

# Statistical Downscaling Modeling with Time Lag Components for Forecasting Rainfall in Wet and Dry Seasons

Sitti Masyitah Meliyana<sup>1\*</sup>, Zakiyah Mar'ah, Hardianti Hafid

*Department of Statistics, Faculty of Mathematics dan Natural Science, Universitas Negeri Makassar, Indonesia*

**Keywords:** statistical downscaling, GCM, CCF, PLS, PCR

## **Abstract:**

Climate change in Indonesia often poses a serious threat to the agricultural sector. The impacts can include reduced agricultural productivity. In this context, rainfall variables are frequently used in research related to the impacts of climate change. In this study, precipitation data from the global circulation model (GCM) outputs are used as predictor variables and rainfall data from the Indramayu station are used as response variables in statistical downscaling modeling. The cross-correlation function between these variables plays an important role in statistical downscaling modeling. The cross-correlation function can enhance the correlation between predictor variables and response variables. Therefore, this research aims to compare the rainfall prediction results using initial GCM data (GCM) and GCM data with lag components (lagged GCM) determined based on the cross-correlation function. The methods used in statistical downscaling modeling are partial least squares regression (PLSR) and principal component regression (PCR). The modeling results using data from the period 1993-2020 show that the PLSR model on lagged GCM data is the best compared to other models (PLSR on GCM data, PCR on GCM data, and PCR on lagged GCM data). This model produces the highest coefficient of determination and the smallest RMSE value. Furthermore, the PLSR model on lagged GCM data can predict the 2008 rainfall data, following the actual rainfall pattern with the smallest RMSEP value. In general, modeling using lagged GCM data provides better rainfall prediction results compared to GCM data.

## **1. Introduction**

Perubahan iklim menjadi ancaman serius khususnya pada bidang pertanian. Provinsi Jawa Barat merupakan salah satu provinsi di wilayah Indonesia yang memberikan kontribusi terbesar terhadap produksi beras nasional, yaitu sebesar 17,6%. Namun, upaya pemerintah Jawa Barat untuk mempertahankan swasembada beras yang telah dicapai semakin sulit disebabkan oleh berbagai faktor. Faktor yang paling berpengaruh terhadap produktivitas pertanian adalah dampak perubahan iklim yang tidak menentu (Anggoro 2013).

Curah hujan merupakan peubah yang paling sering digunakan dalam penelitian mengenai dampak perubahan iklim. Proses pembentukan hujan di kawasan tropis wilayah Indonesia merupakan proses yang paling sukar disimulasikan. Oleh karena itu, model-model iklim resolusi tinggi perlu dikembangkan dalam skala lokal dengan mempertimbangkan informasi dari sirkulasi atmosfer global yang dapat diperoleh dari luaran *global circulation model* (GCM) (Notodiputro *et al.* 2005). Namun, informasi dari luaran GCM masih berskala global dan tidak untuk fenomena skala lebih kecil. Teknik *statistical downscaling* (SD) dapat digunakan untuk memperoleh informasi iklim yang berskala lokal dari luaran GCM (Fernandez 2005).

\* Corresponding author.

E-mail address: sittimashitahmr@unm.ac.id



Wigena (2011) menggunakan teknik SD dengan metode regresi kuadrat terkecil parsial (RKTP) multi respon untuk peramalan curah hujan di kabupaten Indramayu. Selain itu, Estiningtyas dan Wigena (2011) menggunakan teknik SD dengan RKTP dan regresi komponen utama (RKU) untuk memprediksi curah hujan pada kondisi el nino, la nina, dan normal di kabupaten Indramayu. Namun, penelitian-penelitian tersebut belum mempertimbangkan komponen waktu tunda data GCM. Oleh karena itu, fungsi korelasi silang/ *cross correlation function* (CCF) akan digunakan dalam penelitian ini untuk menentukan komponen waktu tunda data GCM. Hal ini penting dilakukan karena hubungan antara peubah respon dengan prediktor haruslah kuat untuk menjelaskan keragaman iklim lokal dengan baik.

Penelitian ini bertujuan untuk membandingkan hasil peramalan data curah hujan menggunakan data GCM dan data GCM tunda dengan metode RKTP dan RKU. Data GCM merupakan data presipitasi luaran GCM awal, sedangkan data GCM tunda merupakan data presipitasi luaran GCM dengan komponen waktu tunda.

### 1.1. Data

Data yang digunakan dalam penelitian ini adalah data presipitasi luaran GCM *climate model intercomparison project* (CMIP5) dalam satuan mm/bulan sebagai peubah prediktor dan data curah hujan stasiun di kabupaten Indramayu sebagai peubah respon pada periode 1979-2008. Data GCM CMIP5 diperoleh dari situs web <http://www.climatexp.knmi.nl/> yang dikeluarkan oleh KNMI Belanda. Musim hujan terjadi pada bulan Oktober hingga Maret dan musim kemarau terjadi pada bulan April hingga September.

Kabupaten Indramayu terletak pada 98.75°BT s.d 116.25°BT dan -16.25°LS s.d 1.25°LU. Ukuran domain GCM yang akan digunakan dalam penelitian ini adalah sejumlah grid GCM berbentuk persegi berukuran 8×8 grid (2.5°×2.5° untuk setiap grid). Penggunaan ukuran domain 8×8 grid yang berada di atas kabupaten Indramayu memberikan hasil yang lebih stabil atau konsisten serta tidak sensitif terhadap data pencilan Wigena (2006).

### 1.2. Analysis Method

Tahapan analisis yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Mengkonversi data GCM dari format netCDF ke format excel menggunakan R dengan package RnetCDF.
2. Menentukan waktu tunda terbaik data GCM menggunakan CCF. CCF dihitung menggunakan rumus berikut dengan  $r_{xy}(l)$  adalah korelasi silang antara deret  $x$  dan  $y$  pada waktu tunda ke- $l$ ,  $C_{xy}(l)$  adalah peragam antara  $x$  dan  $y$  pada waktu tunda ke- $l$ ,  $S_x$  dan  $S_y$  berturut-turut adalah standard deviasi deret  $x$  dan  $y$ :
 
$$r_{xy}(l) = \frac{C_{xy}(l)}{S_x S_y}$$
3. Membagi data curah hujan menjadi dua kelompok, yakni data pemodelan (periode 1979-2007) dan data validasi (periode 2008) pada data GCM dan data GCM tunda.
4. Melakukan eksplorasi terhadap data pemodelan menggunakan plot per bulan data curah hujan stasiun dan *variance inflation factors* (VIF).
5. Menerapkan teknik SD menggunakan data pemodelan pada masing-masing data GCM dan data GCM tunda dengan metode RKTP dan RKU.

Tahapan-tahapan yang dilakukan dalam analisis RKU adalah sebagai berikut (Mattjik dan Sumertajaya 2011):

- a) Menguji kehomogenan ragam data peubah prediktor.
- b) Jika pada bagian (a) menunjukkan ragam data peubah prediktor heterogen, maka peubah prediktor  $x_j$  ditransformasi menjadi bentuk baku  $z_j$  dan menggunakan matriks ragam-peragam  $Z$  (matriks korelasi peubah asal  $x$ ),

$$z_j = \frac{(x_j - \mu_j)}{\sqrt{\sigma_j^2}}, j = 1, 2, \dots, p$$

dengan  $\mu_j$  adalah nilai rata-rata peubah  $x$  ke- $j$  dan  $\sigma_j^2$  adalah nilai ragam peubah  $x$  ke- $j$ . Akan tetapi, jika hasil (a) menunjukkan sebaliknya maka lanjutkan ke langkah (c) menggunakan matriks ragam-peragam peubah  $x$ .

- c) Menghitung nilai akar ciri ( $\lambda_j$ ) dan vektor ciri ( $\mathbf{e}_j$ ), serta skor KU ( $w_j$ ) dari matriks ragam-peragam peubah  $z$  dengan,

$$\mathbf{w}_j = \mathbf{e}_j' \mathbf{Z} = e_{j1}z_1 + e_{j2}z_2 + \dots + e_{jp}z_p$$

- d) Meregresikan peubah respon  $y$  dengan  $w_j$  yang terpilih.  
 e) Mentransformasi persamaan regresi dari  $w_j$  ke peubah  $z_j$ .  
 f) Mentransformasi persamaan regresi dari peubah  $z_j$  ke peubah  $x_j$ .

Salah satu algoritma pendugaan parameter RKTP adalah *non-linear iterative partial least squares* (NIPALS) dengan tahapan sebagai berikut (Wold et al. 2001):

- a) Mendapatkan nilai vektor awalan  $\mathbf{u}$  yang diperoleh dari nilai vektor tunggal  $\mathbf{y}$  sehingga  $\mathbf{u} = \mathbf{y}$ .  
 b) Menghitung pembobot  $-\mathbf{X}(\mathbf{w})$  menggunakan formula  $\mathbf{w} = \mathbf{X}'\mathbf{u}/\mathbf{u}'\mathbf{u}$  dan mengortonormalkan vektor  $\mathbf{w}$  dengan formula  $\mathbf{w} = \mathbf{w}/\sqrt{\mathbf{w}'\mathbf{w}}$  sehingga  $\|\mathbf{w}\| = 1$ .  
 c) Menghitung skor- $x$ ,  $\mathbf{t} = \mathbf{X}\mathbf{w}$ .  
 d) Menghitung pembobot- $y$ ,  $\mathbf{c} = \mathbf{y}'\mathbf{t}/\mathbf{t}'\mathbf{t}$ .  
 e) Memperbaharui skor- $y$ ,  $\mathbf{u} = \mathbf{y}\mathbf{c}/\mathbf{c}'\mathbf{c}$ .  
 f) Menyederhanakan matrik  $\mathbf{X}$  dan vektor  $\mathbf{y}$ , yakni:  

$$\mathbf{m} = \frac{\mathbf{X}'\mathbf{t}}{\mathbf{t}'\mathbf{t}} \quad \mathbf{X} = \mathbf{X} - \mathbf{t}\mathbf{m}' \quad \mathbf{y} = \mathbf{y} - \mathbf{t}\mathbf{c}'$$
  
 g) Melanjutkan ke komponen berikutnya (kembali ke langkah awal) hingga validasi silang mengindikasikan tidak ada lagi informasi yang nyata dari  $\mathbf{X}$  terhadap  $\mathbf{y}$ .  
 h) Menduga vektor koefisien regresi pada analisis RKTP dengan formula sebagai berikut:

$$\mathbf{b}_{RKTP} = \mathbf{w}(\mathbf{m}'\mathbf{w})^{-1}\mathbf{c}'$$

6. Melakukan peramalan data curah hujan stasiun Indramyu periode 2008 pada data GCM dan GCM tunda, serta menentukan model terbaik menggunakan nilai korelasi dan *RMSEP*.

## 2. Hasil dan Pembahasan

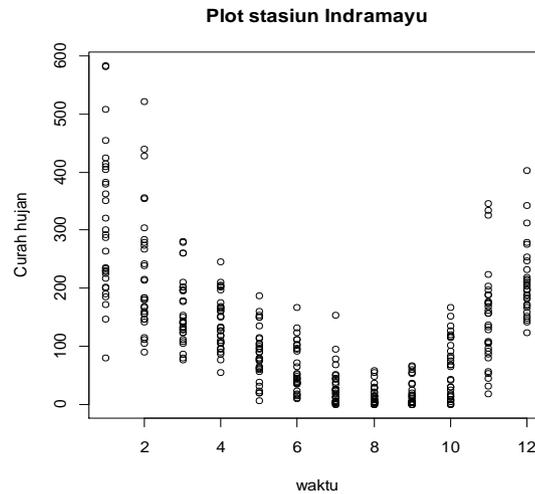
### 2.1. Penentuan Waktu Tunda Terbaik Data GCM.

Gambar 1 (a) merupakan plot data presipitasi per bulan luaran GCM pada peubah  $x_1$ . Berdasarkan plot tersebut, curah hujan tertinggi rata-rata terjadi pada bulan Maret dan April. Bulan Maret dan April merupakan masa peralihan dari musim hujan ke musim kemarau sehingga pada bulan-bulan tersebut seharusnya memiliki curah hujan yang rendah. Hal ini mengakibatkan nilai korelasi antara data prediktor dengan respon kecil. Selanjutnya, CCF digunakan untuk menentukan waktu tunda terbaik peubah  $x_1$ .

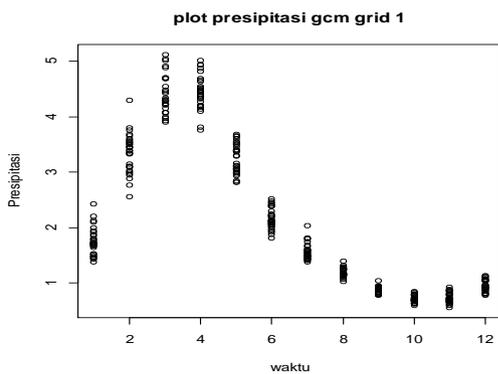
Penentuan waktu tunda terbaik peubah  $x_1$  menunjukkan bahwa peubah  $x_1$  memiliki korelasi tertinggi dengan peubah  $y$  pada waktu tunda ke-2 (Gambar 1 (b)). Artinya, data curah hujan stasiun bulan Januari terjadi di bulan Maret pada data GCM untuk peubah  $x_1$ . Selanjutnya, data peubah  $x_1$  dilakukan pergeseran 2 bulan ke depan sehingga presipitasi tertinggi rata-rata terjadi pada bulan Januari dan membentuk pola U (Gambar 1 (c)). Penentuan waktu tunda terbaik juga dilakukan terhadap peubah  $x_2 - x_{64}$ .

## 2.2. Eksplorasi Data

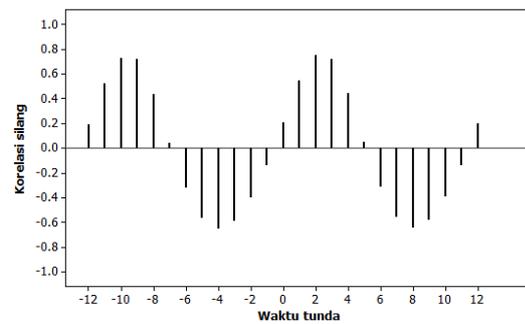
Eksplorasi data yang disajikan pada Gambar 2 menunjukkan bahwa tebaran data curah hujan stasiun Indramayu membentuk pola U, yakni curah hujan tinggi terjadi pada bulan Januari dan Februari, bulan Maret hingga September menunjukkan pola curah hujan semakin rendah, dan curah hujan kembali tinggi pada bulan Oktober hingga Desember. Seperti yang telah diketahui bahwa kabupaten Indramayu, yang merupakan salah satu kabupaten di provinsi Jawa Barat Indonesia, beriklim tropis yang memiliki dua musim, yakni musim hujan dan musim kemarau. Selain itu, pola tebaran data presipitasi GCM tunda mengikuti pola curah hujan stasiun (Gambar 1 (c)) sehingga menghasilkan korelasi yang tinggi antara data presipitasi GCM tunda dengan data curah hujan stasiun.



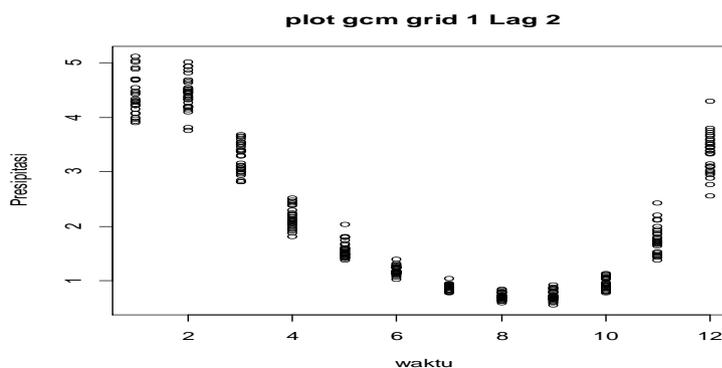
Gambar 1. Plot curah hujan stasiun periode 1993-2020



(a)



(b)



(c)

**Gambar 2. Plot presipitasi peubah  $x_1$  (a), CCF antara stasiun dengan  $x_1$  (b), dan Plot presipitasi GCM tunda pada peubah  $x_1$  (c)**

Hasil perhitungan menunjukkan bahwa jumlah peubah prediktor setelah penentuan waktu tunda yang memiliki korelasi lebih dari 0.7 dengan peubah respon ada sebanyak 73%. Sementara itu, korelasi peubah respon dengan peubah prediktor sebelum penentuan waktu tunda yang lebih dari 0.7 hanya mencapai 9%.

Multikolinieritas yang nyata dapat dilihat dari nilai VIF yang lebih dari 10.00. Hasil perhitungan pada Tabel 1 menunjukkan bahwa umumnya peubah prediktor memiliki nilai VIF yang lebih besar dari 10.00. Hal ini mengindikasikan adanya multikolinieritas yang nyata antar peubah prediktor atau terdapat hubungan yang kuat antar grid data GCM tunda yang saling berdekatan. Oleh karena itu, penelitian ini menggunakan metode RKTP dan RKU.

**Tabel 1 Nilai VIF peubah prediktor**

Peubah	VIF	Peubah	VIF	Peubah	VIF	Peubah	VIF
x1	414.34	x17	1044.13	x33	914.333	x49	236.244
x2	660.06	x18	1175.31	x34	945.788	x50	418.416
x3	394.59	x19	728.64	x35	417.096	x51	1055.41
x4	67.05	x20	613.75	x36	952.676	x52	1024.86
x5	87.77	x21	463.53	x37	594.493	x53	1056.74
x6	37.25	x22	120.98	x38	180.29	x54	208.76
x7	17.49	x23	77.04	x39	42.251	x55	43.127
x8	34.22	x24	128.68	x40	50.123	x56	14.878
x9	863.10	x25	1058.23	x41	647.954	x57	139.081
x10	1252.11	x26	985.06	x42	430.745	x58	646.023
x11	697.41	x27	412.71	x43	932.971	x59	922.176
x12	218.90	x28	847.99	x44	1109.04	x60	834.771
x13	235.09	x29	526.02	x45	755.59	x61	590.633
x14	162.07	x30	121.64	x46	160.59	x62	148.201
x15	60.59	x31	90.57	x47	33.042	x63	5.556
x16	85.56	x32	125.58	x48	23.557	x64	5.863

2.3. Analisis Data GCM

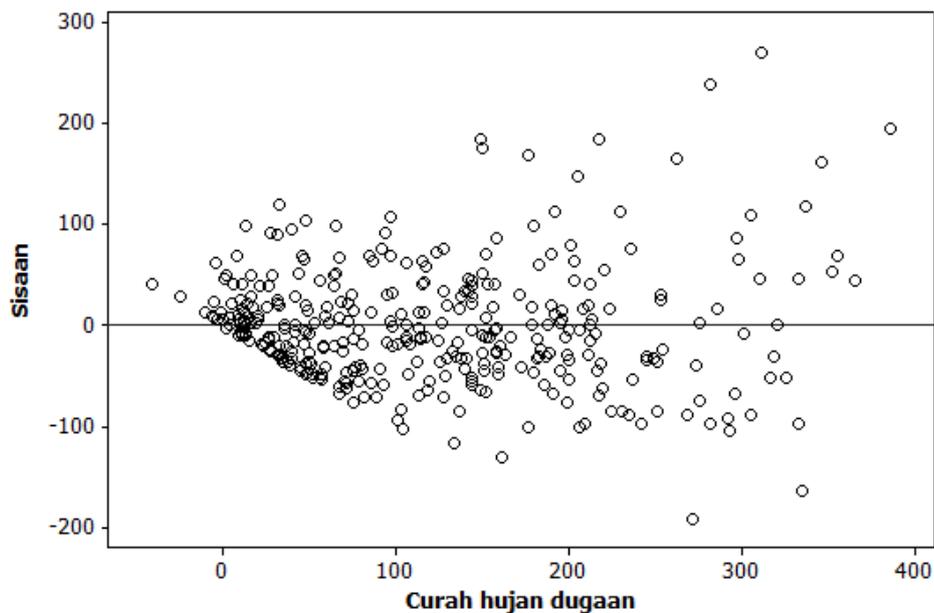
2.3.1. Regresi Kuadrat Terkecil Parsial (RKTP)

Penentuan jumlah komponen yang diperlukan dalam RKTP menggunakan statistik *prediction residual sum of squares* (PRESS). PRESS merupakan salah satu pendekatan yang dipertimbangkan untuk prosedur kestabilan koefisien penduga regresi. Berdasarkan hasil pada Tabel 2, nilai PRESS menunjukkan bahwa cukup menggunakan 3 faktor dalam model RKTP meskipun terdapat 4 faktor yang memiliki nilai akar rataaan PRESS terkecil atau faktor yang memiliki nilai  $-p > 0.1$ . selain itu, tiga faktor terekstrak mampu menjelaskan 93.97% keragaman data presipitasi GCM dan 61.5% keragaman data curah hujan stasiun (Gambar 3).

Model RKTP menghasilkan beberapa keluaran berupa nilai sisaan dan nilai dugaan model. Gambar 3 menunjukkan bahwa kondisi ragam sisaan model RKTP tidak homogen. Plot sisaan yang ditunjukkan membentuk pola corong yang mengindikasikan terjadinya heterokedastisitas pada data. Nilai mutlak sisaan cenderung membesar seiring dengan penambahan nilai curah hujan dugaan.

Tabel 2 Komponen terekstrak pada model RKTP data GCM

Jumlah faktor terekstrak	Akar rataaan PRESS	Peluang > PRESS	Keragaman kumulatif	
			Peubah Prediktor	Peubah Respon
0	1.0174	<.0001		
1	0.7532	<.0001	66.92	45.7
2	0.6583	0.0510	87.31	59.1
3	0.6425	0.1790	93.97	61.5
4	0.6381	1.0000		



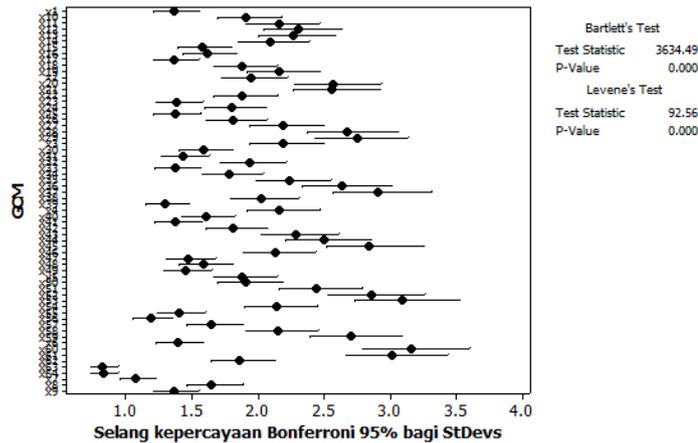
Gambar 3 Plot sisaan dan nilai curah hujan dugaan model RKTP data GCM

2.3.2. Regresi Komponen Utama (RKU)

Hasil uji kehomogenan ragam data GCM tercantum pada Gambar 4. Gambar 4 menunjukkan bahwa data GCM memiliki ragam yang heterogen sehingga AKU dibentuk berdasarkan matriks korelasi peubah asal. Jumlah KU yang digunakan untuk membangun model RKU dipilih berdasarkan proporsi kumulatif keragaman total yang mampu dijelaskan oleh KU. Dalam penelitian ini, penentuan jumlah KU yang akan digunakan berdasarkan pada proporsi kumulatif keragaman total yang berkisar 80%–95% sehingga terdapat 4 model RKU berdasarkan jumlah KU yang digunakan pada Tabel 3.

Model RKU dibangun dengan meregresikan KU hasil AKU terhadap data curah hujan stasiun. Hasilnya ditunjukkan pada Tabel 4. Tabel 4 memberikan informasi bahwa keempat model RKU menghasilkan nilai  $R^2$  berkisar 34.2%–62% dan nilai RMSE yang cukup besar, yakni berkisar 67.15–88.58. Hal ini berarti bahwa model awal RKU hanya mampu menjelaskan keragaman data sekitar 62%. Di sisi lain, model RKTP cukup baik dalam menjelaskan keragaman data daripada keempat model RKU. Model RKTP mampu menghasilkan nilai  $R^2$  lebih tinggi, yakni sebesar 70.55% dengan nilai RMSE lebih kecil sebesar 59.1.

Diagnosis sisaan dari keempat model RKU disajikan pada Gambar 5. Gambar 5 menunjukkan bahwa kondisi ragam sisaan tidak homogen. Hal ini serupa dengan kondisi ragam sisaan model RKTP. Pada curah hujan yang tinggi sebaran sisaan lebih beragam dibandingkan dengan curah hujan rendah.



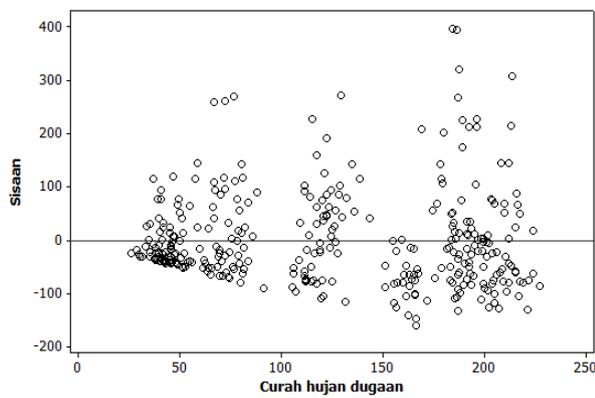
Gambar 4 Uji kehomogenan ragam data GCM

Tabel 3 Keragaman KU menggunakan AKU pada data GCM

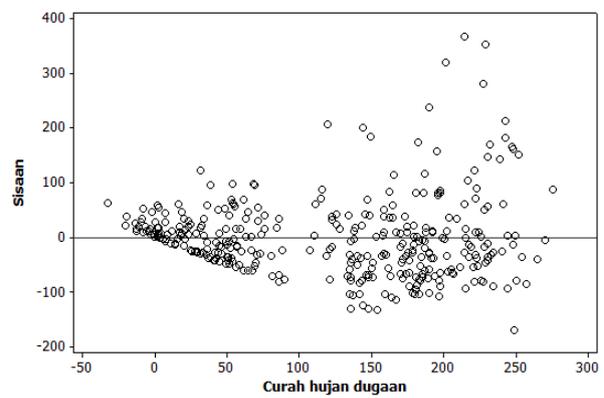
	KU 1	KU 2	KU 3	KU 4	KU 5
Nilai Akar Ciri	44.27	11.90	4.33	1.36	0.46
Proporsi Keragaman	0.69	0.19	0.07	0.02	0.01
Proporsi Kumulatif	0.69	0.88	0.95	0.97	0.97

**Tabel 4 Nilai R<sup>2</sup> dan RMSE model data GCM**

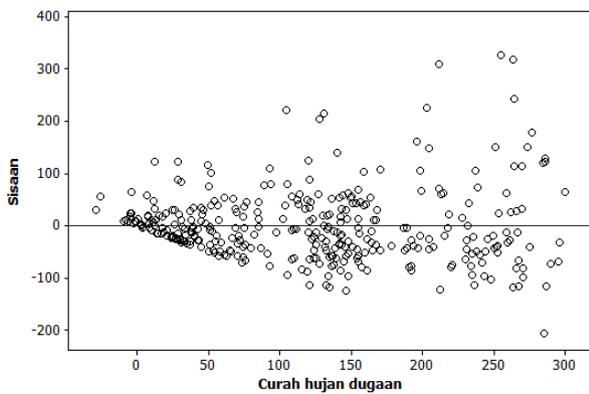
Model	Komponen	R <sup>2</sup>	RMSE
RKTP	Faktor 1, Faktor 2, Faktor 3	70.55%	59.1
R1KU	KU 1	34.2%	88.58
R2KU	KU 1, KU 2	55.7%	67.15
R3KU	KU 1, KU 2, KU 3	59.6%	69.6
R4KU	KU 1, KU 2, KU 3, KU 4	62.0%	67.62



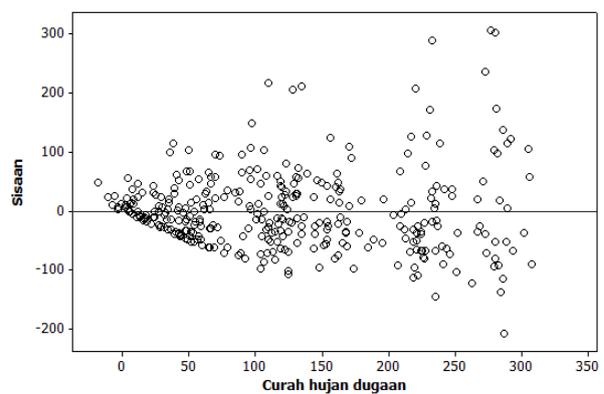
(a)



(b)



(c)



(d)

**Gambar 5** Plot sisaan dan nilai curah hujan dugaan model R1KU (a), model R2KU (b), model R3KU (c), dan model R4KU (d) pada data GCM

2.4. Analisis Data GCM Tunda

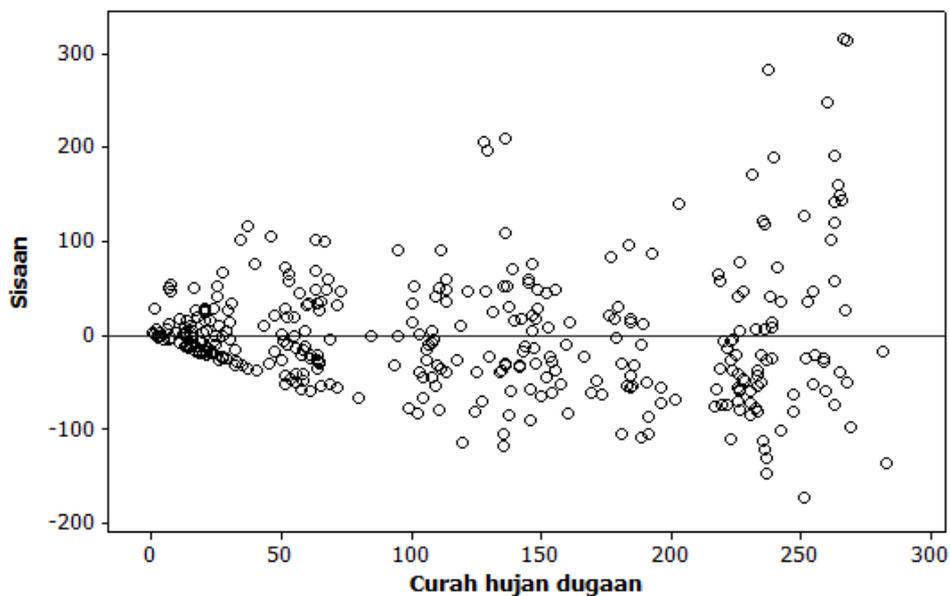
2.4.1. Regresi Kuadrat Terkecil Parsial (RKTP)

Sama halnya pada bagian RKTP data GCM, analisis pada bagian ini diawali dengan penentuan jumlah faktor yang akan digunakan dalam pemodelan dengan menggunakan statistik PRESS. Nilai PRESS pada Tabel 5 memberikan informasi bahwa cukup menggunakan 1 faktor dalam model RKTP. Jumlah faktor yang digunakan dalam model RKTP pada data GCM tunda lebih sedikit daripada jumlah faktor pada data GCM. Faktor tersebut mampu menjelaskan keragaman data presipitasi GCM tunda sebesar 83.1% dan keragaman data curah hujan stasiun sebesar 62.1%.

Diagnosis sisaan model RKTP menunjukkan bahwa kondisi ragam sisaan data GCM tunda tidak homogen (Gambar 6). Pola corong yang terbentuk mengindikasikan terjadinya heterokedastisitas pada data GCM tunda. Nilai mutlak sisaan cenderung membesar seiring dengan penambahan nilai curah hujan dugaan.

**Tabel 5** Komponen terekstrak pada model RKTP data GCM tunda

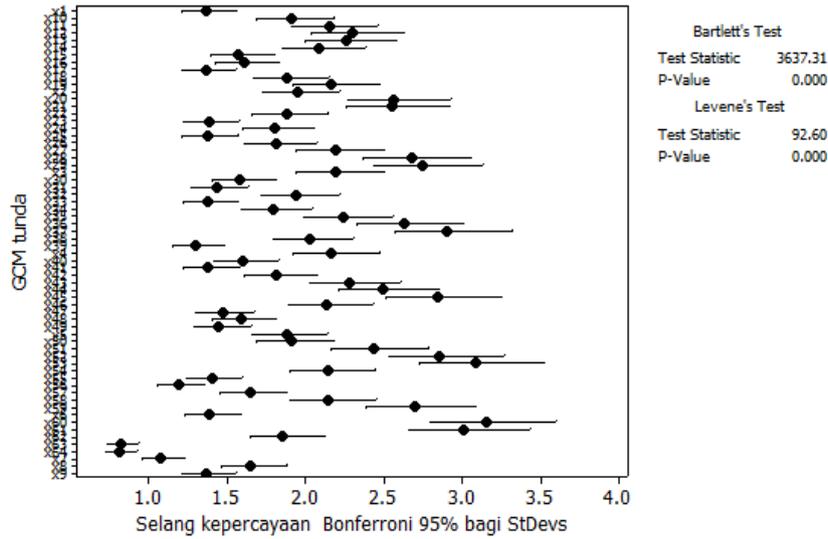
Jumlah faktor terekstrak	Akar rata-rata PRESS	Peluang > PRESS	Keragaman kumulatif	
			Peubah Prediktor	Peubah Respon
0	1.017409	<.0001		
1	0.63070	0.3630	83.1%	62.1%
2	0.62841	1.0000		
3	0.63530	0.0120		



**Gambar 6** Plot sisaan dan nilai curah hujan dugaan model RKTP data GCM tunda

2.4.2. Regresi Komponen Utama

Hasil uji kehomogenan ragam data GCM tunda menunjukkan bahwa data GCM tunda memiliki ragam yang heterogen (Gambar 7). Oleh karena itu, AKU dibentuk berdasarkan matriks korelasi peubah asal. Selanjutnya, 4 KU yang diperoleh mampu menjelaskan keragaman data sebesar 95% (Tabel 6). Dengan demikian, terdapat 4 model RKU berdasarkan jumlah KU yang digunakan pada data GCM tunda.



Gambar 7 Uji kehomogenan ragam data GCM tunda

Tabel 6 Keragaman KU menggunakan AKU pada data GCM tunda

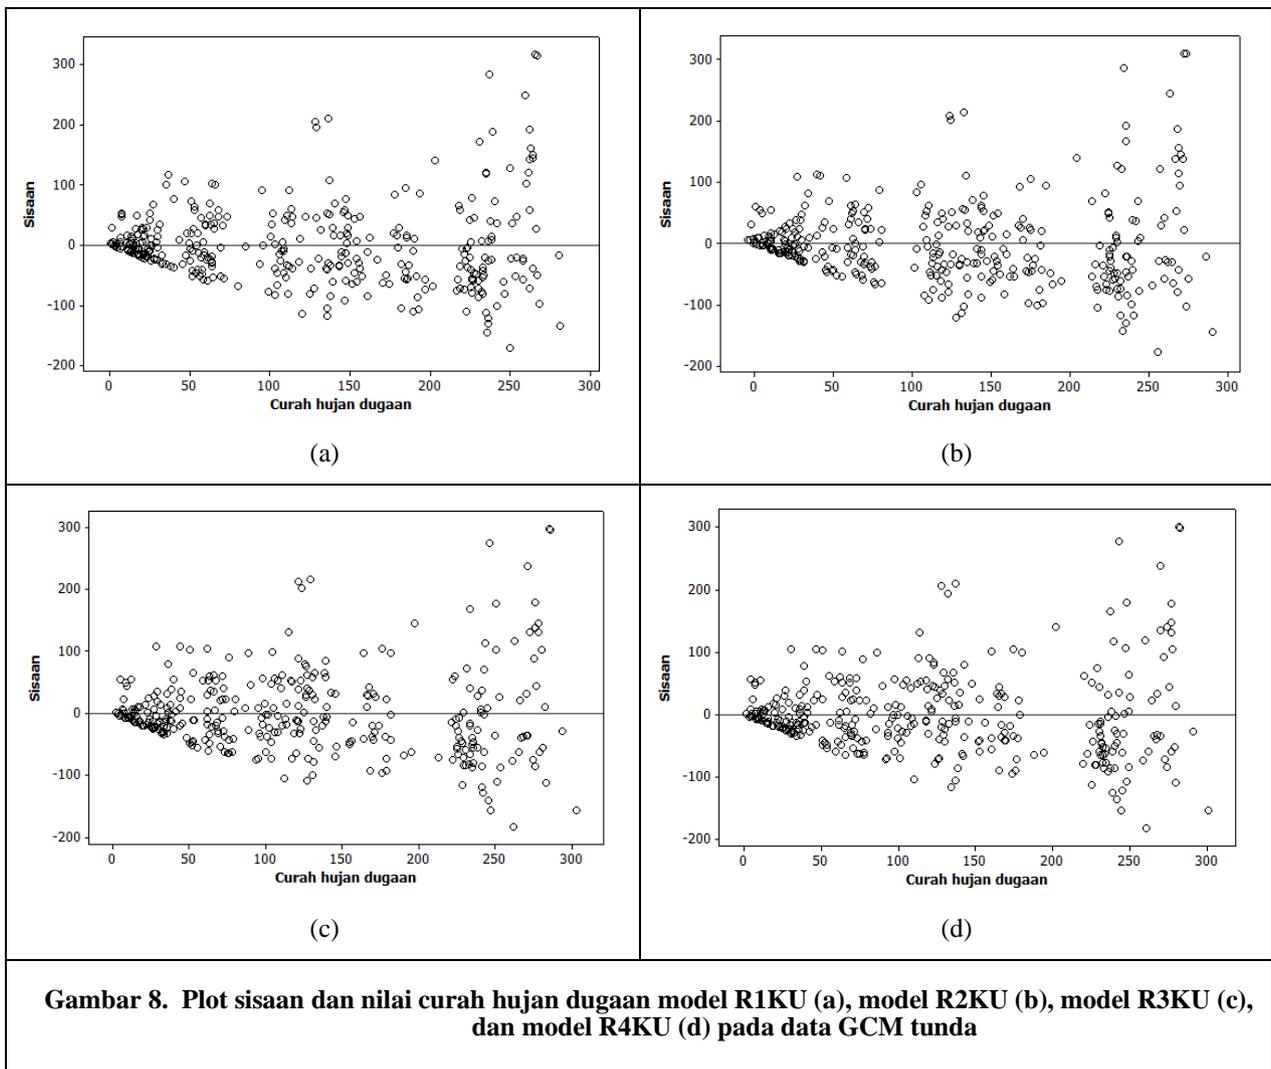
	KU 1	KU 2	KU 3	KU 4	KU 5
Nilai Akar Ciri	53.16	3.81	2.68	1.15	0.66
Proporsi Keragaman	0.83	0.06	0.04	0.02	0.01
Proporsi Kumulatif	0.83	0.89	0.93	0.95	0.96

Tabel 7 Nilai R<sup>2</sup> dan RMSE model data GCM tunda

Model	Komponen	R <sup>2</sup>	RMSE
RKTP	Faktor 1	71.7%	57.93
R1KU	KU 1	62.0%	67.33
R2KU	KU 1, KU 2	62.3%	67.15
R3KU	KU 1, KU 2, KU 3	63.0%	66.67
R4KU	KU 1, KU 2, KU 3, KU 4	63.0%	66.69

Hasil regresi antara KU dengan data curah hujan stasiun memberikan informasi bahwa keempat model RKU menghasilkan nilai  $R^2$  berkisar 62.0%–63.0% dan nilai RMSE berkisar 66.69–67.33 (Tabel 7). Hal ini berarti bahwa model awal RKU dengan menggunakan data GCM tunda lebih baik daripada model RKU dengan data GCM tanpa waktu tunda. Model RKU pada data GCM tunda rata-rata mampu menjelaskan keragaman data sekitar 63%. Namun, model RKTP pada data GCM tunda lebih baik dalam menjelaskan keragaman data daripada keempat model RKU. Secara umum, model RKTP pada data GCM tunda merupakan model terbaik dengan nilai  $R^2$  tertinggi sebesar 71.7% dan nilai RMSE terkecil sebesar 57.93.

Gambar 8 menunjukkan bahwa kondisi ragam sisaan keempat model RKU tidak homogen. Nilai mutlak sisaan semakin membesar dengan pertambahan besar nilai curah hujan dugaan. Dengan kata lain, curah hujan tinggi lebih beragam daripada curah hujan rendah.



**Gambar 8. Plot sisaan dan nilai curah hujan dugaan model R1KU (a), model R2KU (b), model R3KU (c), dan model R4KU (d) pada data GCM tunda**

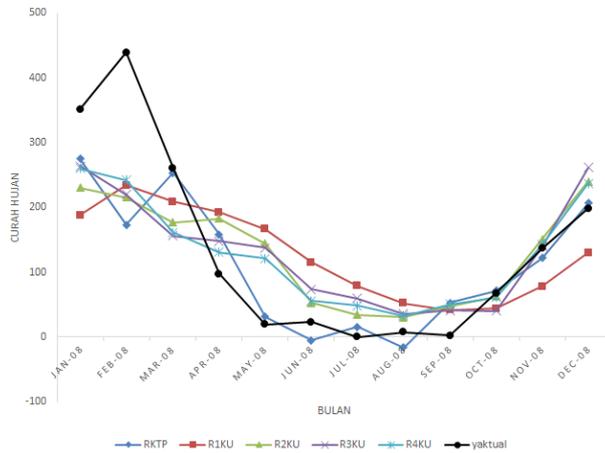
2.5. Peramalan Data Curah Hujan dan Pemilihan Model Terbaik

Peramalan dan validasi data dilakukan terhadap data curah hujan periode 2008. Tabel 7 menyajikan nilai korelasi dan RMSEP hasil pendugaan data curah hujan menggunakan data GCM tunda dan data GCM. Pada data GCM, model RKTP dan R1KU memberikan hasil dugaan yang sama dengan nilai RMSEP relatif besar, yakni berkisar 79.93–103.74 dan nilai korelasinya berkisar 0.74–0.9. Namun, model RKTP pada data GCM tunda memberikan hasil dugaan yang lebih baik daripada hasil dugaan pada data GCM. Nilai RMSEP yang dihasilkan lebih kecil, yakni berkisar 71.91–77.29. Nilai korelasinya juga lebih tinggi, yakni berkisar 0.88–0.93. Secara umum, model RKTP pada data GCM tunda merupakan model terbaik dalam menduga curah hujan stasion Indramayu periode 2008. Nilai korelasinya tertinggi, yakni sebesar 0.93 dengan nilai RMSEP yang relatif kecil sebesar 75.26

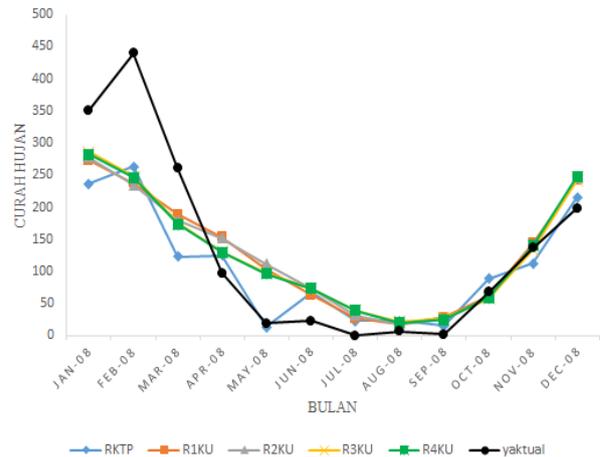
Gambar 9 menunjukkan bahwa model R1KU pada data GCM tidak mampu menangkap pola curah hujan dengan baik, khususnya periode Januari–Juni 2008. Jarak antara nilai aktual dengan nilai dugaan cukup jauh. Namun, model RKTP cukup baik dalam menangkap pola curah hujan, khususnya periode Maret–Desember 2008. Jarak antara nilai aktual dengan nilai dugaan model RKTP cukup dekat dari model R1KU secara umum.

Tabel 8 Nilai korelasi dan RMSEP hasil peramalan data curah hujan periode 2020

Model	GCM tunda		GCM	
	RMSEP	Korelasi	RMSEP	Korelasi
RKTP	75.26	0.93	84.220	0.840
R1KU	74.95	0.9	103.74	0.74
R2KU	77.29	0.88	91.87	0.81
R3KU	71.91	0.91	89.62	0.82
R4KU	73.02	0.91	79.93	0.9



Gambar 9 Plot nilai curah hujan stasiun Indramayu dan curah hujan dugaan model RKTP dan R1KU periode 2020 pada data GCM



Gambar 10. Plot nilai curah hujan stasiun Indramayu dan curah hujan dugaan model RKTP dan R1KU periode 2020 pada data GCM tunda

Plot dugaan nilai curah hujan yang dihasilkan oleh model R<sub>KU</sub> (R<sub>1KU</sub>, R<sub>2KU</sub>, R<sub>3KU</sub>, dan R<sub>4KU</sub>) pada data GCM tunda menunjukkan bahwa model R<sub>KU</sub> tidak mampu menduga curah hujan dengan baik, khususnya periode Januari–Juni 2020;'' (Gambar 10). Namun, hasil ini lebih baik dibandingkan dengan hasil dugaan model R<sub>KU</sub> pada data GCM. Model R<sub>KTP</sub> pada data GCM tunda merupakan model terbaik yang mampu melakukan pendugaan curah hujan yang mengikuti pola curah hujan aktualnya. Selain itu, jarak antara curah hujan dugaan dengan curah hujan aktual yang dihasilkan cukup dekat sesuai dengan nilai RMSEP-nya yang terkecil. Secara umum, pemodelan dengan menggunakan data GCM tunda memberikan hasil dugaan curah hujan yang lebih baik dibandingkan dengan data GCM.

### 3. Kesimpulan

Fungsi korelasi silang antara data curah hujan dan data presipitasi luaran GCM berperan penting dalam pemodelan *statistical downscaling*. Penggunaan fungsi korelasi silang dalam pemodelan *statistical downscaling* mampu meningkatkan nilai korelasi antara data curah hujan dan data presipitasi luaran GCM. Akibatnya, data GCM mampu memberikan hasil pemodelan yang lebih baik daripada data GCM. Model R<sub>KTP</sub> merupakan model terbaik yang mampu menjelaskan keragaman data dengan baik dibandingkan model lainnya (R<sub>KTP</sub> pada data GCM, R<sub>KU</sub> pada data GCM dan GCM tunda) dengan nilai jumlah kuadrat kesalahan paling minimum.

Hasil pendugaan data curah hujan stasiun Indramayu periode 2008 menunjukkan bahwa secara umum model-model pada data GCM tunda mampu memberikan hasil dugaan yang mengikuti pola aktualnya. Jarak antara data curah hujan aktual dengan curah hujan dugaan relatif dekat. Secara umum, model R<sub>KTP</sub> pada data GCM tunda merupakan model terbaik dalam memberikan hasil dugaan curah hujan. Model tersebut mampu melakukan pendugaan curah hujan yang mengikuti pola curah hujan aktualnya dengan nilai jumlah kuadrat kesalahan pendugaan terkecil.

### References

- Anggoro. 2013. Bersiaga hadapi perubahan iklim. *Agrina* [Internet]. [diunduh 2014 Apr 23]. Tersedia pada: [http://www.agrina-online.com/show\\_article](http://www.agrina-online.com/show_article).
- Estiningtyas W, Wigena AH. 2011. Teknik statistical downscaling dengan regresi komponen utama dan regresi kuadrat terkecil parsial untuk prediksi curah hujan pada kondisi el nino, la nina, dan normal. *Jurnal Meteorologi dan Geofisika*. 12(1):65-72.
- Fernandez E. 2005. On the influence of predictors area in statistical downscaling of daily parameters. *Norwegia Meteorological Institute*. 9:1-21.
- Mattjik AA, Sumertajaya IM. 2011. *Sidik Peubah Ragam*. Bogor (ID): IPB Pr.
- Wigena AH. 2011. Regresi kuadrat terkecil parsial multi respon untuk statistical downscaling. *Forum Statistika dan Komputasi*. 16(2):12-15.
- Notodiputro KA, Wigena AH, Fitriadi. 2005. Pendekatan regresi komponen utama dan ARIMA untuk statistical downscaling. *IPTEK*. 11(3):137-142.
- Wigena AH. 2006. Pemodelan statistical downscaling dengan regresi projection persuit untuk peramalan curah hujan bulanan [disertasi]. Bogor (ID): Institut Pertanian Bogor.
- Wold S, Sjostrom M, Eriksson L. 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*. 58:109-130.