

Perbaikan Estimasi Hujan Multisatelit Berbasis *Google Earth Engine* dengan Data Penakar Hujan di Sulawesi Selatan

Improvement of Google Earth Engine-Based Multi-satellite Rainfall Estimation using Rain Gauge Data in South Sulawesi

Prayoga Ismail^{1, 2*}, Retnadi Heru Jatmiko³, Nur Mohammad Farda³, Muhammad Arif Munandar⁴

¹Program Magister Penginderaan Jauh, Fakultas Geografi, Universitas Gadjah Mada, Yogyakarta, Indonesia 55281

²Stasiun Meteorologi Sultan Hasanuddin, Maros, Sulawesi Selatan, Indonesia 90552

³Departemen Sains Informasi Geografis, Fakultas Geografi, Universitas Gadjah Mada, Yogyakarta, Indonesia 55281

⁴Direktorat Meteorologi Penerbangan, BMKG, Jakarta Pusat, Indonesia 10610

Email: *yogamailforalvin@gmail.com; retnadih@ugm.ac.id; farda@ugm.ac.id; arif.meteorologi@gmail.com

Received: 06th December 2024; Revised: 26th December 2024; Accepted: 10th January 2025

Abstrak – Presipitasi, khususnya hujan, memiliki peran penting dalam memahami cuaca dan iklim. Di Indonesia, distribusi pengamatan curah hujan in situ yang tidak merata menjadi kendala dalam pengukuran curah hujan. Sistem penginderaan jauh dan teknologi komputasi awan, seperti *Google Earth Engine* (GEE), dapat menjadi solusi. Penelitian ini mengevaluasi distribusi spasial dan performa dari empat estimasi hujan multisatelit di GEE yaitu CHIRPS, GSMAP, GPM-IMERG, dan PERSIANN-CDR sebelum dan sesudah kalibrasi menggunakan data penakar hujan BMKG di Sulawesi Selatan pada periode 2018-2023. Data multisatelit original menunjukkan perbedaan signifikan dengan RMSE tahunan mencapai 1534 mm/tahun, RSQ tahunan 0,3, dan RBIAS tahunan sebesar 27% dibandingkan observasi, dengan O_CHPS memiliki kesamaan spasial terbaik secara visual. Kalibrasi dengan metode *Geographical Differential Analysis* (GDA) berhasil meningkatkan akurasi berupa menurunkan RMSE tahunan menjadi 807 mm/tahun, meningkatkan RSQ pada skala tahunan menjadi 0,5, dan mengurangi bias tahunan menjadi 1,6%. Perbaikan performa ini juga terjadi pada estimasi hujan bulanan dan harian. Setelah kalibrasi, C_PRSN memberikan distribusi spasial dan performa terbaik, dengan penurunan RMSE tahunan mencapai 26%, peningkatan RSQ tahunan sebesar 105%, dan penurunan bias tahunan sebesar 101% dari data original-nya. Sensitivitas terhadap elevasi dan intensitas hujan juga diperbaiki, dengan perbaikan indikator deteksi khususnya untuk hujan lebat-ekstrem, yaitu peningkatan POD sebesar 43% dan CSI 262%, serta penurunan FAR sebesar 42%.

Kata kunci: Hujan; multisatelit; kalibrasi; *Google Earth Engine*; akurasi.

Abstract – Precipitation, particularly rainfall, is vital in understanding weather and climate. In Indonesia, the uneven distribution of in situ rainfall observations poses a challenge to accurately measuring surface rainfall. Remote sensing systems and cloud computing technologies, such as *Google Earth Engine* (GEE), offer potential solutions. This study evaluates the spatial distribution and performance of four multi-satellite rainfall estimates available in GEE, namely CHIRPS, GSMAP, GPM-IMERG, and PERSIANN-CDR, before and after calibration using BMKG rain gauge data in South Sulawesi during the 2018–2023 period. The original multi-satellite data revealed significant discrepancies, with an annual RMSE of 1534 mm/year, a yearly RSQ value of 0.3, and an annual RBIAS of 27% compared to observational data. Among the datasets, O_CHPS demonstrated the best spatial similarity visually. Calibration using the *Geographical Differential Analysis* (GDA) method effectively enhanced the accuracy, reducing the annual RMSE to 807 mm/year, increasing the yearly RSQ to 0.5, and lowering the annual bias to 1.6%. Improvements were also noted in monthly and daily rainfall estimates. After calibration, C_PRSN exhibited the most favorable spatial distribution and performance, achieving a 26% reduction in annual RMSE, a 105% increase in annual RSQ, and a 101% decrease in annual bias compared to its initial data. Furthermore, sensitivity to elevation and rainfall intensity was enhanced, with

improved detection indicators, particularly for heavy to extreme rainfall events. This included a 43% increase in POD, a 262% increase in CSI, and a 42% reduction in FAR.

Keywords: Rainfall; multi-satellite; calibration; Google Earth Engine; accuracy.

1. Pendahuluan

Hujan dalam konteks meteorologi adalah proses turunnya presipitasi dari atmosfer ke permukaan bumi dalam bentuk tetesan air dengan diameter butiran lebih dari atau sama dengan 0,5 mm [1]. Sebagai salah satu unsur dalam siklus hidrologi, hujan penting untuk memahami karakteristik iklim di suatu wilayah [2]. Namun, distribusi pengamatan curah hujan *in situ* di Indonesia belum merata dan masih terbatas. Topografi Indonesia dan statusnya sebagai negara kepulauan, di mana 70% wilayahnya adalah lautan, turut berkontribusi pada kondisi ini [3]. Pemanfaatan data dari sumber lain dapat menjadi alternatif untuk memperoleh data secara spasial dan temporal guna mengidentifikasi karakteristik curah hujan permukaan. Salah satu sumber data tersebut adalah sistem penginderaan jauh, yang mampu menyediakan informasi berharga terutama untuk area yang sulit atau tidak dapat dijangkau oleh manusia, di mana pengukuran curah hujan dengan alat penakar hujan secara *in situ* hampir tidak mungkin dilakukan [4].

Produk estimasi curah hujan berbasis satelit memiliki potensi untuk memenuhi ketersediaan data curah hujan secara spasial dan temporal. Namun, pengolahan sejumlah besar data satelit dalam jangka waktu yang lama membutuhkan sistem penyimpanan, pemrosesan, dan pasca-pemrosesan komputasi yang ekstensif. Adanya teknologi komputasi awan *Google Earth Engine* (GEE), memungkinkan pengguna menyimpan sejumlah besar data dan memprosesnya di server tanpa perlu mengunduh data mentah terlebih dahulu. Keunggulan ini membuat pemrosesan data satelit di GEE lebih efisien.

Peneliti telah melakukan beberapa studi untuk menguji akurasi data estimasi curah hujan satelit, baik dari satu satelit atau beberapa satelit. Diantaranya ada satelit *The Global Precipitation Measurement Mission* (GPM) yang diuji kesesuaiannya di China yang memiliki performa bervariasi terhadap skala waktu, intensitas hujan, dan ketinggian [5]. Kemudian, beberapa produk presipitasi dari satelit telah dievaluasi kinerjanya di Meksiko dan mendapati bahwa performa produk presipitasi umumnya menurun pada skala harian dan di wilayah dengan elevasi tinggi atau topografi kompleks [6]. Di India, estimasi hujan berbasis satelit yang tersedia di GEE dikaji dan diidentifikasi sumber ketidakpastian datanya diantaranya dari landasan konseptual dan pendekatan, spesifikasi algoritma dan sensor, serta sumber data masukan yang digunakan [7]. Di Indonesia, satelit *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks-Climate Data Record* (PERSIANN-CDR) dan *Tropical Rainfall Measuring Mission* (TRMM) 3B42 dibandingkan dengan data hujan terukur di Sumba Barat, hasilnya data hujan satelit bulanan berkorelasi tinggi dengan data hujan terukur, tetapi untuk hujan harian korelasi sangat rendah [8]. Data satelit *Climate Hazards Center InfraRed Precipitation with Station Data* (CHIRPS), *Global Satellite Mapping of Precipitation* (GSMaP), dan *Integrated Multi-satellite Retrievals for GPM* (IMERG) dibandingkan dengan data *Automatic Weather Station* (AWS) di Lampung Selatan, dengan hasil estimasi hujan satelit masih memiliki bias dan *root mean square error* (RMSE) cukup tinggi, terutama pada hujan harian. Guna meningkatkan akurasi estimasi curah hujan dari data multisatelit, peneliti mengintegrasikan data satelit dengan sumber data lain seperti data penakar hujan. Data satelit *TRMM Multi-satellite Precipitation Analysis* (TMPA) digabungkan dengan data pengamatan lapangan dengan membandingkan 2 metode, dimana metode *Geographical Differential Analysis* (GDA) lebih unggul [9]. Data satelit IMERG yang telah dikoreksi dengan data hujan pengamatan menggunakan teknik GDA menghasilkan simulasi hidrologi yang lebih andal [10]. Kemudian, data satelit TRMM yang telah dikoreksi menggunakan data observasi memiliki korelasi lebih tinggi dan nilai kesalahan lebih rendah dibanding data aslinya [11].

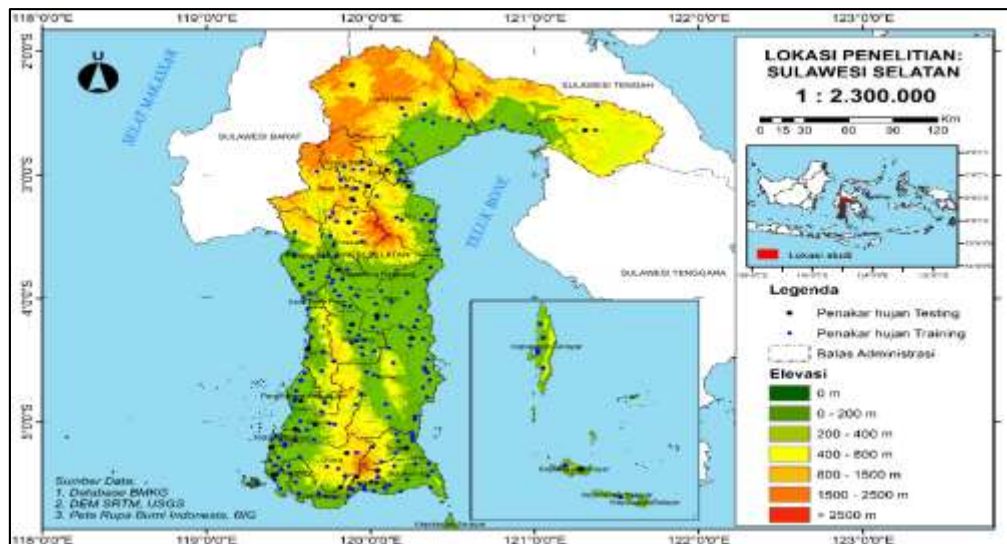
Selain itu, perbaikan data hujan satelit menggunakan variabel prediktor seperti indeks vegetasi, elevasi, dan penggunaan lahan mendapati bahwa variabel tersebut berpengaruh untuk *downscaling* data hujan satelit [12]. Penggabungan *downscaling* untuk memperhitungkan variabel prediktor dan proses kalibrasi mampu menghasilkan data hujan berbasis satelit yang beresolusi spasial tinggi dan lebih andal [13-15]. Metode evaluasi mencakup metrik statistik dan indikator deteksi memiliki kesamaan dengan beberapa studi yang telah ada. Namun, belum ada studi yang secara khusus meneliti kinerja empat estimasi

curah hujan multisatelit berbasis GEE terhadap data penakar hujan dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) di wilayah Sulawesi Selatan. Pemilihan data satelit di GEE berdasarkan pada ketersediaan untuk mengevaluasi kinerja satelit pada skala temporal harian, bulanan, dan tahunan selama periode 2018-2023. Penggunaan data terbaru membuat penelitian ini relevan dengan kondisi saat ini. Lokasi penelitian yang dipilih juga memiliki karakteristik cuaca multiskala dan area yang kompleks, sehingga menarik untuk dipelajari. Untuk memperbaiki estimasi hujan multisatelit, studi ini menerapkan kalibrasi dengan GDA. Kalibrasi GDA direkomendasikan sebagai metode yang meningkatkan akurasi spasial dan temporal satelit TRMM [9]. Metode ini juga menunjukkan efektivitasnya dalam mengoreksi data satelit IMERG [10].

Studi ini memiliki tujuan diantaranya. 1) Mengevaluasi distribusi spasial estimasi hujan multisatelit di wilayah Sulawesi Selatan selama 2018-2023 pada berbagai skala waktu (harian, bulanan, dan tahunan) sebelum dan sesudah kalibrasi. 2) Mengevaluasi performa estimasi hujan multisatelit terhadap data hujan observasi sebelum dan sesudah kalibrasi dengan menganalisis (a) metrik evaluasi statistik pada berbagai skala waktu dan elevasi, dan (b) indikator deteksi pada berbagai intensitas curah hujan.

2. Metode

Seperti yang ditampilkan pada Gambar 1, penelitian ini berfokus pada wilayah Sulawesi Selatan. Provinsi ini terletak di Pulau Sulawesi dan berbatasan dengan Laut Flores di selatan, Selat Makassar di barat, Sulawesi Barat dan Sulawesi Tengah di utara, serta Sulawesi Tenggara dan Teluk Bone di timur. Topografi Sulawesi Selatan yang beragam, meliputi *area* pesisir, dataran, perbukitan, hingga pegunungan, membuat lokasi ini menarik untuk dikaji. Tabel 1 menyajikan data/*material* yang digunakan, sedangkan Gambar 2 menunjukkan diagram alir penelitian.



Gambar 1. Peta lokasi penelitian yaitu Provinsi Sulawesi Selatan.

Penelitian dimulai dari pengumpulan data berupa data estimasi hujan multisatelit, data hujan observasi (*in situ*), data peta dasar (batas administrasi wilayah), serta data *digital elevation model* (DEM), yang kemudian diolah menggunakan GEE. Skala temporal kajian ditentukan pada tingkat harian, bulanan, dan tahunan untuk pengolahan akumulasi curah hujan dari data observasi, yang juga melalui proses interpolasi untuk menghasilkan peta curah hujan wilayah studi. Data hujan satelit diolah untuk menghasilkan peta estimasi curah hujan multisatelit *original*, yang diekstraksi di lokasi pos hujan observasi. Proses kalibrasi dilakukan pada data multisatelit menggunakan data hujan observasi, menghasilkan peta estimasi hujan multisatelit terkalibrasi, yang juga diekstraksi ulang di lokasi pos hujan. Untuk menjawab tujuan pertama, dilakukan analisis spasial peta estimasi hujan (*original* dan terkalibrasi) terhadap data observasi, serta evaluasi performa masing-masing data. Untuk menjawab tujuan kedua, dilakukan analisis metrik statistik (seperti RMSE, *R-squared*/ RSQ, dan *relative bias*/ RBIAS), serta indikator deteksi (*probability of detection*/ POD,

Tabel 1. Data/materials yang digunakan pada penelitian ini.

No	Data	Sumber/ Penyedia	Resolusi/ skala
1	CHIRPS Daily v2 (CHPS)	GEE Repository, UCSB/CHG [16]	Res. spasial 0,05x0,05 derajat, Res. temporal harian
2	GPM-IMERG v7 (GPMI)	GEE Repository, NASA DISC [17]	Res. spasial 0,1x0,1 derajat, Res. temporal 30 menit
3	GSMAP Operational v8 (GSMP)	GEE Repository, JAXA EORC [18]	Res. spasial 0,1x0,1 derajat, Res. temporal 1 jam
4	PERSIANN-CDR (PRSN)	GEE Repository, NOAA NCDC [19]	Res. spasial 0,25x0,25 derajat, Res. temporal harian
5	Data penakar hujan <i>in situ</i> (OBS)	BMKG [20]	224 titik pos hujan, Res. temporal harian
6	Batas administrasi wilayah	Peta Rupa Bumi Indonesia, BIG [21]	Skala 1:50.000
7	Data DEM SRTM	USGS [22]	Res. spasial 30 meter



Gambar 2. Diagram alir penelitian.

false alarm ratio/FAR, dan *critical success index*/CSI). Penelitian ini membagi data observasi menjadi sebanyak 89% untuk kalibrasi dan 11% untuk pengujian performa. Penelitian ini menggunakan metode kalibrasi GDA, yang memiliki proses perhitungan sederhana [10, 16]. Metode GDA yang digunakan untuk setiap multisatelit meliputi tahapan (a) menghitung selisih antara curah hujan yang dicatat oleh setiap penakar hujan observasi dan piksel satelit yang sesuai, (b) menerapkan interpolasi spasial pada data selisih curah hujan melalui teknik *Inverse Distance Weighting* (IDW) untuk membuat peta *residual*, dan (c) melakukan penyesuaian estimasi curah hujan satelit berdasarkan peta *residual* yang dihasilkan. Hasil penelitian memberikan kesimpulan mengenai perbaikan akurasi estimasi hujan dari data multisatelit serta rekomendasi data terbaik untuk wilayah studi.

3. Hasil dan Pembahasan

3.1 Distribusi spasial curah hujan

Distribusi hujan tahunan dari data observasi (OBS) menunjukkan sebagian besar berada pada rentang 2000-3000 mm/tahun, intensitas tinggi (3000-5000 mm/tahun) di bagian utara dan barat daya, hal ini terlihat pada Gambar 3 yang merupakan hasil pengolahan akumulasi hujan tahunan rata-rata. Topografi dan angin muson berperan penting dalam distribusi spasial curah hujan di wilayah ini [23], di mana lereng pegunungan bagian barat lebih cenderung menerima curah hujan tahunan lebih tinggi. Dari empat multisatelit *original*, *original CHIRPS* (O_CHPS) paling mendekati OBS meskipun *overestimate* di utara, diikuti *original PERSIANN-CDR* (O_PRSN) yang cenderung *underestimate* di seluruh wilayah. *Original GSMAP* (O_GSMP) *overestimate* di timur, sedangkan *original GPM-IMERG* (O_GPMI) menunjukkan *overestimate* tertinggi di hampir seluruh wilayah. Data multisatelit terkalibrasi menunjukkan hasil yang lebih akurat, dengan *calibrated PERSIANN-CDR* (C_PRSN) menjadi yang paling mendekati OBS.

Berdasarkan analisis distribusi hujan bulanan, terungkap bahwa di Sulawesi Selatan terjadi pergeseran wilayah curah hujan tinggi setiap bulannya dari sisi barat menuju timur, mulai Januari hingga Desember. Wilayah utara dan barat selalu memiliki curah hujan lebih tinggi sepanjang tahun, sementara wilayah tengah, selatan, dan timur cenderung menerima curah hujan lebih rendah, terutama selama musim kemarau. Data multisatelit *original* dan terkalibrasi menunjukkan variasi terhadap data OBS. Secara umum dari multisatelit *original*, O_CHPS paling sering mencerminkan distribusi hujan yang mendekati OBS. Sedangkan, pada multisatelit terkalibrasi, C_PRSN konsisten menunjukkan hasil yang paling mendekati OBS.

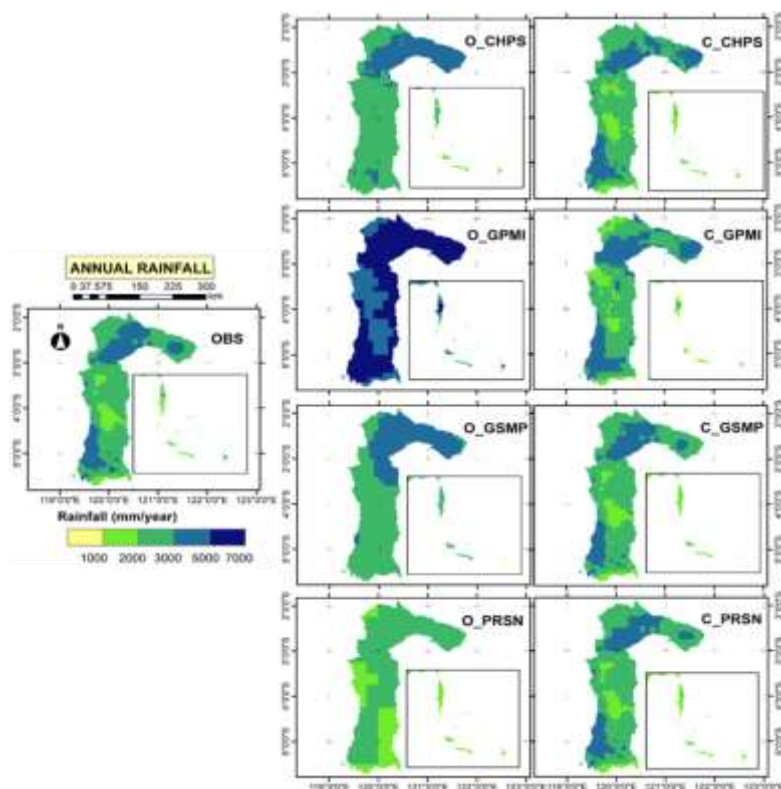
Analisis distribusi hujan harian memiliki kemiripan dengan pola hujan bulanan. Pada kejadian hujan harian, dari multisatelit *original* terlihat bahwa O_CHPS dan O_GPMI cukup mendekati dengan distribusi spasial hujan dari data OBS, sementara O_PRSN dan O_GSMP menunjukkan *underestimate* yang cukup signifikan. Pada multisatelit terkalibrasi, semua menunjukkan perbaikan distribusi yang lebih akurat dibandingkan versi *original*, dengan C_PRSN konsisten menunjukkan pola yang paling mendekati OBS.

Secara keseluruhan, O_CHPS dan C_PRSN adalah multisatelit yang paling konsisten dalam mencerminkan distribusi curah hujan di Sulawesi Selatan, baik secara tahunan, bulanan, maupun harian.


3.2 Performa estimasi hujan multisatelit

3.2.1 Metrik statistik pada berbagai skala waktu

Gambar 4 menampilkan evaluasi metrik statistik dari multisatelit pada skala waktu tahunan. Setiap satelit menunjukkan keunggulan berbeda pada masing-masing metrik. Untuk RMSE, yang mengukur kesalahan absolut antara estimasi multisatelit dan data observasi dalam satuan mm/tahun, CHPS menonjol dengan nilai terendah (969 mm/tahun) pada versi *original* dan turun menjadi 781 mm/tahun setelah kalibrasi, sehingga menunjukkan akurasi yang cukup konsisten. Sementara itu, pada metrik RSQ, O_GPMI mencatatkan nilai tertinggi pada versi *original* yaitu 0,4, sedangkan *calibrated CHIRPS* (C_CHPS) memiliki nilai RSQ tertinggi setelah kalibrasi yaitu 0,51. Hal ini menunjukkan CHPS paling mampu merepresentasikan variasi data aktual. Pada metrik RBIAS, CHPS kembali tampil unggul dengan bias terendah, yakni 7,3% pada versi *original* dan berhasil mencapai hampir nol (-0,04%) setelah kalibrasi, menandakan bahwa estimasinya semakin mendekati data observasi. Proses kalibrasi juga membawa perbaikan yang signifikan pada bias GPMI. Secara keseluruhan pada hujan tahunan, CHPS berhasil mengurangi kesalahan dan bias, serta menunjukkan kecocokan estimasi hujan terbaik setelah kalibrasi.




Gambar 3. Distribusi spasial hujan tahunan rata-rata 2018-2023 dari data observasi, multisatelit *original* dan multisatelit terkalibrasi.




Gambar 4. RMSE, RSQ, dan RBIAS tahunan dari multisatelit *original* dan terkalibrasi.

Gambar 5 menunjukkan metrik statistik estimasi hujan multisatelit pada skala waktu bulanan. Metrik RMSE menunjukkan kesalahan absolut antara estimasi dan observasi dalam mm/bulan. Pada musim hujan, nilai RMSE cenderung lebih tinggi dibandingkan musim kemarau, baik pada multisatelit *original* maupun terkalibrasi. O_CHPS memiliki RMSE terendah pada data *original* (155 mm/bulan), sementara O_GPMI mencatat RMSE tertinggi (283 mm/bulan). Setelah kalibrasi, C_GPMI mencatat RMSE terendah (122 mm/bulan), sedangkan C_CHPS tertinggi (125 mm/bulan). Metrik RSQ mengukur kemampuan estimasi hujan multisatelit merepresentasikan variasi observasi. Pada multisatelit *original*, O_GPMI memiliki RSQ tertinggi (0,51), sedangkan O_PRSN terendah (0,29). Setelah kalibrasi, C_GPMI menunjukkan peningkatan signifikan dengan RSQ tertinggi (0,65), sementara C_CHPS terendah (0,62). Metrik RBIAS menilai bias antara estimasi hujan multisatelit dan observasi. O_CHPS menunjukkan bias terendah pada data *original* (3,6%), sedangkan O_GPMI bias tertinggi (95,8%). Kalibrasi berhasil mengurangi bias, dengan C_CHPS mencapai bias terendah (0,07%), mendekati nilai observasi, sementara C_GSMP menunjukkan bias tertinggi (-1,14%). Kalibrasi secara keseluruhan meningkatkan akurasi estimasi multisatelit pada hujan bulanan.



Gambar 5. Heat map dari RMSE, RSQ, dan RBIAS bulanan dari multisatelit *original* dan terkalibrasi.



Gambar 6. Box and whiskers plot dari RMSE, RSQ, dan RBIAS harian dari multisatelit *original* dan terkalibrasi.


Gambar 6 menampilkan metrik statistik estimasi hujan multisatelit pada kejadian-kejadian hujan harian. Metrik RMSE mengukur kesalahan absolut dari estimasi hujan multisatelit terhadap hujan observasi. Pada multisatelit *original*, O_CHPS memperoleh RMSE terendah secara keseluruhan, dengan median sekitar 30 mm/hari. Sedangkan, C_GPMI menunjukkan RMSE tertinggi dengan median sekitar 51 mm/hari, menandakan estimasi yang paling tidak akurat. Pada multisatelit terkalibrasi, C_PRSN mencatat nilai RMSE terendah secara keseluruhan, dengan median 28 mm/hari. Sementara, C_GPMI menunjukkan RMSE tertinggi dengan median sekitar 34 mm/hari. Metrik RSQ mengukur kemampuan estimasi hujan multisatelit dalam merepresentasikan variasi data observasi harian. Multisatelit *original* menunjukkan kecocokan estimasi yang tergolong rendah, dengan O_GPMI lebih baik dari lainnya dan O_GSMP serta O_PRSN terburuk, masing-masing dengan median 0,19 dan 0,06 saja. Kalibrasi meningkatkan RSQ dari seluruh multisatelit. Pada multisatelit terkalibrasi, C_PRSN memperlihatkan RSQ yang unggul secara keseluruhan dengan median sekitar 0,43. Sementara, C_GPMI mengindikasikan RSQ dengan median terendah yaitu 0,3. Metrik RBIAS juga menunjukkan variasi dalam skala waktu harian. Pada multisatelit *original*, O_CHPS menunjukkan bias terkecil secara keseluruhan dengan median sekitar -2,3%. Sementara O_GPMI mencatatkan bias terbesar yaitu dengan median -111%, mencerminkan ketidakakuratan yang signifikan. Kalibrasi efektif dalam memperkecil bias semua multisatelit. Pada multisatelit terkalibrasi, C_PRSN memperoleh bias terkecil secara keseluruhan yaitu median 0,55%, menandakan semakin mendekati data observasi. Sementara, C_GSMP menunjukkan bias terbesar dengan median 4%. Hasil ini mengonfirmasi temuan yang menunjukkan bahwa kalibrasi dengan data penakar hujan secara substansial meningkatkan akurasi dan distribusi spasial dari estimasi hujan multisatelit [10].

3.2.2 Metrik statistik pada berbagai elevasi


Gambar 7 menunjukkan bahwa pada skala waktu bulanan, RMSE dari multisatelit *original* maupun multisatelit terkalibrasi menunjukkan tren yang meningkat seiring dengan meningkatnya elevasi, kecuali pada O_GPMI. Di sisi lain, koefisien determinasi (RSQ) pada multisatelit *original* cenderung menurun seiring dengan meningkatnya elevasi, kecuali pada O_PRSN. Sebaliknya, multisatelit terkalibrasi menunjukkan RSQ yang cenderung meningkat seiring meningkatnya elevasi. Sementara itu, bias relatif (RBIAS) cenderung meningkat seiring dengan bertambahnya elevasi pada semua multisatelit *original* maupun terkalibrasi, kecuali O_GPMI. Pada skala bulanan, O_PRSN memiliki RMSE terendah (64,5 mm/bulan) pada elevasi 0–200 m, sedangkan O_GPMI tertinggi (416 mm/bulan) di elevasi yang sama. Setelah kalibrasi, C_GPMI mencatat RMSE terendah

(51 mm/bulan, elevasi 400-600 m) dan tertinggi (238,6 mm/bulan, elevasi 0-200 m). O_GSMP menunjukkan RSQ tertinggi (0,94) dan terendah (0,002) di elevasi 0-200 m. Setelah kalibrasi, C_GPMI memiliki RSQ tertinggi (0,95, elevasi 0-200 m) dan terendah (0,17, elevasi sama). Dalam RBIAS, O_PRSN bias terkecil (-0,09%, elevasi 0-200 m) dan O_GPMI bias terbesar (216,5%, elevasi 0-200 m). Setelah kalibrasi, C_CHPS memiliki bias terkecil (-2,43%, elevasi 0-200 m), sedangkan C_GPMI bias terbesar (72,4%, elevasi 0-200 m).

Diagram tebar pada Gambar 8 menunjukkan bahwa pada skala waktu harian, multisatelit *original* maupun terkalibrasi sama-sama menunjukkan tren RMSE yang meningkat seiring dengan bertambahnya elevasi. Koefisien determinasi (RSQ) pada multisatelit *original* maupun terkalibrasi cenderung meningkat seiring bertambahnya elevasi. Sementara itu, multisatelit *original* O_GPMI dan O_GSMP mengindikasikan adanya tren menurun seiring bertambahnya elevasi pada bias relatif (RBIAS), sedangkan O_CHPS dan O_PRSN meningkat seiring bertambahnya elevasi. Namun, multisatelit terkalibrasi memperlihatkan tren bias relatif terhadap elevasi yang berkebalikan dengan multisatelit *original*. Pada skala harian, O_CHPS mencatat RMSE terendah (13,8 mm/hari, elevasi 0-200 m) dan O_PRSN tertinggi (86,9 mm/hari, elevasi 1000-1200 m). Setelah kalibrasi, C_CHPS memiliki RMSE terendah (10,1 mm/hari, elevasi 400-600 m) sekaligus tertinggi (61,7 mm/hari, elevasi 0-200 m). O_CHPS mencapai RSQ tertinggi (0,71, elevasi 0-200 m), sedangkan RSQ terendah (nol) terjadi di berbagai elevasi pada semua multisatelit. Setelah kalibrasi, C_CHPS mencatat RSQ tertinggi (0,89, elevasi 0-200 m). Dalam RBIAS, O_CHPS memiliki bias terkecil (-0,39%, elevasi 1000-1200 m) dan O_GPMI terbesar (316%, elevasi 0-200 m). Setelah kalibrasi, C_CHPS bias terkecil (0,01%, elevasi 0-200 m) dan C_PRSN bias terbesar (236%, 0-200 m).



Gambar 7. Diagram tebar dari Elevasi vs RMSE (kiri), Elevasi vs RSQ (tengah), dan Elevasi vs RBIAS (kanan) pada skala waktu bulanan dari multisatelit *original* dan terkalibrasi.



Gambar 8. Diagram tebar dari Elevasi vs RMSE (kiri), Elevasi vs RSQ (tengah), dan Elevasi vs RBIAS (kanan) pada skala waktu harian dari multisatelit *original* dan terkalibrasi.

3.2.3 Indikator deteksi pada berbagai intensitas hujan

Studi ini mengevaluasi indikator deteksi hujan harian dengan klasifikasi intensitas hujan berdasarkan kriteria BMKG yang ada di tabel 2, namun untuk hujan lebat hingga ekstrem kami gabung. Hasil analisis ini dapat diperhatikan pada Gambar 9.

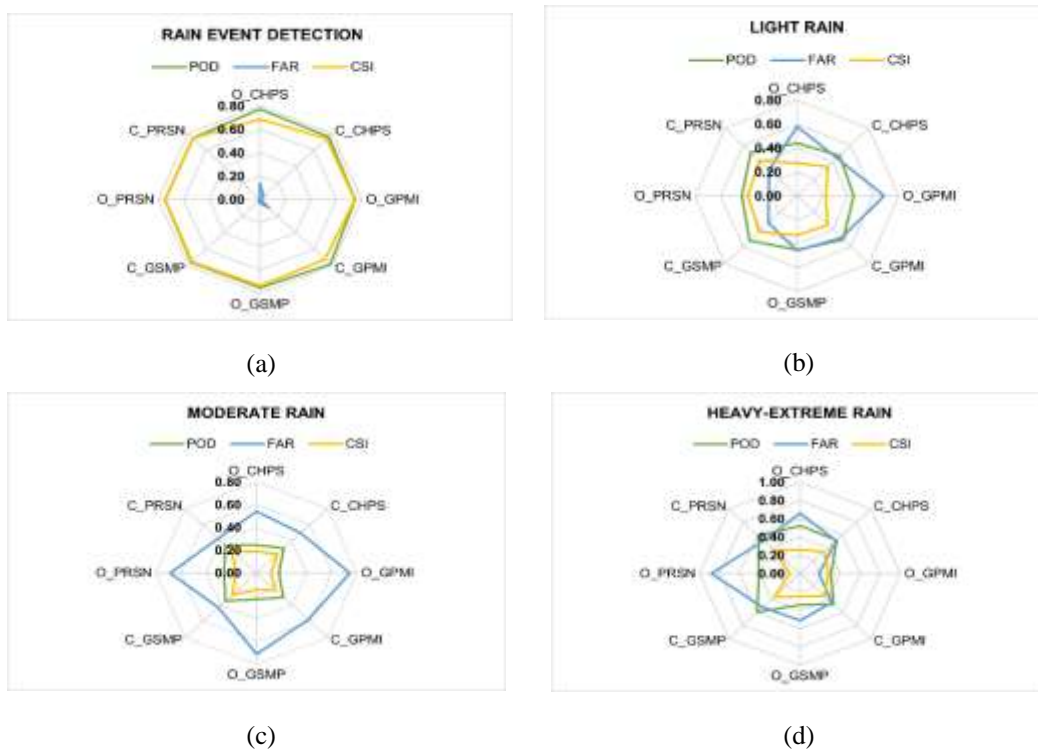
Tabel 2. Intensitas hujan harian menurut BMKG.

Kategori Hujan	Intensitas harian
Hujan ringan	0,5 – 20 mm/hari
Hujan sedang	20 – 50 mm/hari
Hujan lebat	50 – 100 mm/hari
Hujan sangat lebat	100 – 150 mm/hari
Hujan ekstrem	>150 mm/hari

Pada kejadian hujan ringan, multisatelit *original* menunjukkan performa terbaik melalui O_GSMP dengan POD 0,45, sementara C_GSMP mencatat POD tertinggi sebesar 0,53 setelah kalibrasi. Pada FAR, O_PRSN memiliki nilai terendah sebesar 0,22 di antara multisatelit *original*, sedangkan C_PRSN menunjukkan FAR terendah sebesar 0,31 setelah kalibrasi. Untuk CSI, O_PRSN mencatatkan nilai tertinggi 0,38 pada multisatelit *original*, dan C_GSMP mencapai 0,42 setelah kalibrasi.

Pada kejadian hujan sedang, O_PRSN meraih POD tertinggi sebesar 0,26 di antara multisatelit *original*, sementara C_PRSN dan C_GSMP menunjukkan peningkatan menjadi 0,35 setelah kalibrasi. Indikator FAR menunjukkan bahwa O_CHPS memiliki nilai terendah sebesar 0,54 di multisatelit *original*, sedangkan C_PRSN dan C_GSMP yang terendah setelah kalibrasi yaitu 0,43. CSI terbaik untuk hujan sedang dicapai oleh O_CHPS di multisatelit *original* dengan nilai 0,19, dan C_PRSN dan C_GSMP setelah kalibrasi dengan nilai 0,28.

Pada hujan lebat hingga ekstrem, O_CHPS mencatatkan POD tertinggi di multisatelit *original* (0,53), sementara C_GSMP mencapai POD tertinggi (0,6) setelah kalibrasi. O_GPMI menunjukkan FAR terendah (0,19) pada multisatelit *original*, sedangkan C_GPMI memiliki FAR terendah (0,48) setelah kalibrasi. Untuk CSI, O_GPMI mencatat nilai tertinggi (0,29) di multisatelit *original*, sementara C_GSMP mencapai CSI terbaik (0,36) setelah kalibrasi. Kalibrasi secara keseluruhan efektif meningkatkan akurasi deteksi, penurunan FAR dan peningkatan CSI, khususnya pada C_PRSN yang konsisten menunjukkan performa terbaik di berbagai intensitas hujan. Temuan ini sejalan dengan studi di China yang menemukan bahwa kalibrasi meningkatkan kemampuan deteksi hujan berbasis satelit pada berbagai intensitas hujan [10].



Gambar 9. Diagram radar menunjukkan performa indikator deteksi dari multisatelit *original* dan terkalibrasi pada (a) Deteksi kejadian hujan, (b) Hujan ringan, (c) Hujan sedang, dan (d) Hujan lebat-ekstrem.

4. Kesimpulan

Penelitian ini telah berhasil mengevaluasi performa empat estimasi hujan multisatelit (CHIRPS, GSMAP, GPM-IMERG, dan PERSIANN-CDR) di wilayah Sulawesi Selatan pada 2018-2023, baik sebelum maupun setelah kalibrasi. Metode kalibrasi GDA terbukti efektif meningkatkan akurasi estimasi hujan multisatelit, dengan memanfaatkan *platform* GEE untuk efisiensi pengelolaan data berskala besar. Hasil penelitian menunjukkan bahwa kalibrasi meningkatkan performa estimasi hujan pada berbagai skala waktu, serta di berbagai elevasi. Hal ini diindikasikan dari penurunan RMSE tahunan sebesar 47%, peningkatan RSQ tahunan 63%, dan penurunan RBIAS tahunan hingga 94%. Selain itu, multisatelit yang telah dikalibrasi lebih andal dalam mendeteksi hujan dengan berbagai intensitas, terutama pada kejadian hujan lebat-ekstrem yang diindikasikan dari peningkatan POD sebesar 38%, penurunan FAR 11%, dan peningkatan CSI hingga 56%. Dari keempat multisatelit, CHIRPS memiliki performa unggul sebelum kalibrasi, sedangkan PERSIANN-CDR menunjukkan performa terbaik setelah kalibrasi. Meskipun demikian, tantangan masih ditemukan pada prediksi hujan sedang hingga hujan ekstrem, terutama di wilayah dengan elevasi tinggi.

Ucapan Terima Kasih

Peneliti mengucapkan terima kasih kepada beasiswa LPDP atas bantuan pendanaan studi. Peneliti mengapresiasi *platform* GEE atas ketersediaan data multisatelit dalam *repository* sehingga penelitian ini lebih efisien. Ucapan terima kasih untuk BMKG atas ketersediaan data hujan observasi di wilayah Sulawesi Selatan, sehingga menunjang penelitian.

Pustaka

- [1] C. D. Ahrens and R. Henson, *Meteorology Today: An Introduction to Weather, Climate, and Environment*, 12th ed. Boston: Cengage Learning, 2019.
- [2] H. Chen, X. Yin, X. Huang, *et al.*, Climatic characteristics and main weather patterns of extreme precipitation in the middle Yangtze River valley, *Journal of Water and Climate Change*, vol. 15, no. 1, pp. 192–208, Jan. 2024, doi: 10.2166/wcc.2023.545.
- [3] I. Mutaqin Ali, L. P. Yudho, D. Sianturi, Strategi Pertahanan Laut dalam Pengamanan Alur Laut Kepulauan Indonesia untuk Mewujudkan Keamanan Maritim dan Mempertahankan Kedaulatan Indonesia, *Jurnal Education and Development*, vol. 10, no. 2, pp. 319–324, May 2022, Accessed: Dec. 24, 2024. [Online]. Available: <https://journal.ipts.ac.id/index.php/ED/article/view/3742>.
- [4] Q. Zeng, Y. Wang, L. Chen, *et al.*, Inter-Comparison and Evaluation of Remote Sensing Precipitation Products over China from 2005 to 2013, *Remote Sens (Basel)*, vol. 10, no. 2, p. 168, Jan. 2018, doi: 10.3390/rs10020168.
- [5] X. Pan, H. Wu, S. Chen, *et al.*, Evaluation and Applicability Analysis of GPM Satellite Precipitation over Mainland China, *Remote Sens.*, vol. 15, no. 11, Jun. 2023, doi: 10.3390/rs15112866.
- [6] P. Rincón-Avalos, A. Khouakhi, O. Mendoza-Cano, *et al.*, Evaluation of satellite precipitation products over Mexico using Google Earth Engine, *J. Hydroinform.*, vol. 24, no. 4, pp. 711–729, Jul. 2022, doi: 10.2166/hydro.2022.122.
- [7] S. Dubey, H. Gupta, M. K. Goyal, *et al.*, Evaluation of precipitation datasets available on Google earth engine over India, *Int. J. Climatol.*, vol. 41, no. 10, pp. 4844–4863, Aug. 2021, doi: 10.1002/joc.7102.
- [8] A. H. Pattiraja, Analisis Hubungan Data Hujan Satelit PERSIANN-CDR & TRMM 3B42 dengan Data Hujan BMKG pada Stasiun Hujan di Wilayah Sumba Barat, *Jurnal Kacapuri: Jurnal Keilmuan Teknik Sipil*, vol. 6, no. 1, p. 128, Jul. 2023, doi: 10.31602/jk.v6i1.11692.
- [9] Z. Shen and H. Wu, A comparative analysis of merging strategies for satellite precipitation estimates and ground observations over Chinese mainland, *J. Atmos. Sol-terr. Phys.*, vol. 246, May 2023, doi: 10.1016/j.jastp.2023.106072.

- [10] C. Mo, M. Zhang, Y. Ruan, *et al.*, Accuracy analysis of IMERG satellite rainfall data and its application in long-term runoff simulation, *Water (Switz.)*, vol. 12, no. 8, Aug. 2020, doi: 10.3390/W12082177.
- [11] N. Nurhamidah, R. Andari, A. Junaidi, *et al.*, Evaluation of the Compatibility of TRMM Satellite Data with Precipitation Observation Data, *Int. J. Inf. Visual.*, vol. 7, no. 2, p. 287, May 2023, doi: 10.30630/joiv.7.2.1578.
- [12] I. A. Khalid and S. Sitanggang, Machine Learning-Based Spatial Downscaling on Precipitation Satellite Data in Riau Province, Indonesia, *TURCOMAT*, vol. 13, no. 02, pp. 7–16, 2022, doi: 10.17762/turcomat.v13i2.12114.
- [13] C. Chen, Q. Chen, B. Qin, *et al.*, Comparison of Different Methods for Spatial Downscaling of GPM IMERG V06B Satellite Precipitation Product Over a Typical Arid to Semi-Arid Area, *Front. Earth Sci.*, vol. 8, Nov. 2020, doi: 10.3389/feart.2020.536337.
- [14] C. Chen, S. Zhao, Z. Duan, *et al.*, An Improved Spatial Downscaling Procedure for TRMM 3B43 Precipitation Product Using Geographically Weighted Regression, in *Ieee J-stars.*, Institute of Electrical and Electronics Engineers, Sep. 2015, pp. 4592–4604. doi: 10.1109/JSTARS.2015.2441734.
- [15] H. Zhu, H. Liu, Q. Zhou, *et al.*, Towards an Accurate and Reliable Downscaling Scheme for High-Spatial-Resolution Precipitation Data, *Remote Sens.*, vol. 15, no. 10, May 2023, doi: 10.3390/rs15102640.
- [16] C. Funk, P. Petersen, M. Landsfeld, *et al.*, The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes, *Sci. Data*, vol. 2, no. 1, p. 150066, Dec. 2015, doi: 10.1038/sdata.2015.66.
- [17] G. J. Huffman, E. F. Stocker, D. T. Bolvin, *et al.*, GPM IMERG Final Precipitation L3 Half Hourly 0.1 degree x 0.1 degree V06 (GPM_3IMERGHH), Goddard Earth Sciences Data and Information Services Center (GES DISC).
- [18] T. Kubota, K. Aonashi, T. Ushio, *et al.*, Global Satellite Mapping of Precipitation (GSMaP) Products in the GPM Era, in *Satellite Precipitation Measurement*, vol. 1, V. Levizzani, C. Kidd, D. B. Kirschbaum, *et al.*, Eds., Cham: Springer, 2020, pp. 355–373. doi: 10.1007/978-3-030-24568-9_20.
- [19] H. Ashouri, K. Hsu, S. Sorooshian, *et al.*, PERSIANN-CDR: Daily Precipitation Climate Data Record from Multisatellite Observations for Hydrological and Climate Studies, *Bull Am Meteorol Soc*, vol. 96, no. 1, pp. 69–83, Jan. 2015, doi: 10.1175/BAMS-D-13-00068.1.
- [20] BMKG, Data penakar hujan (in situ), *Unpublished data*, 2024. Badan Meteorologi, Klimatologi, dan Geofisika.
- [21] Badan Informasi Geospasial, *Batas Wilayah Administrasi*, 2023, BIG. Accessed: Jan. 02, 2025. [Online]. Available: <https://geoservices.big.go.id/portal/apps/webappviewer/index.html?id=cb58db080712468cb4bfd408dbde3d70>.
- [22] United States Geological Survey, *USGS EROS Archive - Digital Elevation - Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global*, 2014, USGS. doi: 10.5066/F7PR7TFT.
- [23] B. Latos, T. Lefort, M. Flatau, *et al.*, Equatorial waves triggering extreme rainfall and floods in Southwest Sulawesi, Indonesia, *Mon Weather Rev*, vol. 149, no. 5, pp. 1381–1401, May 2021, doi: 10.1175/MWR-D-20-0262.1.