curah hujan dan temperatur harian DAS Jangkok, data debit air sungai harian DAS Jangkok pada tahun 2016 - 2017. Data curah hujan harian DAS Jangkok yang digunakan adalah data curah hujan harian pada Pos Amatan Jurang Malang dan Sesao-Aiknyet. Sementara data temperatur harian yang mempengaruhi DAS Jangkok digunakan data pada Pos Amatan Kopang. Data luaran GCM merupakan variabel prediktor pada pemodelan SD curah hujan dan temperatur, dimana variabel responnya adalah data curah hujan dan temperatur DAS Jangkok. Pada pemodelan debit air sungai, data debit air sungai DAS Jangkok merupakan variabel respon, dengan variabel prediktornya adalah curah hujan dan temperatur hasil prediksi berdasarkan model SD nonparametrik Kernel.

Data presipitasi dan temperatur luaran GCM yang digunakan adalah data CPC *Global Precipitation (Daily Total Precipitation)* yang diperoleh dari <https://www.esrl.noaa.gov/psd/data/gridded/data.cpc.globalprecip.html> dan data CPC *Global Daily Temperatur (Daily Maximum Temperatur)* yang diperoleh dari <https://www.esrl.noaa.gov/psd/data/gridded/data.cpc.globaltemp.html>. Data tersebut merupakan data total presipitasi dan temperatur harian pada lokasi *latitude* dan *longitude* tertentu, dengan domain 8X8 di atas koordinat letak Pulau Lombok.

### 3.2. Metode Analisis Data

Pada penelitian ini terdapat dua pemodelan, yaitu pemodelan SD curah hujan dan temperatur untuk memprediksi curah hujan dan temperatur DAS Jangkok serta pemodelan debit air sungai berdasarkan data iklim hasil prediksi. Sehingga langkah penelitian beserta metode analisis datanya diuraikan sebagai berikut:

1. Pemodelan *statistical downscaling* (SD) curah hujan dan temperatur DAS Jangkok
  - a. Reduksi dimensi data GCM dengan algoritma CART yang menghasilkan proyeksi variabel data GCM. Pada tahap ini curah hujan dan temperatur dibagi dalam beberapa kelas berdasarkan k-Mean Cluster dan sebagai variabel prediktor adalah data GCM.
  - b. Mengestimasi bentuk fungsional antara data iklim lokal (curah hujan dan temperatur DAS Jangkok) sebagai variabel respon dengan variabel-variabel hasil proyeksi data GCM sebagai variabel prediktor. Estimasi bentuk fungsional tersebut dilakukan dengan pendekatan regresi nonparametrik Kernel, dengan tahapan
    - 1) Menentukan estimator Kernel Nadaraya-Watson untuk curah hujan dan temperatur dengan fungsi Kernel Kuartik dan berbagai nilai *bandwidth*
    - 2) Menentukan pemilihan *bandwidth* optimum dengan kriteria *Generalized Cross Validation (GCV)*
    - 3) Menentukan estimator Kernel Nadaraya-Watson dengan menggunakan *bandwidth* optimum
  - c. Prediksi data curah hujan dan temperatur DAS Jangkok berdasarkan model SD yang diperoleh.
2. Pemodelan debit air sungai DAS Jangkok dengan pendekatan regresi nonparametrik Kernel. Pada pemodelan ini data debit air sungai DAS Jangkok merupakan variabel respon, dengan variabel prediktornya adalah curah hujan dan temperatur hasil prediksi berdasarkan model SD nonparametrik Kernel.
  - a. Menentukan estimator Kernel Nadaraya-Watson untuk debit air sungai dengan fungsi Kernel Kuartik dan berbagai nilai *bandwidth*
  - b. Menentukan pemilihan *bandwidth* optimum dengan kriteria GCV
  - c. Menentukan estimator Kernel Nadaraya Watson dengan menggunakan *bandwidth* optimum
3. Prediksi debit air sungai DAS Jangkok berdasarkan model yang diperoleh

## 4. HASIL DAN PEMBAHASAN

Hasil dan pembahasan penelitian ini diuraikan berdasarkan tahapan-tahapan penelitian sebagai berikut.

#### 4.1. Hasil Reduksi Dimensi dengan Algoritma CART

Reduksi dimensi data presipitasi GCM didasarkan pada data curah hujan di dua pos pengamatan di DAS Jangkok yaitu Pos Jurang Malang dan Pos Sesaot-Aiknyet. Sedangkan reduksi dimensi data temperatur GCM didasarkan pada data temperatur di Pos Kopang yang diperkirakan mempengaruhi kondisi temperatur DAS Jangkok. Sebelum reduksi dimensi dilakukan, data curah hujan dan temperatur di masing-masing pos amatan dikelompokkan dalam beberapa kelas menggunakan metode k-Mean Cluster. Hasil pengelompokan menunjukkan bahwa curah hujan di masing-masing pos amatan dikelompokkan dalam tiga kelas, demikian juga dengan temperatur. Tiga kelas curah hujan pada pos amatan digunakan dalam algoritma CART untuk mereduksi dimensi data presipitasi GCM. Tiga kelas temperatur pada pos amatan digunakan dalam algoritma CART untuk mereduksi dimensi data temperatur GCM. Hasil reduksi dimensi dengan algoritma CART dapat dilihat pada tabel 1.

**Tabel 1** Hasil Reduksi Dimensi Data GCM dengan Algoritma CART

Pos Amatan	Jumlah Simpul	Jumlah Simpul Terminal	Ketepatan Klasifikasi	Variabel dalam Model	Tingkat Kepentingan (%)
Jurang Malang	5	3	89.2	$X_{25}$	100.0
				$X_1$	53.3
Sesaot-Aiknyet	5	3	83.8	$X_{25}$	100.0
				$X_5$	27.5
Kopang	5	3	64.4	$X_7$	100.0
				$X_8$	97.7

Tabel 1 menunjukkan bahwa hasil klasifikasi yang diperoleh mempunyai ketepatan yang tinggi (lebih dari 80%) kecuali pada klasifikasi temperatur pada Pos Kopang. Dan dari hasil analisis CART tersebut presipitasi GCM yang mempengaruhi curah hujan di Pos Jurang Malang adalah variabel  $X_{25}$  (*Global precipitation* pada grid  $9.250^{\circ}$  LS dan  $116.75^{\circ}$  BT) dan  $X_1$  (*Global precipitation* pada grid  $6.750^{\circ}$  LS dan  $113.75^{\circ}$  BT), sedangkan yang mempengaruhi curah hujan di Pos Sesaot-Aiknyet adalah variabel  $X_{25}$  (*Global precipitation* pada grid  $9.250^{\circ}$  LS dan  $116.75^{\circ}$  BT) dan  $X_5$  (*Global precipitation* pada grid  $7.250^{\circ}$  LS dan  $113.75^{\circ}$  BT). Adapun temperatur GCM yang mempengaruhi temperatur Pos Kopang adalah variabel  $X_7$  (*Global temperature* pada grid  $8.750^{\circ}$  LS dan  $116.25^{\circ}$  BT), dan  $X_8$  (*Global temperature* pada grid  $8.750^{\circ}$  LS dan  $116.75^{\circ}$  BT). Variabel-variabel hasil proyeksi data GCM tersebut selanjutnya digunakan sebagai prediktor dalam pemodelan *statistical downscaling* nonparametrik Kernel curah hujan dan temperatur DAS Jangkok.

#### 4.2. Model Statistical Downscaling Nonparametrik Kernel Curah Hujan dan Temperatur DAS Jangkok

Pada proses pemodelan SD dengan pendekatan regresi nonparametrik Kernel terdapat proses pemilihan *bandwidth* optimum untuk mendapatkan model regresi yang terbaik. Hasil Pemilihan *bandwidth* optimum dapat dilihat pada tabel 2.

Berdasarkan *bandwidth* optimum tersebut dibangun dua model curah hujan dan satu model temperatur DAS Jangkok. Model yang diperoleh digunakan untuk memprediksi

data curah hujan dan temperatur di DAS Jangkok, dimana ketepatan hasil prediksinya diukur dari besarnya nilai RMSE seperti yang terlihat pada tabel 3.

**Tabel 2** Hasil Pemilihan *Bandwidth* Optimum Model Iklim DAS Jangkok

Variabel Iklim	<i>Bandwidth</i> optimum		GCV minimum
	$h_1$	$h_2$	
Curah Hujan Pos Jurang Malang	0,3046671	0,4313521	263,3102918
Curah Hujan Pos Sesaot-Aiknyet	0,3396855	0,4909225	245,8663110
Temperatur Pos Kopang	0,7836873	0,4235503	1,4101635

**Tabel 3** Nilai RMSE Prediksi Variabel Iklim DAS Jangkok

Variabel Iklim	Nilai RMSE
Curah Hujan Pos Jurang Malang	9.031198
Curah Hujan Pos Sesaot-Aiknyet	7.812062
Temperatur Pos Kopang	0.8027175

Tabel 3 menunjukkan bahwa hasil prediksi yang diperoleh mempunyai ketepatan yang cukup tinggi, hal ini terlihat dari nilai RMSE yang relatif kecil. Dengan demikian variabel iklim tersebut dapat digunakan sebagai prediktor dalam pemodelan debit air sungai.

#### 4.3 Model Debit Air Sungai DAS Jangkok

Dari studi awal penelitian ini diketahui bahwa sebaran titik antara data debit air sungai dengan curah hujan dan temperatur membentuk pola yang tidak jelas bentuk fungsionalnya, sehingga pendekatan yang digunakan dalam pemodelan debit air sungai berdasarkan variabel iklim di DAS Jangkok adalah regresi nonparametrik Kernel. Pemodelan yang dilakukan ada dua, yaitu pemodelan debit air sungai yang diamati pada Pos AWLR Jurang Malang dan Pos AWLR Sesaot-Aiknyet. Pada pemodelan debit Pos AWLR Jurang Malang, sebagai variabel prediktor adalah data hasil prediksi curah hujan Pos Jurang Malang dan temperatur Pos Kopang. Sementara pada pemodelan debit Pos AWLR Sesaot-Aiknyet, variabel prediktornya adalah data hasil prediksi curah hujan Pos Sesaot-Aiknyet dan temperatur Pos Kopang. Pada proses pemodelan debit air sungai dengan pendekatan regresi nonparametrik Kernel terdapat proses pemilihan *bandwidth* optimum untuk mendapatkan model regresi yang terbaik. Hasil pemilihan *bandwidth* optimum terlihat pada tabel 4.

Nilai-nilai *bandwidth* optimum berdasarkan data pada Pos Jurang Malang digunakan dalam model regresi nonparametrik Kernel debit air sungai Pos Jurang Malang berdasarkan variabel curah hujan Pos Jurang Malang ( $X_1$ ) dan temperatur Pos Kopang ( $X_2$ ) hasil simulasi.

Sedangkan nilai-nilai *bandwidth* optimum berdasarkan data pada Pos Sesaot-Aiknyet digunakan dalam model regresi nonparametrik Kernel debit air sungai Pos

Sesaot-Aiknyet berdasarkan variabel curah hujan Pos Sesaot-Aiknyet ( $X_1$ ) dan temperatur Pos Kopang ( $X_2$ ) hasil simulasi.

**Tabel 4** Hasil Pemilihan *Bandwidth* Optimum Model Debit DAS Jangkok

Pos AWLR	<i>Bandwidth</i> optimum		GCV minimum
	$h_1$	$h_2$	
Jurang Malang	0.8304426	0.8077585	0.1426225
Sesaot-Aiknyet	0.8152089	0.6882178	6.5253445

Adapun model regresi nonparametrik Kernel debit air sungai Pos Jurang Malang yang diperoleh adalah sebagai berikut

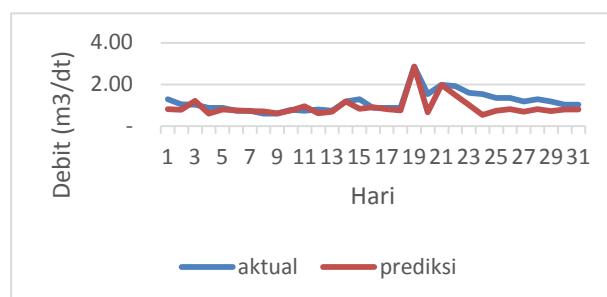
$$\hat{m}(.) = \frac{\sum_{i=1}^n \left( \frac{15}{16} \right)^3 \left( 1 - \left( \frac{X_{i1} - x_1}{0.8304426} \right)^2 \right)^2 \left( 1 - \left( \frac{X_{i2} - x_2}{0.8077585} \right)^2 \right)^2 Y_i}{\sum_{i=1}^n \left( \frac{15}{16} \right)^3 \left( 1 - \left( \frac{X_{i1} - x_1}{0.8304426} \right)^2 \right)^2 \left( 1 - \left( \frac{X_{i2} - x_2}{0.8077585} \right)^2 \right)^2} \quad (8)$$

Sedangkan model regresi nonparametrik Kernel debit air sungai Pos Sesaot-Aiknyet yang diperoleh adalah sebagai berikut

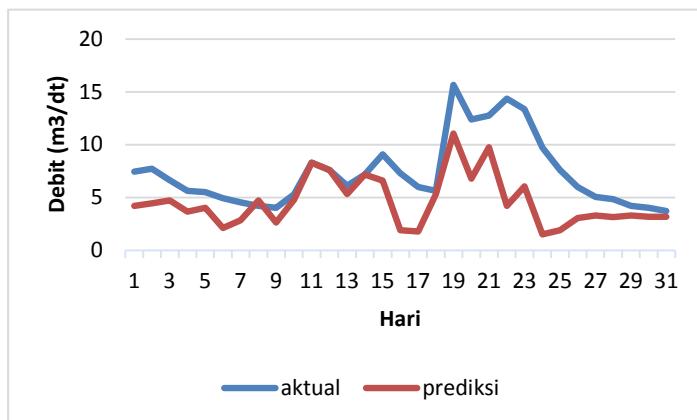
$$\hat{m}(.) = \frac{\sum_{i=1}^n \left( \frac{15}{16} \right)^3 \left( 1 - \left( \frac{X_{i1} - x_1}{0.8152089} \right)^2 \right)^2 \left( 1 - \left( \frac{X_{i2} - x_2}{0.6882178} \right)^2 \right)^2 Y_i}{\sum_{i=1}^n \left( \frac{15}{16} \right)^3 \left( 1 - \left( \frac{X_{i1} - x_1}{0.8152089} \right)^2 \right)^2 \left( 1 - \left( \frac{X_{i2} - x_2}{0.6882178} \right)^2 \right)^2} \quad (9)$$

Model debit air sungai pada persamaan 8 dan 9 digunakan untuk prediksi debit air sungai untuk Pos AWLR Jurang Malang dan Sesaot-Aiknyet DAS Jangkok. Hasil prediksi yang diperoleh ditunjukkan pada gambar 1 dan 2.

Gambar 1 dan 2 menunjukkan bahwa pola debit air sungai prediksi tidak berbeda jauh dari pola debit air sungai aktual di dua pos AWLR tersebut. Untuk melihat ketepatan prediksinya dapat dilihat dari nilai RMSE seperti terlihat pada tabel 5, dimana tabel 5 menunjukkan bahwa hasil prediksi yang diperoleh mempunyai ketepatan yang cukup tinggi. Hal ini terlihat dari nilai RMSE yang relatif kecil.



**Gambar 1** Grafik Perbandingan Debit Air Sungai Aktual dan Prediksi Pada Pos AWLR Jurang Malang DAS Jangkok



**Gambar 2** Grafik Perbandingan Debit Air Sungai Aktual dan Prediksi Pada Pos AWLR Sesaot-Aiknyet DAS Jangkok

**Tabel 5** Nilai RMSE Prediksi Debit Air Sungai DAS Jangkok

Pos AWLR	Nilai RMSE
Jurang Malang	0.38
Sesaot-Aiknyet	3.73

## 5. KESIMPULAN

Berdasarkan uraian di atas dapat disimpulkan bahwa model statistical downscaling curah hujan dan temperatur memberikan hasil prediksi dan curah hujan dan temperatur DAS Jangkok yang cukup baik untuk digunakan dalam pemodelan debit air sungai. Adapun model debit air sungai yang dihasilkan berdasarkan hasil prediksi iklim DAS Jankok tersebut memberikan hasil prediksi yang cukup baik juga namun untuk lebih baiknya dalam pemodelan debit tidak hanya berdasarkan faktor iklim tapi juga memasukkan faktor-faktor lain yang mempengaruhi debit air sungai.

## DAFTAR PUSTAKA

- Eubank, R. 1998. *Spline Smoothing And Nonparametric Regression*. New York, USA: Marcel Dekker. Inc..
- Fernandez, E. 2005. *On The Influence of Predictors Area in Statistical Downscaling of Daily Parameters*. Oslo: Report no.09/2005, Norwegian Meteorological Institute.
- Gagnon, S., Singh, B., Roussele, J., dan Roy, L. 2005. An Application of The Statistical Downscaling Model (SDSM) to Simulate Climatic Data for Streamflow Modelling in Quebec. *Canadian Water Resource Journal*, Vol. 30, hal. 297–319.
- Hadijati, M., Komalasari, D., dan Fitriyani, N. 2016. *Statistical Downscaling Model using Nonparametric Regression to Predict Temperature in Selaparang Lombok*. Mataram, International Conference in Science and Technology (ICST) 2016.
- Hadijati, M., Marwan, dan Komalasari, D. 2015. Classification and Regression Tree (CART) Analysis on Statistical Downscaling Modeling of Rainfall in Lombok

Island. *Mataram, International Conference on Mathematics, Sciences and Education.*

- Hardle, W. dan Muller, M. 1997. *Multivariate and Semiparametric Regression*. [Online] Available at: <http://www.edoc.hu-berlin.de/series/sfb-373-papers/1997-26/PDF/26.pdf> [Accessed 26 April 2013].
- Kannan, S. dan Ghosh, S. 2013. A Nonparametric Kernel Regression Model for Downscaling Multisite Daily Precipitation in The Mahanadi Basin. *Water Resources Research*, Volume 49.
- Lembang, F., Setiawan, dan Sutikno. 2009. *Pengembangan Model Ramalan Curah Hujan untuk Pemodelan Statistical Downscaling dengan Pendekatan Regresi Bayes PCA*, Surabaya: Seminar Nasional Statistika VI FMIPA ITS.
- Loh, W.-Y., 2011. Classification and Regression Trees. *WIREs Data Mining Knowledge Discovery*, 1(January/February), hal. 14–23.
- Sachindra, D., Huang, F., Barton, A., dan Perera, B. 2015. Potential Improvements to Statistical Downscaling of General Circulation Model Outputs to Catchment Stream flows with Downscaled Precipitation and Evaporation. *Theoretical and Applied Climatology*, Vol. 122, hal. 159–179.
- Samadi, S., Carbone, G.J., Mahdavi, M., Sharifi, F., dan Bihamta, M.R. 2012. Statistical Downscaling of Climate Data to Estimate Streamflow in Semi-arid Catchment. *Hydrology and Earth System Sciences Discussions*, Vol. 9, hal. 4869–4928.
- Singh, S., Kannan, S., dan Timbadiya, P. 2016. Statistical Downscaling of Multisite Daily Precipitation for Tapi Basin Using Kernel Regression Model. *Current Science*, Vol. 10, hal. 1468–1484.
- Timofeev, R. 2004. *Classification and Regression Trees (CART): Theory and Application*, Berlin: Master Thesis, Humboldt University.
- Wigena, A. 2006. *Pemodelan Statistical Downscaling dengan Regresi Projection Pursuit untuk Peramalan Curah Hujan Bulanan: Kasus Curah Hujan Bulanan di Indramayu*, Bogor: Disertasi Pascasarjana IPB.
- Wilby, R., Charles, S.P., Zorita, E., Timbal, B., Whetton, P. dan Mearns, L.O. 2004. *Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods*, s.l.: IPCC Reports.
- Zorita, E. dan Storch, H. 1999. The Analog Method as A Simple Statistical Downscaling Technique: Comparison with Complicated Methods. *J Clim*, Vol. 12, hal. 2474–2489.
- .