

Linearized Ridge Regression Modeling with MM-Estimator in Statistical Downscaling for Rainfall Forecasting

Pemodelan *Linearized Ridge Regression* dengan *MM-Estimator* pada *Statistical Downscaling* untuk Peramalan Curah Hujan

M. Zaky Hisyam Gozhi¹, Muh. Ikbal Taufik², Siswanto Siswanto^{*3}, Anisa Kalondeng⁴, Sitti Sahrman⁵

^{1,2,3,4,5}Departemen Statistika, Universitas Hasanuddin, Indonesia

Email: ¹zakyhg25@gmail.com, ²ikbaljrt@gmail.com

^{*3}siswanto@unhas.ac.id, ⁴nkalondeng@gmail.com ⁵sittisahrimansalam@gmail.com

^{*}Corresponding Author

Received: 12 February 2025, revised: 17 April 2025, accepted: 20 April 2025

Abstract

Rainfall is one of the important climate variables to be predicted because it affects various sectors, such as agriculture, health, and disasters. One method that can be used to forecast rainfall is statistical downscaling, which is the process of relating large-scale climate variables to local-scale climate variables. However, this method has several challenges, such as the presence of heteroscedasticity, multicollinearity, and outliers in the data. To overcome these challenges, this study proposes linearized ridge regression modelling with MM-estimator in statistical downscaling for rainfall forecasting. Linearized ridge regression is a linear regression method that can reduce the influence of multicollinearity by adding a penalty parameter to the covariance matrix. MM-estimator is a robust method that can handle outliers by using two estimators, namely the initial estimator (S-estimator) and the final estimator (M-estimator). This research uses daily rainfall data from BMKG Pangkep station and Global Circulation Model (GCM) output data as predictors. The results showed that linearized ridge regression modelling with MM-estimator has better performance than linearized ridge regression modelling without MM-estimator in terms of accuracy and resilience to outliers with a correlation value of 0.94 against the acute rainfall data, the Root Means Square Error value obtained is 97.26 and 86.57% of determinant coefficient value. Therefore, linearized ridge regression modelling with MM-estimator can be used as an alternative statistical downscaling method for rainfall forecasting. Based on the forecasting results for January - December 2023, it shows that the highest rainfall in Pangkep Regency is in January and the lowest rainfall is in September.

Keywords: Linearized Ridge Regression; MM-Estimator; Rainfall; Statistical Downscaling

Abstrak

Curah hujan merupakan salah satu variabel iklim yang penting untuk diprediksi karena berpengaruh terhadap berbagai sektor, seperti pertanian, kesehatan, dan kebencanaan. Salah satu metode yang dapat digunakan untuk meramalkan curah hujan adalah *statistical downscaling*, yaitu proses menghubungkan variabel iklim berskala besar dengan variabel iklim berskala lokal. Namun, metode



JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

ini memiliki beberapa tantangan, seperti adanya heteroskedastisitas, multikolinearitas, dan pencilaan pada data. Untuk mengatasi tantangan tersebut, penelitian ini mengusulkan pemodelan regresi *ridge* yang dilinierkan dengan *MM-estimator* dalam *statistical downscaling* untuk peramalan curah hujan. *Linearized ridge regression* merupakan metode regresi linier yang dapat mengurangi pengaruh multikolinieritas dengan menambahkan parameter penalti pada matriks kovarians. *MM-estimator* merupakan metode *robust* yang dapat menangani *outlier* dengan menggunakan dua estimator, yaitu estimator awal (*S-Estimator*) dan estimator akhir (*M-Estimator*). Penelitian ini menggunakan data curah hujan harian dari stasiun BMKG Pangkep dan data luaran *Global Circulation Model* (GCM) sebagai prediktor. Hasil penelitian menunjukkan bahwa pemodelan regresi *ridge* yang dilinierisasi dengan *M-Estimator* memiliki performa yang lebih baik dibandingkan pemodelan regresi *ridge* yang dilinierisasi tanpa *M-Estimator* dari segi akurasi dan ketahanan terhadap *outlier* dengan nilai korelasi sebesar 0,94 terhadap data curah hujan dasar harian, nilai *Root Mean Square Error* yang diperoleh sebesar 97,26 dan nilai koefisien determinasi 86,57%. Oleh karena itu, pemodelan *linearized ridge regression* dengan *MM-Estimator* dapat digunakan sebagai alternatif metode *statistical downscaling* untuk peramalan curah hujan. Berdasarkan hasil peramalan untuk bulan Januari - Desember 2023 menunjukkan bahwa curah hujan tertinggi di Kabupaten Pangkep berada pada bulan Januari dan curah hujan terendah berada pada bulan September.

Kata kunci: *Linearized Ridge Regression; MM-Estimator; Curah Hujan; Statistical Downscaling*

1. PENDAHULUAN

Kekeringan memiliki dampak yang sangat besar di Indonesia sebagai negara agraris. Kekeringan dapat mengurangi produksi tanaman pangan yang mempengaruhi jumlah pangan nasional dan stabilitas ekonomi [18]. Maka dari itu, diperlukan cara untuk mencegah dan mengatasi kekeringan dengan melakukan peramalan curah hujan. Peramalan curah hujan adalah usaha untuk mengetahui kondisi curah hujan di masa depan dengan menggunakan metode tertentu. Peramalan curah hujan dapat membantu pemerintah dan masyarakat dalam mengurangi risiko, meningkatkan kewaspadaan, dan menyesuaikan diri dengan kekeringan.

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) menggunakan metode *Adaptive Neuro-Fuzzy Inference System*, *Autoregressive Integrated Moving Average*, dan *Wavelet* untuk meramalkan curah hujan di Indonesia [15]. Namun, hasil dari gabungan ketiga metode tersebut masih belum memberikan hasil yang optimal dengan tingkat akurasinya hanya sekitar 60% - 70%. Hal ini disebabkan oleh pola atmosfer di Indonesia yang tidak stabil dan sulit diprediksi serta data yang digunakan untuk peramalan adalah data curah hujan yang diukur di permukaan bumi [1]. Oleh karena itu, diperlukan metode yang menggunakan data atmosfer yang didapat dari luaran *Global Circulation Model* (GCM). Luaran GCM adalah model numerik yang menggambarkan sistem iklim dan hubungan antara penyusun-penyusunnya, yaitu atmosfer, lautan, kriosfer, biosfer, dan kemosfer [11]. Namun, informasi iklim dari GCM masih berskala global sehingga digunakan *statistical downscaling* untuk mendapatkan informasi iklim dalam skala lokal dengan resolusi yang tinggi.

Statistical downscaling merupakan model statistika yang dapat menyinkronkan variabel iklim dari GCM yang berskala global (presipitasi) dengan variabel iklim yang berskala lokal (curah hujan) [17]. Pendekatan *statistical downscaling* didasarkan dengan terdapatnya hubungan antara grid skala global (prediktor) dan grid skala lokal (respon) yang dinyatakan dengan model statistika yang digunakan untuk menerjemahkan karakteristik skala global menjadi karakteristik dari beberapa variabel iklim lokal. Luaran GCM memiliki dimensi yang besar dan korelasi yang tinggi (multikolinieritas) antar-grid [22].

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

Ridge Regression (RR) merupakan metode yang dapat dilakukan dalam mengatasi masalah multikolinearitas. *Ridge Regression* dibutuhkan satu nilai untuk konstanta estimasi *ridge*, sedangkan dalam metode *Generalized Ridge Regression* (GRR) dibutuhkan konstanta sejumlah variabel regsesornya [24]. Namun, karena konstanta optimal pada estimasi *ridge* dan estimasi *generalized ridge* sulit dicari, maka metode ini jarang digunakan. Selain itu, proses estimasi menggunakan *generalized ridge* akan menghasilkan fungsi dari parameter *ridge* yang rumit sehingga estimasi dengan menggunakan metode ini akan lebih sulit dilakukan. Ketiga estimasi tersebut masih memiliki beberapa kelemahan yang kemudian diperbaiki menjadi estimasi *Linearized Ridge Regression* (LRR) dengan menggabungkan metode GRR dengan metode Liu-type [1]. Meskipun demikian, metode LRR adalah sebuah metode penaksiran parameter yang sensitif terhadap data *outlier* yang dapat mengurangi kebaikan model [11]. Salah satu metode untuk mengatasi *outlier* pada data adalah *MM-Estimator*. Metode *MM-estimator* dapat memperoleh estimasi parameter yang tidak terlalu dipengaruhi oleh *outlier* dan memiliki varians yang kecil [7].

Sahrman dkk. (2024) membahas mengenai metode LRR untuk mengatasi multikolinearitas pada data curah hujan Kabupaten Pangkep. Akan tetapi, adanya nilai pencilan pada data membuat nilai koefisien determinasi pada model relatif rendah yang hanya sebesar 57% [16]. Sementara itu, penelitian lainnya yang dilakukan menggunakan metode regresi *ridge robust S, M*, dan *MM-estimator* untuk mengatasi masalah multikolinearitas dan *outlier*. Metode *robust MM-estimator* memiliki efisiensi dan nilai *breakdown point* yang tinggi, sehingga cocok untuk mengatasi data yang mengandung *outlier* atau melanggar asumsi normalitas [12]. Berdasarkan penelitian di atas, penelitian kali ini berfokus pada kombinasi antara LRR dan *MM-Estimator* dalam mengatasi masalah multikolinearitas dan *outlier* pada data curah hujan Kabupaten Pangkep.

2. LANDASAN TEORI

2.1 Statistical Downscaling

Teknik *statistical downscaling* merupakan teknik yang mengubah data dengan skala yang besar menjadi data dengan skala yang lebih kecil atau bersifat lokal. *Statistical downscaling* mengasumsikan bahwa iklim saat ini valid untuk iklim masa depan yang membutuhkan deret waktu dengan pengamatan yang cukup panjang dan berkualitas tinggi, dan hanya memberikan variabel yang datanya telah diamati [2]. Teknik ini menginterpolasi variabel-variabel prediktor atmosfer berskala besar terhadap variabel-variabel berskala lebih kecil. Teknik ini menggunakan model statistika untuk menginterpretasikan hubungan antara data berskala global dengan data berskala lokal dalam rentang waktu tertentu [23].

Penggunaan model *statistical downscaling* membutuhkan data GCM sebagai bahan utama untuk meramalkan curah hujan lokal. Hasil dari model tersebut berkaitan langsung dengan data curah hujan pada masa lampau yang dapat meramal curah hujan untuk waktu yang akan datang. *Statistical downscaling* harus memenuhi syarat sebagai berikut untuk hasil yang memuaskan [2]:

1. Variabel respon maupun variabel prediktor memiliki hubungan yang kuat untuk mendeskripsikan keragaman iklim lokal dengan baik.
2. Variabel prediktor diproyeksikan sangat baik oleh model GCM.
3. Tidak berubahnya hubungan antara variabel prediktor dan variabel respon selama perubahan waktu dan tetap sama meskipun terdapat perubahan iklim. Secara umum model *statistical downscaling* ditulis dalam persamaan (2.1).

$$Y_{(t,p)} = f(X_{t,q,s,g}) \quad (2.1)$$

X merupakan variabel model GCM dan Y merupakan variabel iklim lokal. t adalah interval waktu, p adalah jumlah variabel Y, q adalah jumlah variabel X, s adalah jumlah lapisan atmosfer, dan g adalah jumlah grid domain GCM [3].

2.2 Multikolinearitas

Masalah yang sering muncul dalam analisis regresi linear berganda adalah adanya keterkaitan yang sangat kuat antara variabel prediktor yang disebut multikolinearitas. Akibat dari multikolinearitas menyebabkan estimasi parameter regresi yang didapat menjadi tidak efisien karena memiliki varians dan bias yang tinggi. Multikolinearitas juga dapat membuat hasil estimasi menjadi sensitif terhadap perubahan kecil. Selain itu multikolinearitas dapat menimbulkan perbedaan kesimpulan antara uji statistik t dan uji statistik f.

Ukuran yang dapat digunakan untuk melakukan pengujian terhadap data yang terdeteksi multikolinearitas pada regresi linier berganda adalah *Variance Inflation Factors* (VIF). Multikolinearitas dapat dilihat dari nilai VIF yang diperoleh. Nilai VIF dapat diperoleh dengan menggunakan persamaan (2.2):

$$VIF_j = \frac{1}{1 - R_j^2} \quad (2.2)$$

Dengan R_j^2 adalah koefisien determinasi dari variabel x_j apabila diregresikan dengan semua variabel independen dalam model. Umumnya, nilai VIF_j yang sering dijadikan patokan dalam mengukur multikolinearitas adalah lebih besar dari 10 ($VIF_j > 10$). Karena nilai $VIF_j > 10$, maka

$$\begin{aligned} VIF_j &> 10 \\ \frac{1}{1 - R_j^2} &> 10 \\ \frac{1}{10} &> 1 - R_j^2 \\ 0,1 - 1 &> -R_j^2 \\ R_j^2 &> 0,9 \end{aligned}$$

Jika nilai $VIF_j > 10$, maka koefisien determinasi $R_j^2 > 0,9$ menyatakan bahwa variabel prediktor x_j dijelaskan sangat baik oleh variabel prediktor lainnya, yang artinya terjadi multikolinearitas pada model regresi linier berganda.

2.3 Linearized Ridge Regression

Metode yang dapat digunakan untuk mengatasi multikolinearitas, diantaranya metode Liu, *ridge*, dan metode GRR. Namun, ketiga metode ini menimbulkan beberapa permasalahan lain pada saat dilakukan estimasi parameter, seperti penentuan konstanta optimal yang sulit dan nilai PRESS (*Prediction Error Sum of Square*) yang besar. Oleh karena itu, terdapat metode *Linearized Ridge Regression* (LRR) yang dapat mengatasi permasalahan di atas. Liu dan Gao mengusulkan metode estimasi parameter model regresi linier berganda yaitu metode *Linearized Ridge Regression* (LRR) sebagai pengembangan dari metode-metode sebelumnya yang dapat mengatasi multikolinearitas [8]. Metode ini dapat mengatasi kelemahan yang terdapat pada metode-metode sebelumnya, diantaranya adalah penentuan optimal yang sulit. Estimasi parameter model regresi dengan metode LRR menghasilkan estimasi parameter model regresi yang disebut dengan estimasi LRR. Metode *Linearized Ridge Regression* akan menghasilkan estimasi LRR yang diperoleh dengan menggunakan hubungan antara k pada estimasi *ridge* dan d pada estimasi Liu, serta hubungan antara k_j pada estimasi *generalized ridge* dan d_j sehingga diperoleh estimasi LRR seperti yang dituliskan pada persamaan (2.3):

$$\hat{\beta}_{LRR} = (Z^T Z + I)^{-1} [(Z^T Z) + QDQ^T] \hat{\beta} \quad (2.3)$$

Dengan

$\mathbf{Z}$: Matriks desain yang berisi data pengamatan dari variabel independent

$\mathbf{Z}^T \mathbf{Z}$: Matriks kovarians dari $\mathbf{Z}$

$\mathbf{I}$: Matriks identitas ukuran $p \times p$

$\mathbf{Q}$: Matriks ortogonal

$\mathbf{D}$: Matriks diagonal

$\hat{\beta}$: Estimasi awal dari parameter regresi linear

2.4 Outlier

Outlier merupakan titik-titik data yang tidak mengikuti pola data lainnya. Adanya *outlier* pada data akan mengganggu dalam proses analisis data dan harus dihindari. Salah satu metode yang dapat digunakan untuk mendeteksi adanya *outlier* adalah *difference in fit standardized* (DFFITS). Metode DFFITS merupakan gabungan antara metode *leverage* ($\mathbf{h}_{ii}$) dan $\mathbf{t}_i$. Pada model *leverage*, $\mathbf{t}_i$ adalah *R-student* (*studentized deleted residual*) untuk kasus ke- i . Persamaan (2.4) digunakan untuk menghitung nilai DFFITS [9]:

$$\text{DFFITS} = \mathbf{t}_i \left(\frac{\mathbf{h}_{ii}}{1 - \mathbf{h}_{ii}} \right)^{\frac{1}{2}} \quad (2.4)$$

Dengan

$\mathbf{t}_i$: residual standar untuk pengamatan ke- i

$\mathbf{h}_{ii}$: elemen diagonal dari matriks *leverage* untuk pengamatan ke- i

2.5 Robust S-Estimator

M-Estimator menggunakan teknik iterasi pembobotan kuadrat terkecil (*Iteratively Reweighted Least Square*) dalam proses estimasinya. Metode ini efektif dalam menangani data yang mengandung *outlier*, khususnya pada variabel respon (y), namun memiliki keterbatasan dalam hal *breakdown point* yang lebih rendah dibandingkan *estimator robust* lainnya [21].

Metode *Robust S-Estimator* merupakan salah satu metode dalam regresi *robust* yang dirancang untuk menangani data dengan *outlier* secara efektif. Metode ini memiliki keunggulan berupa *breakdown point* yang tinggi, yaitu mencapai 50%, sehingga dapat menangani data dengan proporsi *outlier* yang signifikan tanpa kehilangan keakuratan estimasi [14]. Metode *S-Estimator* bekerja dengan meminimumkan fungsi skala residual berdasarkan fungsi pembobot, seperti *Tukey's Bisquare*, hingga iterasi mencapai konvergensi. Proses iteratif dimulai dengan menentukan estimasi awal koefisien regresi, kemudian menghitung residual dan nilai pembobot secara berulang hingga diperoleh nilai parameter yang stabil. Secara matematis, *S-Estimator* didefinisikan sebagai solusi dari persamaan (2.5) [19]:

$$\hat{\beta}_s = \min_{\beta} \hat{\sigma}_s(\mathbf{e}_1, \mathbf{e}_2, \mathbf{e}_3, \dots, \mathbf{e}_n) = \min \sum_{i=1}^n \rho \left(\frac{y_i - \sum_{j=0}^p X_{ij} \beta_j}{\hat{\sigma}} \right) \quad (2.5)$$

Dengan:

$$\hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n (\mathbf{e}_i^2) - (\sum_{i=1}^n \mathbf{e}_i)^2}{n(n-1)}} \quad (2.6)$$

Dengan

ρ : fungsi *loss* atau fungsi pembobot

$\mathbf{e}_i$: nilai residual untuk pengamatan ke- i

$\hat{\sigma}_s$: skala estimasi

y_i : variabel respon untuk pengamatan ke- i
 x_{ij} : variabel prediktor ke- j untuk pengamatan ke- i
 β_j : parameter regresi ke- j

2.6 Robust M-Estimator

Metode *M-Estimator* merupakan salah satu metode dalam regresi *robust* yang dikembangkan untuk mengatasi kelemahan metode kuadrat terkecil ketika data mengandung *outlier*. Metode ini bekerja dengan mengganti fungsi kuadrat pada OLS dengan fungsi objektif lain yang dapat meminimumkan pengaruh *outlier*. Secara matematis, *M-estimator* dapat didefinisikan dalam persamaan (2.7) [6]:

$$\hat{\beta}_M = \min_{\beta} \sum_{i=1}^n \rho\left(\frac{e_i}{\hat{\sigma}_s}\right) = \min_{\beta} \sum_{i=1}^n \rho\left(\frac{y_i - \sum_{j=0}^p X_{ij}\beta_j}{\hat{\sigma}_s}\right) \quad (2.7)$$

2.7 Robust MM-Estimator

Pada tahun 1987 Yohai memperkenalkan *robust MM-estimator* yang mengkombinasikan efisiensi tinggi (mencapai 95%) dengan suatu *high breakdown point* (50%) [20]. Metode ini menggunakan skala residual yang diminimumkan menggunakan *S-estimator* untuk mengestimasi koefisien parameter. Selanjutnya skala residual tetap konstan dan digunakan *M-Estimator* untuk melakukan menetapkan parameter-parameter regresi. Metode *MM-estimator* didefinisikan dalam persamaan (2.8) [4]:

$$\hat{\beta}_{MM} = \min \sum_{i=1}^n \rho\left(\frac{e_i}{\hat{\sigma}_M}\right) = \sum_{i=1}^n \rho\left(\frac{y_i - \sum_{j=0}^p X_{ij}\beta_j}{\hat{\sigma}_M}\right) \quad (2.8)$$

Dengan $\hat{\sigma}_M$ merupakan skala residual awal yang diperoleh menggunakan *S-estimator* yang konvergen.

2.8 Linearized Ridge MM-Estimator

Linearized Ridge MM-Estimator (LRMM) dihasilkan dengan mengganti $\hat{\beta}$ pada persamaan (2.3) menjadi $\hat{\beta}_{MM}$ yang merupakan hasil estimasi dari *Robust MM* pada persamaan (2.8). Pendekatan ini mengelola multikolinearitas melalui LRR, meningkatkan ketahanan terhadap *outlier* dan gangguan data menggunakan *MM-Estimator*. Metode LRMM mampu menghasilkan model regresi yang lebih stabil, terutama ketika data mengandung *outlier*. LRMM didefinisikan dalam persamaan (2.9):

$$\hat{\beta}_{LRMM} = (Z'Z + I)^{-1}[(Z'Z) + QDQ']\hat{\beta}_{MM} \quad (2.9)$$

2.9 Curah Hujan

Curah hujan adalah bagian penting dari siklus hidrologi dan perubahan polanya secara langsung memengaruhi sumber daya air. Perubahan pola curah hujan sebagai akibat dari perubahan iklim kini menjadi masalah bagi pengelola sumber daya air dan ahli hidrologi [5]. Curah hujan yang ditentukan oleh beberapa unsur seperti topografi, arah medan, arah angin, dan kecepatan angin, adalah banyaknya curah hujan yang turun pada suatu wilayah tertentu dalam waktu tertentu dan dicatat dengan menggunakan alat pengukur hujan secara harian, bulanan, dan skala tahunan dalam skala milimeter atau sentimeter [10]. Intensitas curah hujan dapat digunakan untuk memperkirakan dampak curah hujan, termasuk kekeringan, tanah longsor, dan banjir.

Curah hujan disebabkan oleh penguapan air permukaan laut yang naik ke atmosfer, lalu mendingin, dan kemudian menyuling sebagian di laut dan sebagian di darat. Air hujan yang jatuh di

darat sebagian menembus tanah (penetrasi), sebagian tertahan oleh tanaman (*blocking*), sebagian menguap kembali (menguap), dan sebagian menjadi lembab [13].

3. METODOLOGI PENELITIAN

Data yang digunakan pada penelitian ini adalah data curah hujan lokal (mm/bulan) di Kabupaten Pangkep yang berasal dari BMKG Kabupaten Maros dari Januari 1999 hingga Juli 2023 sebagai variabel respon dan data curah hujan atmosfer yang diperoleh dari GCM sebanyak 64 variabel sebagai variabel prediktor. Langkah-langkah metode riset yang dilakukan pada riset ini:

- a) Eksplorasi data dengan metode statistik deskriptif dan diagram kotak garis pada data GCM dan curah hujan lokal
- b) Pembagian data curah hujan menjadi dua kelompok, yaitu data *train* dan data *test*. Data *train* yang digunakan adalah data pada periode Januari 1999 sampai Desember 2021 dan data *test* yang digunakan adalah data pada periode Januari 2022 sampai Juli 2023.
- c) Penentuan nilai *Cross-Correlation Function* (CCF) yang merupakan nilai korelasi tertinggi antara variabel berskala global dengan variabel yang berskala lokal untuk menyeleraskan data GCM dengan data curah hujan lokal
- d) Identifikasi multikolinearitas pada data curah hujan menggunakan persamaan (2.2).
- e) Identifikasi *outlier* pada data dengan menggunakan persamaan (2.3).
- f) Pembentukan model *statistical downscaling* menggunakan *Linearized Ridge MM-Estimator*

- 1) Mengestimasi β awal dengan menggunakan metode kuadrat terkecil sehingga diperoleh nilai $\hat{y}_i$
- 2) Menghitung nilai residual $e_i = y_i - \hat{y}_i$ dari metode kuadrat terkecil
- 3) Menghitung $\hat{\sigma}$ dengan menggunakan persamaan (2.6).
- 4) Menghitung nilai $u_i = \frac{e_i}{\hat{\sigma}}$
- 5) Menghitung pembobot awal w_i menggunakan pembobot *tukey bisquare* dengan persamaan:

$$w_i = \begin{cases} \left[1 - \left(\frac{u_i}{1.547}\right)^2\right]^2 & , \quad |u_i| \leq 1.547 \\ 0 & , \quad |u_i| > 1.547 \end{cases}$$

- 6) Mengestimasi koefisien $\hat{\beta}_s$ dengan metode *weighted least square* menggunakan pembobot w_i berdasarkan persamaan (2.5).
- 7) Mengulangi langkah 2 – 6 hingga nilai $\hat{\beta}_s$ konvergen.
- 8) Menghitung nilai residual $e_i = y_i - \hat{y}_i$ dari $\hat{\beta}_s$
- 9) Menghitung $\hat{\sigma}$ dengan menggunakan persamaan:

$$\hat{\sigma}_M = \frac{\text{median}|e_i - \text{median}(e_i)|}{0.6745}$$

- 10) Menghitung nilai $u_i = \frac{e_i}{\hat{\sigma}_M}$
- 11) Menghitung pembobot w_i menggunakan pembobot *tukey bisquare* berdasarkan persamaan:

$$w_i = \begin{cases} \left[1 - \left(\frac{u_i}{4.685}\right)^2\right]^2 & , \quad |u_i| \leq 4.685 \\ 0 & , \quad |u_i| > 4.685 \end{cases}$$

- 12) Mengestimasi koefisien $\hat{\beta}_{MM}$ dengan metode *weighted least square* menggunakan pembobot w_i berdasarkan persamaan (2.8) sehingga diperoleh nilai residual yang baru
- 13) Menghitung nilai residual baru dari langkah 12 sebagai residual langkah 8
- 14) Mengulang langkah 8 sampai langkah 13 sehingga diperoleh $\hat{\beta}_{MM}$ konvergen
- 15) Menghitung nilai matriks orthogonal Q

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman


- 16) Menghitung nilai matrix diagonal D
- 17) Mengestimasi koefisien $\hat{\beta}_{LRMM}$ menggunakan persamaan (2.9)
- g) Melakukan validasi terhadap model yang telah dibentuk dengan nilai *Mean Absolute Percentage Error* (MAPE) dan nilai korelasi antara hasil peramalan curah hujan dengan LRR dengan data aktual (data curah hujan lokal).
- h) Meramalkan curah hujan menggunakan model yang telah dibentuk dan divalidasi untuk periode Januari 2023 – Desember 2023.

4. HASIL DAN PEMBAHASAN

4.1 Eksplorasi Data

1. Data Curah Hujan Lokal

Hasil eksplorasi data menggunakan diagram kotak garis dan statistika deskriptif pada data curah hujan lokal dari BMKG yang dijelaskan pada Gambar 1 dan Tabel 1 untuk mengetahui karakteristik data curah hujan yang akan digunakan dalam pembentukan model. Berdasarkan hasil eksplorasi data pada data curah hujan yang berasal dari BMKG pada gambar 1, dapat diketahui bahwa rata – rata curah hujan bulanan dari tahun 1999 – 2023 di Kabupaten Pangkep memiliki curah hujan terendah berada pada bulan Agustus dengan rata-rata 19,96 dan curah hujan tertinggi pada bulan Januari dengan rata-rata 773,5.



Gambar 1. Eksplorasi Data Curah Hujan dari BMKG

Tabel 1. Statistika Deskriptif Data Curah Hujan dari GCM


Variabel	Mean	StDev	Min	Median	Max
Januari	773,50	292,60	255,50	743,30	1540,50
Februari	580,20	226,10	116,00	529,50	1006,50
Maret	429,40	178,20	150,00	419,50	958,00
April	278,90	175,20	75,50	249,00	884,00
Mei	167,00	93,40	42,50	141,70	374,30
Juni	129,30	91,50	31,50	94,70	385,50
Juli	50,87	45,64	0,00	38,50	169,50
Agustus	19,96	32,02	0,00	9,35	117,00
September	38,80	80,80	0,00	6,50	350,00

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

Oktober	172,20	157,70	0,00	153,50	524,30
November	319,70	204,30	0,00	339,50	779,50
Desember	624,00	328,40	0,00	629,60	1252,50

2. Data Curah Hujan di Atmosfer

Hasil eksplorasi data menggunakan diagram kotak garis pada data curah hujan di atmosfer menggunakan GCM yang dijelaskan pada gambar 2, dilakukan untuk mengetahui karakteristik data curah hujan yang akan digunakan dalam pembentukan model. Berdasarkan hasil eksplorasi data dan statistik deskriptif curah hujan dari atmosfer menggunakan GCM, yang dijelaskan pada Gambar 2 dan Tabel 2 dapat diketahui bahwa data setiap bulatan memiliki pola yang serupa dengan data curah hujan lokal di Kabupaten Pangkep dan membentuk pola hujan monsun yang memiliki perbedaan signifikan antara periode musim kemarau dan periode musim hujan. Berdasarkan hasil eksplorasi data pada data curah hujan di skala global yang berasal dari GCM, dapat diketahui bahwa data curah hujan bulanan dari tahun 1999-2023 di atmosfer wilayah Kabupaten Pangkep memiliki curah hujan terendah berada pada bulan September dengan rata-rata 255,55 dan curah hujan tertinggi pada bulan Februari dengan rata-rata 610,28.



Gambar 2. Eksplorasi Data Curah Hujan dari GCM

Tabel 2. Statistik Deskriptif Data Curah Hujan dari GCM

Variabel	Mean	StDev	Min	Median	Max
Januari	558,85	14,32	530,13	558,19	582,57
Februari	610,28	9,69	469,99	611,14	620,49
Maret	452,96	11,50	431,60	454,26	475,34
April	436,98	11,00	410,21	437,78	454,54
Mei	401,35	6,83	388,98	402,81	414,36
Juni	358,34	6,85	348,83	356,01	371,90
Juli	328,59	4,35	321,90	327,58	337,95
Agustus	316,55	4,72	305,62	317,13	323,19
September	225,55	5,88	200,09	227,01	337,50
Oktober	349,68	7,71	329,29	350,78	362,67


JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

Variabel	Mean	StDev	Min	Median	Max
November	428,49	8,27	410,24	431,16	440,98
Desember	540,07	9,44	520,23	542,59	556,47

4.2 Cross-correlation Function

Penyelarasan penggunaan *statistical downscaling* pada data berskala global dan data skala lokal, dilakukan dengan cara mengidentifikasi nilai *cross correlation function* (CCF) yang tertinggi masing-masing variabel prediktor terhadap variabel respon. Berikut salah satu hasil *cross correlation function* pada variabel X_1 .

Berdasarkan nilai CCF variabel X_1 yang dijelaskan pada gambar 3 (a), diketahui nilai korelasi tertinggi berada pada lag +2, hal ini berarti bahwa nilai curah hujan lokal memiliki korelasi yang kuat dengan nilai curah hujan GCM pada 2 periode setelahnya. Data yang telah diolah berdasarkan nilai CCF yang diperoleh pada gambar 3 (b) dan Tabel 3 akan digunakan dalam pembentukan model bersama data curah hujan lokal di Kabupaten Pangkep.



(a) (b)
Gambar 3. (a) CCF variabel X_1 , (b) data curah hujan di Atmosfer setelah di *statistical downscaling*

Tabel 3. Hasil CCF pada masing-masing variabel prediktor

Variabel	Lag	CCF	Variabel	Lag	CCF
X_1	2	0.74	X_{33}	1	0.78
X_2	1	0.76	X_{34}	1	0.78
X_3	1	0.78	X_{35}	1	0.77
X_4	1	0.74	X_{36}	1	0.72
X_5	8	0.65	X_{37}	8	0.73
X_6	6	0.70	X_{38}	8	0.71
X_7	6	0.73	X_{39}	0	0.74
X_8	10	0.69	X_{40}	0	0.68
X_9	1	0.76	X_{41}	1	0.78
X_{10}	1	0.77	X_{42}	1	0.79
X_{11}	1	0.78	X_{43}	1	0.77
X_{12}	1	0.74	X_{44}	8	0.70
X_{13}	8	0.71	X_{45}	9	0.71
X_{14}	7	0.72	X_{46}	9	0.72
X_{15}	6	0.63	X_{47}	0	0.70

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

Variabel	Lag	CCF	Variabel	Lag	CCF
X ₁₆	9	0.69	X ₄₈	0	0.67
X ₁₇	1	0.79	X ₄₉	1	0.76
X ₁₈	1	0.79	X ₅₀	1	0.79
X ₁₉	1	0.78	X ₅₁	1	0.75
X ₂₀	1	0.74	X ₅₂	8	0.71
X ₂₁	8	0.69	X ₅₃	9	0.70
X ₂₂	7	0.54	X ₅₄	9	0.68
X ₂₃	10	0.53	X ₅₅	1	0.66
X ₂₄	10	0.56	X ₅₆	0	0.69
X ₂₅	1	0.79	X ₅₇	1	0.74
X ₂₆	1	0.79	X ₅₈	1	0.78
X ₂₇	1	0.78	X ₅₉	1	0.75
X ₂₈	1	0.75	X ₆₀	8	0.72
X ₂₉	1	0.73	X ₆₁	8	0.71
X ₃₀	1	0.73	X ₆₂	1	0.65
X ₃₁	-9	0.59	X ₆₃	1	0.68
X ₃₂	0	0.64	X ₆₄	0	0.73

4.3 Identifikasi Multikolinearitas

Hasil identifikasi multikolinearitas menggunakan nilai *Variance Inflation Factor* (VIF) pada data curah hujan skala global luaran GCM yang akan digunakan sebagai variabel prediktor. Berdasarkan hasil nilai VIF dari 64 variabel prediktor yang terlampir pada Tabel 4, dapat diketahui bahwa pada data terdapat multikolinearitas atau terdapat korelasi antar variabel prediktornya karena memiliki nilai $VIF > 10$, sehingga berdasarkan identifikasi multikolinearitas ini diperlukan *Linearized Ridge Regression* untuk mengoptimalkan peramalan curah hujan.

Tabel 4. Nilai VIF Variabel Prediktor

Variabel	Nilai VIF	Variabel	Nilai VIF
X ₁	42,81	X ₃₃	1989,52
X ₂	471,32	X ₃₄	2398,40
X ₃	526,31	X ₃₅	1277,36
X ₄	480,6	X ₃₆	593,84
X ₅	121,83	X ₃₇	113,75
X ₆	24,05	X ₃₈	32,29
X ₇	43,17	X ₃₉	50,82
X ₈	30,29	X ₄₀	116,71
X ₉	462,64	X ₄₁	1628,44
X ₁₀	1126,81	X ₄₂	2705,36
X ₁₁	998,69	X ₄₃	1355,66
X ₁₂	1133,26	X ₄₄	401,87
X ₁₃	243,74	X ₄₅	159,73
X ₁₄	35,10	X ₄₆	54,82
X ₁₅	25,31	X ₄₇	51,84
X ₁₆	11,72	X ₄₈	94,50
X ₁₇	1178,66	X ₄₉	2039,77
X ₁₈	1433,74	X ₅₀	3186,92
X ₁₉	874,68	X ₅₁	1440,56

Variabel	Nilai VIF	Variabel	Nilai VIF
X ₂₀	947,52	X ₅₂	949,07
X ₂₁	116,35	X ₅₃	147,73
X ₂₂	7,99	X ₅₄	49,56
X ₂₃	8,27	X ₅₅	37,37
X ₂₄	8,32	X ₅₆	120,28
X ₂₅	1715,71	X ₅₇	958,25
X ₂₆	2191,42	X ₅₈	1560,32
X ₂₇	1429,59	X ₅₉	696,88
X ₂₈	868,38	X ₆₀	428,19
X ₂₉	154,60	X ₆₁	71,59
X ₃₀	42,76	X ₆₂	30,32
X ₃₁	4,26	X ₆₃	53,05
X ₃₂	29,55	X ₆₄	82,90

4.4 Identifikasi Outlier

Langkah selanjutnya adalah melakukan pendeteksian *outlier* pada data. *Outlier* adalah observasi yang berbeda polanya atau nilainya dari observasi-observasi lainnya. *Outlier* dapat mempengaruhi hasil analisis dan membuat hasil prediksi menjadi tidak akurat. Salah satu metode yang dapat digunakan untuk mendeteksi *outlier* adalah dengan menggunakan DFFITS. Nilai DFFITS yang lebih besar dari $2\sqrt{\frac{p}{n}} = 2\sqrt{\frac{64}{300}} = 0.9237$ menunjukkan bahwa data tersebut merupakan *outlier*. Berdasarkan hasil perhitungan diperoleh bahwa dari 300 data observasi terdapat 40 data observasi yang terindikasi *outlier*.

4.5 Pembentukan Model Statistical Downscaling dengan Linearized Ridge MM-Estimator

Linearized ridge MM-Estimator merupakan metode kombinasi antara *linearized ridge regression* yaitu metode yang digunakan untuk mengatasi multikolinearitas dalam model regresi dan robust MM-estimator untuk mengatasi data *outlier*. Adapun hasil estimasi parameter dengan MM-estimator disajikan pada Tabel 5.

Tabel 5. Hasil Estimasi Parameter untuk Model *Linearized Ridge MM-Estimator*


Parameter	Estimasi	Parameter	Estimasi
β_0	502,97	β_{34}	-11,37
β_1	-12,52	β_{35}	21,38
β_2	-127,14	β_{36}	-8,74
β_3	178,96	β_{37}	-23,88
β_4	-43,37	β_{38}	37,53
β_5	-9,07	β_{39}	6,20
β_6	22,99	β_{40}	-30,42
β_7	-1,88	β_{41}	-23,43
β_8	-8,61	β_{42}	194,24
β_9	-82,38	β_{43}	-52,49
β_{10}	257,78	β_{44}	-21,01
β_{11}	-313,46	β_{45}	-20,44
β_{12}	62,27	β_{46}	-30,09
β_{13}	17,09	β_{47}	44,38
β_{14}	-30,44	β_{48}	-17,83

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahriman

Parameter	Estimasi	Parameter	Estimasi
β_{15}	17,01	β_{49}	111,43
β_{16}	-17,39	β_{50}	-183,47
β_{17}	78,80	β_{51}	5,77
β_{18}	-173,62	β_{52}	42,65
β_{19}	239,11	β_{53}	-22,60
β_{20}	-63,28	β_{54}	45,78
β_{21}	-13,42	β_{55}	-13,16
β_{22}	3,71	β_{56}	5,84
β_{23}	-6,96	β_{57}	-94,12
β_{24}	22,28	β_{58}	90,54
β_{25}	106,61	β_{59}	50,49
β_{26}	-94,16	β_{60}	-14,20
β_{27}	29,38	β_{61}	-4,99
β_{28}	-16,69	β_{62}	-50,13
β_{29}	26,01	β_{63}	47,14
β_{30}	-0,99	β_{64}	3,56
β_{31}	-10,88	β_{65}	343,44
β_{32}	23,17	β_{66}	-346,88
β_{33}	-139,03	β_{67}	-551,17

4.6 Validasi Model

Hasil peramalan curah hujan menggunakan model LRMM dibandingkan dengan data curah hujan yang berasal dari BMKG untuk Kabupaten Pangkep untuk periode Januari 2022 – Juli 2023. Perbandingan hasil peramalan curah hujan dilakukan menggunakan nilai RMSE, R^2 dan nilai korelasi antar hasil peramalan curah hujan dan nilai aktualnya.



Gambar 4. Plot perbandingan hasil ramalan curah hujan menggunakan LRMM dan data curah hujan yang berasal dari BMKG periode Januari 2022 – Juli 2023


Berdasarkan hasil yang diperoleh pada gambar 4, plot perbandingan peramalan curah hujan menggunakan model LRMM dengan data curah hujan yang berasal dari BMKG, didapatkan hasil bahwa seiring pertambahan periode, model semakin baik dalam meramalkan curah hujan dan

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahriman

memiliki hasil yang mendekati nilai curah hujan lokal karena memiliki nilai korelasi sebesar 0,94. Prediksi data curah hujan yang akurat dan memiliki kesalahan yang relatif kecil juga diperlihatkan dengan nilai RMSE sebesar 97,26. Selain itu, nilai koefisien determinasi yang diperoleh sebesar 86,57% mengartikan bahwa data prediksi model LRMM dapat menjelaskan pola curah hujan aktual dengan baik. Berdasarkan hasil LRMM dengan penggunaan metode LRR tanpa menggunakan *Robust MM-Estimator* oleh Sahriman dkk. (2024), dapat diperoleh bahwa model LRMM dapat bekerja lebih baik dalam melakukan prediksi data curah hujan Kabupaten Pangkep yang mengalami masalah multikolinearitas dan *outlier* secara bersamaan.

Peramalan curah hujan dilakukan menggunakan model *Linearized ridge MM-Estimator* untuk Kabupaten Pangkep untuk periode Januari – Desember 2023 yang divisualisasikan dalam Gambar 5. Berdasarkan hasil yang dipaparkan pada Gambar 5 dan Tabel 6, hasil peramalan untuk Januari – Desember 2023 menunjukkan bahwa curah hujan di Kabupaten Pangkep bahwa pada bulan Januari – April dan bulan Oktober – Desember cenderung memiliki curah hujan yang tinggi sedangkan pada bulan Mei – September cenderung memiliki curah hujan yang relatif rendah dengan bulan dengan curah hujan paling rendah berada pada bulan September.



Gambar 5. Plot hasil ramalan menggunakan LRMM periode Januari - Desember 2023

Tabel 6. Hasil Prediksi Ramalan Curah Hujan Januari – Desember 2023

Bulan	Ramalan Curah Hujan (mm/bulan)
Januari	968,32
Februari	797,23
Maret	348,31
April	326,32
Mei	113,91
Jun	79,77
Juli	46,38
Agustus	162,06
September	9,72
Oktober	312,72
November	422,14
Desember	748,58

5. KESIMPULAN

Peramalan curah hujan menggunakan model LRMM dengan data curah hujan yang berasal dari BMKG memiliki nilai korelasi sebesar 0,94 terhadap data curah hujan aktualnya. Besar nilai RMSE yang didapatkan adalah sebesar 97,26. Selain itu, nilai koefisien determinasi yang didapatkan sebesar 86,57%. Hal ini berarti bahwa hasil ramalan curah hujan menggunakan *Linearized Ridge MM-Estimator* masuk dalam kategori cukup presisi dan dapat memprediksi curah hujan di Kabupaten Pangkep dengan baik. Berdasarkan hasil peramalan untuk Januari – Desember 2023 menunjukkan bahwa curah hujan tertinggi di Kabupaten Pangkep berada pada bulan Januari dan curah hujan terendah berada pada bulan September.

DAFTAR PUSTAKA

- [1] Adam, M., Sahrman, S., & Sirajang, N., 2023. Penerapan Metode Linearized Ridge Regression pada Data yang Mengandung Multikolinearitas. *ESTIMASI: Journal of Statistics and Its Application*, 4(1), 122–129.
- [2] Araya-Osses, D., Casanueva, A., Román-Figueroa, C., Uribe, J. M., & Paneque, M., 2020. Climate change projections of temperature and precipitation in Chile based on statistical downscaling. *Climate Dynamics*, 54(9–10), 4309–4330. <https://doi.org/10.1007/s00382-020-05231-4>
- [3] Asyeifa, V. R., 2017. Pemodelan Statistical Downscaling dengan Projection Pursuit Regression untuk Meramalkan Curah Hujan Bulanan di Sentra Produksi Padi Jawa Timur. Institut Teknologi Sepuluh Npember.
- [4] Atamia, N. A., Susanti, Y., & Handajani, S. S., 2021. PRISMA, Prosiding Seminar Nasional Matematika Perbandingan Analisis Regresi Robust Estimasi-S dan Estimasi-M dengan Pembobot Huber dalam Mengatasi Outlier. *Prosiding Seminar Nasional Matematika*, 4, 673–679. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [5] Gajbhiye, S., Meshram, C., Singh, S. K., Srivastava, P. K., & Islam, T., 2016. Precipitation trend analysis of Sindh River basin, India, from 102-year record (1901–2002). *Atmospheric Science Letters*, 17(1), 71–77. <https://doi.org/10.1002/asl.602>
- [6] Huber, P. J., 1973. Robust Regression: Asymptotics, Conjectures And Monte Carlo. *The Annals of Statistics*, 1(5), 799–821.
- [7] Jadhav, N. H., 2020. On linearized ridge logistic estimator in the presence of multicollinearity. *Computational Statistics*, 35(2), 667–687. <https://doi.org/10.1007/s00180-019-00935-6>
- [8] Liu, X.-Q., & Gao, F., 2011. Linearized Ridge Regression Estimator in Linear Regression. *Communications in Statistics - Theory and Methods*, 40(12), 2182–2192. <https://doi.org/10.1080/03610921003746693>
- [9] Mardiana., 2019. Perbandingan Model Regresi Robust Estimasi M, Estimasi S Dan Estimasi MM Pada Faktor Yang Mempengaruhi Angka Kejadian Demam Berdarah Dengue Di Provinsi Jawa Timur Tahun 2017. Universitas Airlangga.
- [10] Nugroho, B. D. A. (2021). Penerapan Klimatologi dalam Pertanian 4.0. Deepublish.

- [11] Özkale, M. R., & Nyquist, H., 2021. The stochastic restricted ridge estimator in generalized linear models. *Statistical Papers*, 62(3), 1421–1460. <https://doi.org/10.1007/s00362-019-01142-7>
- [12] Pangestu, B. A. W., & Purhadi, P., 2020. Pemodelan Faktor-faktor yang Mempengaruhi Angka Kematian Bayi dan Angka Kematian Ibu di Provinsi Jawa Timur Tahun 2017 dan Tahun 2018 Menggunakan Bivariate Gamma Regression. *Inferensi*, 3(2), 89. <https://doi.org/10.12962/j27213862.v3i2.7363>
- [13] Paramita, R. M., & Mukono, J., 2018. Hubungan Kelembapan Udara Dan Curah Hujan dengan Kejadian Demam Berdarah Dengue Di Puskesmas Gunung Anyar 2010-2016. *The Indonesian Journal of Public Health*, 12(2), 202. <https://doi.org/10.20473/ijph.v12i2.2017.202-212>
- [14] Rahayu, D. A., Nursholihah, U. F., Suryaputra, G., & Surono, S., 2023. Comparasion of The M, MM and S Estimator in Robust Regression Analysis on Indonesian Literacy Index Data 2018. *EKSAKTA: Journal of Sciences and Data Analysis*, 11–22. <https://doi.org/10.20885/eksakta.vol4.iss1.art2>
- [15] Ruslana, Z. N., Tresnawati, R., Rosyidah, R., Harmoko, I. W., & Siswanto, S. (2021). Reliabilitas Prediksi Curah Hujan Dasarian Pada Kejadian Curah Hujan Ekstrim Pemicu Banjir 26 Oktober 2020 di Kebumen: Model Statistik (HyBMG) versus Model Dinamik (ECMWF). *Jurnal Geosains dan Teknologi*, 4(2), 83–100. <https://doi.org/10.14710/jgt.4.2.2021.83-100>
- [16] Sahrman, S., Randa, E. L., Surianda, S. A., Hisyam, M. Z. G., Taufik, Muh. I., & Putra, G. D., 2024. Rainfall Forecasting Of Salt Producing Areas In Pangkep Regency Using Statistical Downscaling Model With Linearized Ridge Regression Dummy. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 18(1), 0483–0492. <https://doi.org/10.30598/barekengvol18iss1pp0483-0492>
- [17] Sahrman, S., & Yulianti, A. S., 2023. Statistical Downscaling Model With Principal Component Regression And Latent Root Regression To Forecast Rainfall In Pangkep Regency. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(1), 0401–0410. <https://doi.org/10.30598/barekengvol17iss1pp0401-0410>
- [18] Saputra, M. D., Hadi, A. F., Riski, A., & Anggraeni, D., 2021. Principal Component Regression in Statistical Downscaling with Missing Value for Daily Rainfall Forecasting. *International Journal of Quantitative Research and Modeling*, 2(3), 139–146. <https://doi.org/10.46336/ijqrm.v2i3.151>
- [19] Setiawan, W., Nessyana Debatara, N., & Sulistianingsih, E., 2019. Metode Estimasi-S Pada Analisis Regresi Robust Dengan Pembobotan. *Tukey Bisquare* (Vol. 08, Nomor 2).
- [20] Shodiqin, A., Aini, A. N., & Rubowo, M. R., 2018. Perbandingan Dua Metode Regresi Robust Yakni Metode *Least Trimmed Squares* (LTS) dengan Metode Estimator-MM (ESTMASI-MM) (Studi Kasus Data Ujian Tulis Masuk Terhadap Hasil Ipk Mahasiswa Upgris). *Jurnal Ilmiah Teknosains*, 4(1).
- [21] Susanti, Y., Pratiwi, H., Sulistijowati, H., & Liana, T., 2014. M Estimation, s estimation, and mm estimation in robust regression. *International Journal of Pure and Applied Mathematics*, 3, 349–360. <https://doi.org/10.12732/ijpam.v9i13.7>
- [22] Upa, D. S., Sahrman, S., & Thamrin, S. A., 2021. Pemodelan Statistical Downscaling dengan Regresi Modifikasi Jackknife Ridge Dummy Berbasis K-means untuk Pendugaan Curah Hujan.

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
M. Zaky Hisyam Gozhi, Muh. Ikbal Taufik, Siswanto Siswanto, Anisa Kalondeng, Sitti Sahrman

ESTIMASI: Journal of Statistics and Its Application, 2(1), 19–28.
<https://doi.org/10.20956/ejsa.v2i1.11189>

- [23] Wigena, A. H., Djuraidah, A., & Sahrman, S., 2015. Statistical Downscaling Dengan Pergeseran Waktu Berdasarkan Korelasi Silang. *Jurnal Meteorologi dan Geofisika*, 16(1), 19–24. <https://doi.org/10.31172/jmg.v16i1.259>
- [24] Yangfan, L., Bian, C., & Chen, H., 2023. Generalized Ridge Regression-Based Channelwise Feature Map Weighted Reconstruction Network for Fine-Grained Few-Shot Ship Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1–10. <https://doi.org/10.1109/TGRS.2023.3235747>