

Evaluasi Keakuratan Produk Satelit (CHIRPS, GPM-IMERG, PERSIANN-CCS, dan GSMaP) Dalam Mengidentifikasi Curah Hujan di Sumatera Barat

Muhammad Aulia Zikri¹, Tiara Emanuella Disera¹, Rio Hansyen Saragih¹, Imma Redha Nugraheni^{2*}

¹Program Studi Sarjana Terapan Meteorologi, Sekolah Tinggi Meteorologi Klimatologi, dan Geofisika, Indonesia

²Program Studi Meteorologi, Sekolah Tinggi Meteorologi Klimatologi, dan Geofisika, Indonesia

Article Info

Article history:

Received Jan 19, 2025

Revised Dec 24, 2025

Accepted Jan 02, 2026

Keywords:

GPM-IMERG

GSMaP

CHIRPS

PERSIANN-CCS

Correlation

ABSTRACT

Satellite-based rainfall products are used to complement ground observations, yet their accuracy remains uncertain in regions with complex topography, such as West Sumatra, where rain gauge networks are sparse. This study aims to evaluate the performance of four satellite rainfall products, GPM-IMERG, CHIRPS, GSMaP, and PERSIANN-CCS, by comparing them with observational data from three BMKG stations. Eyeball analysis and statistical verification were conducted using daily, ten-day, monthly, and seasonal temporal aggregations. The statistical metrics employed include CC, RMSE, NRMSE, MAE, and categorical contingency metrics such as POD, FAR, CSI, FOH, and HSS. The results show that CHIRPS yields the best accuracy on the daily scale, $CC = 0.17$, $RMSE = 27.97$ mm, while GPM-IMERG consistently outperforms all products on ten-day to seasonal scales, achieving the highest correlation (up to $CC = 0.84$) with relatively low estimation errors. Contingency metrics further confirm GPM-IMERG as the most reliable product for detecting rainfall events. These findings highlight the importance of validating satellite rainfall products in topographically complex regions and demonstrate that GPM-IMERG provides the most reliable rainfall estimates for West Sumatra, particularly for medium- to long-term analyses.

Copyright © 2025 Universitas Indraprasta PGRI.
All rights reserved.

Corresponding Author:

Imma Redha Nugraheni,

Program Studi Meteorologi,

Sekolah Tinggi Meteorologi Klimatologi dan Geofisika,

Jl. Meteorologi No.5, Tanah Tinggi, Kec. Tangerang, Kota Tangerang, Banten

Email: imma.redha@stmkg.ac.id

1. PENDAHULUAN

Dalam meteorologi, curah hujan menjadi salah satu variabel vital dalam menentukan karakteristik cuaca suatu wilayah. Sebagai negara kepulauan, Indonesia memiliki iklim yang dinamis dan sering kali mengalami anomali curah hujan yang signifikan [1]. Peningkatan anomali curah hujan dapat mengakibatkan debit aliran air tinggi dan cepat serta mengalir ke Daerah Aliran Sungai (DAS). DAS memiliki keterbatasan dalam menampung debit curah hujan jika anomali terlalu tinggi sehingga mengakibatkan limpasan air hujan dari daerah hulu hingga hilir. DAS yang memiliki keterbatasan kapasitas penampungan akan mengalirkan limpasan ke wilayah hilir DAS apabila terjadi peningkatan curah hujan di wilayah hulu [2]. Limpasan air yang sangat besar, dapat memengaruhi berbagai sektor kehidupan, seperti pertanian, infrastruktur, hingga penanggulangan bencana.

Salah satu daerah yang mengalami peningkatan anomali curah hujan di Indonesia adalah Sumatera Barat. Sebagian besar daerah ini memiliki tipe hujan ekuatorial yang memiliki dua puncak musim hujan sepanjang tahunnya [3]. Selain itu, daerah ini juga memiliki jajaran gunung berapi yang masih aktif, sehingga memiliki potensi bencana yang lebih tinggi, seperti banjir lahar dan sebagainya [4]. Dengan daerah yang luas dan topografi yang beragam, daerah ini dilengkapi dengan berbagai instrumen meteorologi dalam observasi

curah hujan. Namun, data yang dihasilkan ini masih belum cukup untuk mampu memetakan dan memprediksi curah hujan dengan tepat karena banyaknya hambatan.

Salah satu hambatan dalam mendapatkan data curah hujan yang baik di Indonesia, khususnya di Sumatera Barat, adalah ketersediaan jumlah titik observasi yang tidak cukup rapat [5]. Data observasi yang tersedia sering kali tidak mencukupi, karena tingginya variasi pola curah hujan, khususnya di daerah pegunungan yang bersifat orografis [6]. Keterbatasan ini menyebabkan analisis dan prediksi curah hujan sulit dilakukan [7]. Dalam beberapa waktu terakhir, data *remote sensing* menjadi pilihan alternatif untuk mengatasi keterbatasan data observasi curah hujan. Data *remote sensing* adalah data yang didapatkan dari pengamatan objek di permukaan Bumi tanpa kontak langsung dengan objek tersebut. Biasanya memanfaatkan instrumen penginderaan jauh seperti radar, satelit, dan pesawat udara [8]. Data ini memiliki keunggulan dalam mendapatkan estimasi data curah hujan dengan resolusi spasial tinggi.

Berbagai instrumen memiliki kelebihan dan kekurangan dalam pemanfaatannya, di antaranya adalah penggunaan satelit dan radar [9]. Pemanfaatan citra satelit dalam mengestimasi curah hujan memiliki sejumlah keunggulan yang menjadikannya pilihan yang lebih efektif dibandingkan dengan penggunaan radar [10]. Salah satu keuntungan utama adalah jangkauan luas yang dapat dicapai oleh citra satelit, memungkinkan pemantauan di daerah terpencil atau negara berkembang yang mungkin tidak dilengkapi infrastruktur radar. Selain itu, satelit modern menawarkan resolusi temporal yang tinggi, memberikan data secara periodik yang esensial untuk memahami pola curah hujan secara *near real-time*. Dalam konteks daerah dengan topografi kompleks, citra satelit mampu mengatasi hambatan fisik yang sering mengganggu akurasi radar.

Namun, dalam pemanfaatannya, data satelit belum sepenuhnya dapat menggantikan data observasi [11]. Hal ini disebabkan oleh perbedaan resolusi dan karakteristik suatu wilayah. Banyak jenis produk satelit dengan karakteristik dan resolusi yang berbeda-beda dan memberikan keakuratan yang berbeda juga [12]. Data satelit memiliki keterbatasan dalam menangkap fenomena cuaca skala mikro, khususnya di daerah dengan topografi kompleks seperti pegunungan [13]. Selain itu, data satelit juga belum mampu mendeteksi kondisi atmosfer bagian bawah, khususnya saat tertutup oleh awan tebal, maka yang akan dideteksi adalah penampang horizontal atas awan saja [14]. Dengan keterbatasan ini, dibutuhkan validasi data satelit terhadap data observasi untuk hasil yang lebih akurat dan presisi. Di antara produk satelit curah hujan yang dapat divalidasi adalah IMERG (*Integrated Multi-satellitE Retrievals for GPM*), CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*), PERSIANN-CCS (*PERSIANN-Cloud Classification System*), dan GSMaP (*Global Satellite Mapping of Precipitation*).

Produk satelit curah hujan ini memiliki karakteristik dan keunggulan masing-masing, sehingga pemanfaatannya dapat disesuaikan dengan kebutuhan. IMERG mampu memberikan estimasi dengan resolusi temporal tinggi dengan cakupan global dan berfokus pada wilayah tropis. Namun, memiliki keterbatasan dalam mengestimasi curah hujan di wilayah pegunungan yang kompleks [15], [16]. Di sisi lain, CHIRPS mampu menggabungkan data satelit dengan data observasi di stasiun dan menyediakan estimasi curah hujan beresolusi tinggi dari tahun 1981 hingga sekarang [17]. Keunggulan CHIRPS ini dalam memantau estimasi curah hujan pada skala regional menjadikannya unggul di wilayah tropis dengan iklim musiman, meskipun masih memiliki ketergantungan pada data observasi stasiun sehingga memiliki akurasi rendah di daerah dengan titik observasi tidak rapat [18], [19].

PERSIANN-CCS dan GSMaP juga memiliki resolusi temporal yang tinggi dan menjadi pilihan yang baik untuk menganalisis kejadian hujan ekstrem [20]. PERSIANN-CCS memanfaatkan jaringan saraf tiruan untuk mengklasifikasi pola awan dari citra inframerah yang memungkinkan mengestimasi curah hujan skala lokal, meskipun masih rentan terhadap bias di wilayah dengan topografi kompleks [21]. Di sisi lain, GSMaP memberikan produk *near real-time* yang cocok untuk memantau banjir dan pola curah hujan, khususnya di wilayah Asia [22], [23]. Namun, di wilayah tropis, akurasi GSMaP cenderung rendah dan memerlukan validasi tambahan di wilayah yang kompleks. Di Indonesia, GSMaP cenderung *overestimate* dengan rata-rata nilai tambahan 82,6% [24].

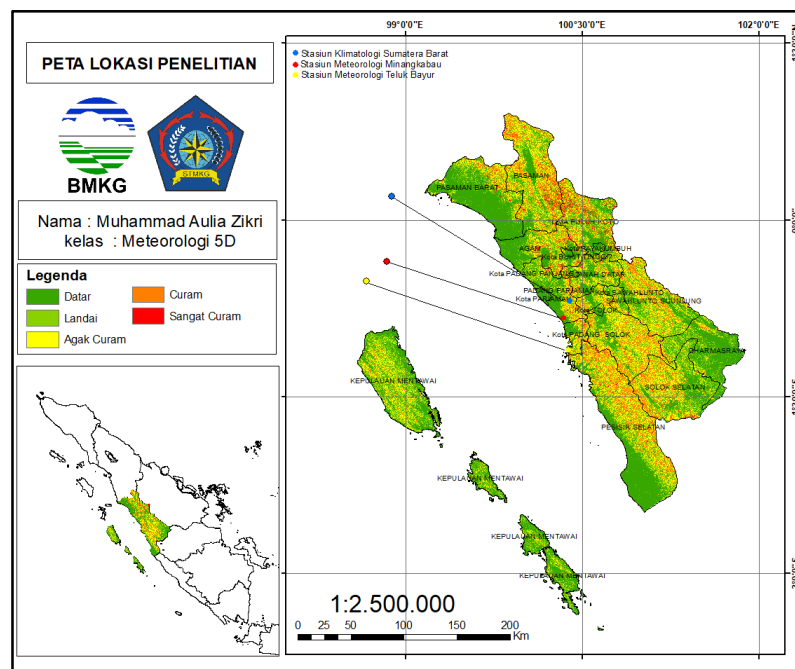
Untuk mengidentifikasi keterbatasan ini, diperlukan evaluasi untuk mengetahui keakuratan produk satelit curah hujan. Salah satu tekniknya adalah dengan membandingkannya dengan data observasi yang diperoleh dari pos-pos pengamatan curah hujan, terutama di wilayah tropis seperti Sumatera Barat dengan tipe hujan yang ekuatorial dan curah hujan ekstrem yang sulit untuk diprediksi [25], [26]. Penelitian sebelumnya menunjukkan bahwa produk satelit seperti IMERG, CHIRPS, PERSIANN-CCS, dan GSMaP memiliki tingkat akurasi yang bervariasi tergantung pada wilayah dan metode validasi.

Namun demikian, kajian evaluasi terhadap keempat produk satelit ini di wilayah dengan topografi kompleks seperti Sumatera Barat masih sangat terbatas. Sebagian besar penelitian sebelumnya hanya berfokus pada satu atau dua produk satelit, belum mencakup analisis waktu dan spasial yang komprehensif, dan belum mengaitkan performa produk dengan karakter orografis wilayah [27]. Selain itu, kurangnya pemanfaatan evaluasi berbasis tabel kontingensi untuk menilai kemampuan deteksi hujan secara lebih detail.

Di sisi lain, kondisi Sumatera Barat yang memiliki jarak antar-AWS dan ARG yang jauh serta distribusi stasiun yang tidak merata menyebabkan data observasi belum cukup merepresentasikan variabilitas curah hujan orografis. Keterbatasan kerapatan stasiun ini menjadi faktor pendukung akan kebutuhan data sekunder dari produk satelit curah hujan untuk mengisi kekosongan informasi pada area yang belum terjangkau oleh stasiun pengamatan curah hujan. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi keakuratan empat produk satelit curah hujan (IMERG, CHIRPS, PERSIANN-CCS, dan GSMaP) dibandingkan dengan data observasi di Sumatera Barat. Verifikasi data ini diharapkan mampu memberikan informasi yang baik untuk meningkatkan akurasi produk satelit dalam memantau curah hujan, serta mendukung penanggulangan bencana di daerah Sumatera Barat.

2. METODE

Penelitian ini dilakukan dengan menggunakan pendekatan kuantitatif deskriptif dan pendekatan komparatif deskriptif untuk mengevaluasi keakuratan produk satelit seperti IMERG, CHIRPS, PERSIANN-CCS, dan GSMaP dan membandingkannya dengan data observasi di Sumatera Barat. Data yang digunakan dalam penelitian mencakup data observasi dari *Automatic Weather System* (AWS) dan *Automatic Agroclimate Weather Station* (AAWS) pada tiga stasiun observasi BMKG di Sumatera Barat (Stasiun Meteorologi Minangkabau, Stasiun Meteorologi Maritim Teluk Bayur, dan Stasiun Klimatologi Sumatera Barat). Data satelit yang digunakan dalam penelitian ini meliputi produk IMERG, CHIRPS, PERSIANN-CCS, dan GSMaP yang masing-masing diunduh dari situs resmi, serta menggunakan bantuan perangkat lunak seperti Google Earth Engine (GEE) dan Google Colab untuk mengefisienkan proses pengumpulan data. GEE digunakan untuk mengumpulkan data CHIRPS yang telah dipotong sesuai dengan lokasi penelitian. Data dari produk satelit yang diambil dengan resolusi spasial $0.1^\circ \times 0.1^\circ$ (IMERG, GSMaP), $0.05^\circ \times 0.05^\circ$ (CHIRPS), dan $0.04^\circ \times 0.04^\circ$ (PERSIANN-CCS), serta diunduh dalam format NetCDF (.nc) untuk IMERG, PERSIANN-CCS, dan CHIRPS. Sedangkan GSMaP diunduh dalam format *comma separated values* (.csv).



Gambar 1. Lokasi penelitian

Dalam penelitian ini, digunakan tiga (3) stasiun pengamatan curah hujan karena mewakili karakter topografi dan distribusi curah hujan di Sumatera Barat: wilayah pesisir (Stasiun Meteorologi Maritim Teluk Bayur dan Stasiun Meteorologi Minangkabau), dataran tinggi/pegunungan (Stasiun Klimatologi Sumatera Barat). Pemilihan ini dilakukan agar evaluasi produk satelit dapat melihat sensitivitas estimasi satelit terhadap variasi orografis di wilayah Sumatera Barat. Selain itu, distribusi AWS/ARG di Sumatera Barat yang jaraknya berjauhan menjadikan ketiga stasiun ini sebagai titik referensi utama yang paling representatif.

Workflow Penelitian

Untuk memperjelas alur penelitian, dilakukan beberapa langkah berikut :

- a. Pengumpulan data
 - Pengunduhan data satelit (IMERG, CHIRPS, PERSIANN-CCS, GSMaP).
 - Pengambilan data observasi harian dari AWS/AAWS pada tiga stasiun BMKG.
- b. Pra-pengolahan data
 - Memotong (*klipping*) data satelit berdasarkan koordinat stasiun.
 - Mengonversi format (NetCDF/CSV menjadi data *grid* analisis)
 - Menyinkronisasi rentang waktu (Desember 2022–November 2023).
- c. Ekstraksi dan perhitungan statistik
 - Menghitung RMSE, NRMSE, MAE, dan CC.
 - Menyusun tabel kontingensi berdasarkan *threshold* hujan.
- d. Analisis per-band data
 - Bandingkan nilai harian antara satelit dan observasi.
 - Hitung performa kategorikal (POD, FAR, FOH, CSI, HSS).
- e. Visualisasi
 - Grafik time series & scatter (R-Studio/Colab).
 - Peta sebaran dan bias spasial (ArcGIS).
- f. Interpretasi dan pembahasan
 - Evaluasi hubungan performa satelit dengan kondisi orografis.

Verifikasi Data

Dalam penelitian ini digunakan *threshold* hujan > 0 mm/ hari sebagai batas deteksi hujan. *Threshold* ini dipilih karena:

- a. Mewakili definisi standar deteksi hujan dalam analisis kategorikal (*rain/no rain*),
- b. Sesuai dengan kebutuhan evaluasi kemampuan satelit dalam membedakan kejadian hujan dan tidak hujan,
- c. Relevan terhadap karakter hujan intensitas rendah–sedang yang umum terjadi di Sumatera Barat.

Definisi “hari hujan” adalah periode 24 jam di mana terkumpul curah hujan sebesar 0,5 mm atau lebih. Jika curah hujan kurang dari nilai tersebut, maka hari tersebut dinyatakan sebagai hari tanpa hujan (no), meskipun jumlah curah hujan tetap diperhitungkan sebagai data akumulasi [28].

Verifikasi data yang dilakukan dapat menggunakan beberapa metrik statistik yaitu *Root Mean Square Error* (RMSE), *Normalize RMSE* (NRMSE), *Mean Absolute Error* (MAE), dan *Correlation Coefficient* (CC). Selain itu, juga menggunakan tabel kontingensi untuk mengevaluasi kemampuan dari satelit dalam mengestimasi intensitas curah hujan. Hasil dari melakukan pengujian dengan tabel kontingensi akan menghasilkan nilai *Probability of Detection* (POD), *False Alarm Ratio* (FAR), *Frequency of Hit* (FOH), *Heidke Skill Score* (HSS) dan *Critical Success Index* (CSI). POD mengukur sejauh mana data satelit mampu mendeteksi kejadian hujan yang sebenarnya terjadi. FAR menunjukkan proporsi deteksi palsu, yaitu ketika satelit memprediksi hujan tetapi kenyataannya tidak ada hujan. CSI menggabungkan metrik untuk mengukur sejauh mana deteksi hujan, kesalahan palsu, dan kejadian hujan yang terlewat. FOH mengukur proporsi kejadian hujan yang berhasil diprediksi dengan benar dibandingkan dengan semua kejadian yang diprediksi sebagai hujan [27]. Namun berbeda dari POD, FOH berfokus pada jumlah prediksi hujan yang benar dibandingkan dengan semua prediksi hujan. Sedangkan, HSS adalah metrik yang menilai akurasi prediksi hujan satelit dibandingkan dengan prediksi acak [29].

1. *Root Mean Square Error* (RMSE)

RMSE adalah akar kuadrat dari rata-rata perbedaan kuadrat antara nilai prediksi (curah hujan satelit) dan nilai aktual (nilai curah hujan observasi) [30]. Nilai RMSE yang besar menandakan adanya anomali yang signifikan antara data observasi dan data satelit curah hujan. Nilai RMSE dapat diformulasikan pada persamaan 1, dimana G_i adalah curah hujan stasiun observasi, S_i adalah nilai produk satelit curah hujan, dan n merupakan banyaknya data [29], [31].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - G_i)^2} \tag{1}$$

2. *Normalize RMSE (NRMSE)*

NRMSE adalah metrik yang digunakan untuk menilai akurasi dan pengulangan data. Ini dihitung dengan membagi kesalahan kuadrat rata-rata akar (RMSE) dari perbedaan antara dua kumpulan data dengan RMSE rata-rata input, dinyatakan sebagai persentase [31]. NRMSE ini mampu membantu membandingkan data curah hujan observasi dan satelit serta memberikan perkiraan yang baik pada berbagai skala temporal [32]. NRMSE dapat dihitung seperti yang diformulasikan apada persamaan 2, dimana G_{max} adalah nilai maksimum dari data curah hujan observasi serta G_{min} adalah nilai curah hujan observasi minimum [29].

$$NRMSE(\%) = \frac{RMSE}{(G_{max} - G_{min})} \times 100 \tag{2}$$

3. *Mean Absolute Error (MAE)*

MAE adalah metrik yang digunakan untuk mengukur tingkat kesalahan rata-rata antara nilai prediksi (data satelit curah hujan) dan nilai aktual (data observasi curah hujan). MAE mampu secara langsung mewakili besaran kesalahan rata-rata tanpa dipengaruhi oleh variabilitas kesalahan atau ukuran sampel [33]. Metrik ini dapat diformulasikan dalam persamaan 3 yang bersumber dari [29].

$$MAE = \frac{\sum_{i=1}^n abs(S_i - G_i)}{n} \tag{3}$$

4. *Correlation Coefficient (CC)*

CC merupakan metrik statistik yang digunakan untuk mengukur kekuatan dan arah hubungan linear antara dua variabel. CC bernilai dari -1 hingga +1, dengan nilai +1 menunjukkan keterikatan atau hubungan linear yang lebih kuat [34]. CC dapat dicari dengan persamaan 4, dengan \underline{S} merupakan nilai curah hujan satelit rata-rata dan \underline{G} adalah nilai curah hujan observasi rata-rata [29].

$$CC = \frac{[\sum_{i=1}^n (S_i - \underline{S}) \times (G_i - \underline{G})]^2}{\sum_{i=1}^n (S_i - \underline{S})^2 \sum_{i=1}^n (G_i - \underline{G})^2} \tag{4}$$

Dalam melihat keterkaitan antar dua variabel dengan metrik ini, maka telah diberikan kriteria atau *threshold* dari nilai CC yang berkisar dari -1 hingga 1. Dalam Tabel 1 menunjukkan nilai positif dari hubungan antar dua variabel. Korelasi positif ini menunjukkan kenaikan pada satu variabel cenderung diikuti oleh kenaikan avriabel lainnya. Sedangkan nilai negatif saat $r < 0$, mengindikasikan kenaikan pada satu avriabel cenderung diikuti penurunan variabel lainnya [35].

Tabel 1. Keterangan kualitatif nilai korelasi

Nilai koefisien	Hubungan
0,00 – 0,199	Sangat lemah
0,20 – 0,399	Lemah
0,40 – 0,599	Sedang
0,60 – 0,799	Kuat
0,80 – 1,000	Sangat kuat

5. *Tabel Kontingensi*

Selain metrik statistik yang digunakan dalam verifikasi data, digunakan juga tabel kontingensi untuk melihat kemampuan curah hujan satelit dalam mendeteksi kejadian curah hujan. Digunakan empat statistik kategorikal berupa *hits* (*a*), *misses* (*c*), *false alarm* (*b*), dan *correct negatives* (*d*), yang dihitung dan dibandingkan melalui tabel silang variabel yang memenuhi kondisi tertentu. Variabel *a* menunjukkan bahwa data model dan data observasi curah hujan menyatakan adanya fenomena hujan. Variabel *b* mengindikasikan bahwa data observasi menunjukkan hujan sedangkan data satelit tidak menunjukkan adanya hujan. Variabel *c* menunjukkan data satelit menunjukkan adanya hujan dan data observasi menunjukkan tidak adanya hujan. Variabel *d* menunjukkan tidak adanya hujan dari data observasi dan data satelit.

Hal ini memungkinkan penguraian bias secara kategorikal pada setiap produk satelit curah hujan [36]. Hasil uji tabel kontingensi akan menghasilkan nilai *Probability of Detection* (POD), *False Alarm Ratio* (FAR), *Frequency of Hit* (FOH), *Critical Succes Index* (CSI), dan *Heidke Skill Score* (HSS). Beberapa nilai uji tabel kontingensi dapat diformulasikan dalam persamaan 5 hingga 9 [29].

a. *Probability of Detection (POD)*

Nilai ini mengukur kemampuan satelit dalam mendeteksi kejadian hujan yang benar-benar terjadi. Semakin tinggi POD, semakin baik satelit dalam menangkap kejadian hujan aktual.

$$POD = \frac{a}{a+c} \quad (5)$$

b. *False Alarm Ratio (FAR)*

Nilai ini menunjukkan seberapa sering satelit mendeteksi hujan padahal kenyataannya tidak terjadi (deteksi palsu). Nilai FAR yang kecil menunjukkan satelit tidak banyak melakukan kesalahan prediksi hujan.

$$FAR = \frac{b}{a+b} \quad (6)$$

c. *Frequency of Hit (FOH)*

Nilai ini mengukur proporsi prediksi hujan yang benar dibandingkan dengan semua prediksi hujan. FOH fokus pada kualitas prediksi yang menyatakan hujan.

$$FOH = \frac{c}{c+a} \quad (7)$$

d. *Critical Success Index (CSI)*

Nilai ini menggabungkan informasi hits, misses, dan false alarms untuk menggambarkan kemampuan satelit mendeteksi hujan secara keseluruhan. CSI sangat berguna dalam mengukur performa model pada kejadian yang jarang.

$$CSI = \frac{a}{a+b+c} \quad (8)$$

e. *Heidke Skill Score (HSS)*

Nilai ini menilai akurasi pendeteksian hujan relatif terhadap prediksi acak. Nilai HSS yang tinggi menunjukkan bahwa satelit memiliki kemampuan prediksi yang lebih baik daripada sekadar tebakan.

$$HSS = \frac{(a+d)-E}{N-E} \quad (10)$$

Dengan N adalah jumlah total kejadian dan E adalah prediksi kejadian benar yang terjadi tanpa diprediksi (*expected random hits*)

Tabel 2. Tabel kontingensi

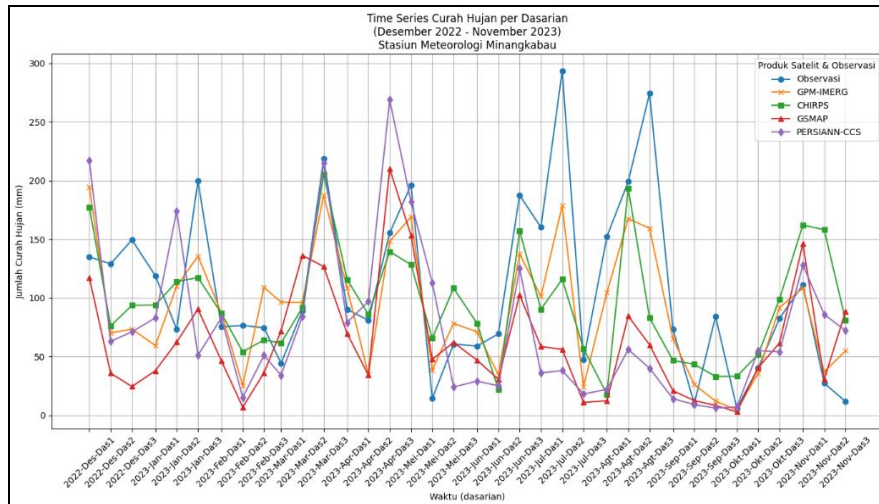
		Data observasi (mm/hari)	
		Hujan > 0 mm/hari	Hujan = 0 mm/hari
Data satelit	Rain > mm/day	<i>hits (a)</i>	<i>false (b)</i>
	Rain = mm/day	<i>misses (c)</i>	<i>correct no rain (d)</i>

3. HASIL PENELITIAN

3.1. Time Series Data Curah Hujan Observasi dan Berbagai Data Satelit Curah Hujan

3.1.1 Stasiun Meteorologi Minangkabau

Pada Stasiun Meteorologi Minangkabau, dapat diamati perbedaan data observasi dan produk satelit curah hujan pada gambar 2. Dapat diamati dari time series, data observasi digambarkan *blue line*, GPM-IMERG dengan *orange line*, CHIRPS dengan *green line*, GSMaP dengan *red line*, dan PERSIANN-CCS dengan *purple line*.




Gambar 2. *Time series* curah hujan per dasarian Stasiun Meteorologi Minangkabau

Hasil *time series* menunjukkan variasi curah hujan musiman yang cukup jelas pada periode pengamatan. Pada musim DJF, curah hujan berfluktuasi dengan puncak pada dasarian pertama Desember 2022 (~200 mm). Produk GPM-IMERG dan CHIRPS menghasilkan estimasi yang mendekati nilai observasi (180–200 mm), sedangkan GSMaP cenderung lebih rendah (~150 mm). Pada musim MAM tercatat puncak curah hujan tertinggi sepanjang tahun, yaitu pada dasarian kedua Mei 2023 (>300 mm). Produk PERSIANN-CCS dan GPM-IMERG memberikan estimasi sekitar 280–300 mm, sementara GSMaP tetap berada di bawahnya (~250 mm). Periode JJA ditandai dengan curah hujan yang lebih rendah dan relatif stabil. Pada dasarian pertama Juni 2023, curah hujan observasi ~150 mm dengan estimasi satelit yang mendekati nilai tersebut kecuali GSMaP (~120 mm). Pada SON, terjadi peningkatan curah hujan kembali, khususnya pada dasarian pertama Oktober 2023 (~250 mm). GPM-IMERG dan PERSIANN-CCS memperlihatkan nilai estimasi yang paling mendekati. Secara keseluruhan, MAM menjadi periode dengan curah hujan tertinggi, sedangkan JJA menjadi fase dengan curah hujan relatif rendah.

3.1.2 Stasiun Meteorologi Maritim Teluk Bayur

Di Stasiun Meteorologi Maritim Teluk Bayur, terlihat perbedaan antara data observasi dan produk satelit curah hujan yang ditampilkan pada Gambar 3. Dalam grafik *time series* tersebut, data observasi direpresentasikan oleh garis biru, GPM-IMERG dengan garis oranye, CHIRPS dengan garis hijau, GSMaP dengan garis merah, dan PERSIANN-CCS dengan garis ungu.



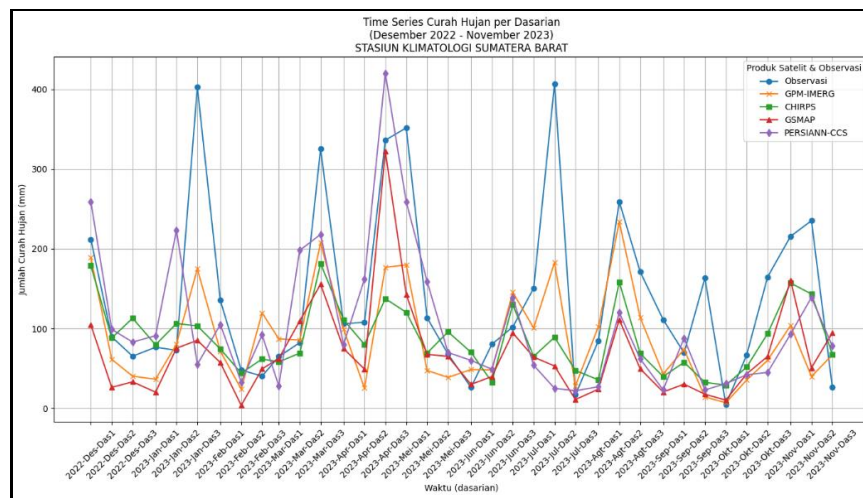
Gambar 3. *Time series* curah hujan per dasarian Stasiun Meteorologi Teluk Bayur

Variasi curah hujan per dasarian menunjukkan pola musiman yang serupa. Pada musim DJF, curah hujan berfluktuasi moderat, dengan puncak pada dasarian pertama Desember 2022 (~250 mm). Produk

GPM-IMERG, CHIRPS, dan PERSIANN-CCS mengestimasi nilai yang mendekati observasi (230–250 mm), sedangkan GSMaP lebih rendah (~200 mm). Musim MAM memperlihatkan intensitas curah hujan tertinggi pada dasarian kedua Mei (>500 mm). Produk PERSIANN-CCS dan GPM-IMERG berada pada kisaran 450–480 mm, sementara CHIRPS dan GSMaP menunjukkan nilai lebih rendah (~400–420 mm). Pada JJA, curah hujan umumnya rendah dan stabil, dengan puncak kecil pada dasarian pertama Juni (~150 mm). GPM-IMERG dan CHIRPS menunjukkan estimasi terdekat, sedangkan GSMaP ~120 mm. Pada SON, terjadi peningkatan signifikan, terutama pada dasarian pertama Oktober (~350 mm). GPM-IMERG dan PERSIANN-CCS berada pada kisaran 320–340 mm, sementara GSMaP tetap lebih rendah. Secara keseluruhan, MAM menjadi periode paling basah, dan JJA menjadi periode paling kering.

3.1.3 Stasiun Klimatologi Sumatera Barat

Perbedaan antara data observasi dan produk satelit curah hujan dapat dilihat pada grafik di Stasiun Klimatologi Sumatera Barat. Pada grafik *time series* tersebut, data observasi diwakili oleh garis biru, GPM-IMERG oleh garis oranye, CHIRPS oleh garis hijau, GSMaP oleh garis merah, dan PERSIANN-CCS oleh garis ungu.



Gambar 4. *Time series* curah hujan per dasarian Stasiun Klimatologi Sumatera Barat

Time series menunjukkan pola musiman yang konsisten dengan dua stasiun lainnya. Pada DJF, puncak curah hujan terjadi pada dasarian pertama Desember (~200 mm). GPM-IMERG dan CHIRPS memperkirakan 180–190 mm, sedangkan PERSIANN-CCS sedikit lebih tinggi (~210 mm) dan GSMaP lebih rendah (~170 mm). Pada MAM, puncak tinggi terjadi pada dasarian kedua Mei (>400 mm). Estimasi PERSIANN-CCS ~390 mm, sedangkan GPM-IMERG dan CHIRPS berada pada kisaran 350–370 mm. Pada JJA, curah hujan lebih rendah dan stabil. Estimasi satelit pada dasarian pertama Juni secara umum mendekati observasi, dengan GSMaP sedikit *undervalued*. Pada SON, curah hujan meningkat kembali, dengan puncak ~300 mm pada dasarian pertama Oktober. GPM-IMERG dan CHIRPS berada pada kisaran 270–290 mm, sedangkan GSMaP ~250 mm. Secara keseluruhan, MAM merupakan musim dengan curah hujan tertinggi, sedangkan JJA menjadi musim terkering.

3.2. Uji Metrik Korelasi, RMSE, NRMSE, dan MAE Data Curah Hujan Observasi dan Berbagai Data Satelit Curah Hujan

3.2.1. Temporal Harian

Tabel 3. Tabel evaluasi akurasi skala temporal harian

No	Produk	CC	RMSE	NRMSE	MAE
1	CHIRPS	0,17	27,97	0,097	14,19
2	PERSIANN-CCS	0,03	30,73	0,107	15,06
3	GSMaP	0,02	30,83	0,110	13,94
4	GPM-IMERG	0,09	29,47	0,100	14,23

Sumber: hasil pengolahan data

Berdasarkan evaluasi 4 produk curah hujan di 3 stasiun observasi curah hujan Sumatera Barat untuk skala temporal harian, didapatkan bahwa Produk CHIRPS menunjukkan performa terbaik di antara keempat produk satelit. Dengan nilai CC sebesar 0,17, CHIRPS memiliki korelasi tertinggi terhadap data observasi, meskipun masih tergolong rendah. Selain itu, CHIRPS memiliki nilai RMSE sebesar 27,97 mm dan NRMSE sebesar 0,097, yang terendah di antara produk lainnya, mengindikasikan bahwa eror yang dihasilkan relatif kecil baik dalam skala absolut maupun relatif terhadap rata-rata data observasi. Nilai MAE sebesar 14,19 mm juga menunjukkan bahwa kesalahan rata-rata absolut CHIRPS tergolong kecil dibandingkan produk lainnya. Di sisi lain, produk PERSIANN-CCS memiliki performa yang kurang baik, dengan nilai CC hanya sebesar 0,03 yang menunjukkan hubungan sangat lemah dengan data observasi. RMSE sebesar 30,73 mm, NRMSE sebesar 0,107, dan MAE sebesar 15,06 mm, yang lebih tinggi dibandingkan CHIRPS, mengindikasikan tingkat error yang signifikan.

Produk GSMaP memiliki nilai CC terendah sebesar 0,02, yang hampir tidak menunjukkan korelasi dengan data observasi. RMSE dan NRMSE GSMaP adalah yang tertinggi, masing-masing sebesar 30,83 mm dan 0,110, menunjukkan eror yang besar baik dalam skala absolut maupun relatif. Namun, nilai MAE GSMaP sebesar 13,94 mm menunjukkan bahwa meskipun korelasi dan eror relatifnya buruk, prediksi GSMaP konsisten dalam skala absolut. Produk GPM-IMERG menempati posisi menengah dengan nilai CC sebesar 0,09, menunjukkan korelasi yang lebih baik dibandingkan PERSIANN-CCS dan GSMaP, tetapi masih lebih rendah dibandingkan CHIRPS. Nilai RMSE sebesar 29,47 mm dan NRMSE sebesar 0,100 lebih rendah dibandingkan PERSIANN-CCS dan GSMaP, tetapi masih lebih tinggi dari CHIRPS. MAE sebesar 14,23 mm menunjukkan bahwa kesalahan absolut GPM-IMERG sedikit lebih besar dibandingkan CHIRPS dan GSMaP. Secara keseluruhan, CHIRPS menjadi produk satelit paling akurat dalam merepresentasikan data observasi pada skala temporal harian, diikuti oleh GPM-IMERG, sementara PERSIANN-CCS dan GSMaP menunjukkan performa yang kurang.

3.2.2. Temporal Dasarian

Tabel 4. Evaluasi akurasi skala temporal dasarian

No	Produk	CC	RMSE	NRMSE	MAE
1	CHIRPS	0,52	91,39	0,23	60,97
2	PERSIANN-CCS	0,33	107,20	0,27	74,09
3	GSMaP	0,49	105,62	0,26	72,10
4	GPM-IMERG	0,77	73,79	0,18	51,39

Sumber: hasil pengolahan data

Pada skala temporal dasarian, uji evaluasi metrik produk satelit curah hujan terhadap data observasi, dapat disimpulkan bahwa GPM-IMERG menunjukkan performa terbaik dengan CC sebesar 0,77, yang menandakan korelasi yang sangat baik dengan data observasi. Nilai RMSE sebesar 73,79 mm menunjukkan deviasi rata-rata yang relatif kecil antara prediksi dan data observasi, sedangkan NRMSE sebesar 0,18 mengindikasikan kesalahan relatif yang kecil. MAE sebesar 51,39 mm menunjukkan bahwa kesalahan rata-rata absolut pada GPM-IMERG adalah yang terendah dibandingkan produk lain, tanpa kecenderungan yang signifikan untuk *overestimate* atau *underestimate*. Sementara itu, CHIRPS dengan CC sebesar 0,52 menunjukkan korelasi moderat terhadap data observasi, namun nilai RMSE sebesar 91,39 mm dan MAE sebesar 60,97 mm menunjukkan prediksi yang cenderung *underestimate*, dengan kesalahan absolut yang lebih besar dibandingkan dengan GPM-IMERG.

Produk GSMaP dengan CC sebesar 0,49 menunjukkan korelasi yang cukup baik, namun nilai RMSE sebesar 105,62 mm dan MAE sebesar 72,10 mm menunjukkan deviasi prediksi yang lebih besar, yang mengindikasikan bahwa GSMaP cenderung *overestimate* nilai observasi. PERSIANN-CCS dengan CC sebesar 0,33 menunjukkan hubungan yang lemah dengan data observasi, dan RMSE sebesar 107,20 mm serta MAE sebesar 74,09 mm menunjukkan kesalahan terbesar di antara produk lainnya, yang mengarah pada kecenderungan *underestimate*. Secara keseluruhan, GPM-IMERG memiliki kinerja terbaik, sedangkan CHIRPS, GSMaP, dan PERSIANN-CCS memiliki kecenderungan untuk *underestimate* atau *overestimate*.

3.2.3. Temporal Bulanan

Tabel 5. Evaluasi akurasi skala temporal bulanan

No	Produk	CC	RMSE	NRMSE	MAE
1	CHIRPS	0,36	136,65	1,39	127,20
2	PERSIANN-CCS	0,21	148,23	1,50	147,67
3	GSMaP	0,28	203,70	2,07	200,97
4	GPM-IMERG	0,71	133,77	1,36	126,87

Sumber: hasil pengolahan data

Apabila ditinjau pada skala temporal bulanan, produk GPM-IMERG menunjukkan kinerja terbaik dengan CC sebesar 0,71, yang menandakan korelasi yang baik dengan data observasi. Nilai RMSE sebesar 133,77 mm dan NRMSE sebesar 1,36 menunjukkan bahwa kesalahan prediksi relatif kecil meskipun data observasi memiliki variasi yang besar. Semakin tinggi nilai RMSE, semakin besar kesalahan prediksi yang terjadi, namun untuk GPM-IMERG, nilai RMSE ini tergolong cukup rendah, yang menunjukkan data satelit curah hujan cukup akurat. MAE sebesar 126,87 mm juga mencerminkan kesalahan absolut rata-rata yang terendah dibandingkan produk lain. Hal ini menunjukkan bahwa prediksi GPM-IMERG lebih konsisten dan lebih mendekati nilai observasi, dengan kecenderungan lebih kecil untuk *overestimate* atau *underestimate*.

Di sisi lain, produk CHIRPS dengan CC sebesar 0,36 menunjukkan korelasi yang lebih rendah dibandingkan GPM-IMERG. RMSE sebesar 136,65 mm dan NRMSE sebesar 1,39 mengindikasikan kesalahan yang lebih besar dibandingkan GPM-IMERG. Semakin tinggi nilai RMSE, semakin besar pula potensi kesalahan dalam prediksi (CHIRPS cenderung *underestimate*). MAE sebesar 127,20 mm menunjukkan bahwa kesalahan absolut CHIRPS lebih tinggi, meskipun masih lebih rendah dibandingkan PERSIANN-CCS dan GSMaP. PERSIANN-CCS dengan CC sebesar 0,21 memiliki hubungan yang lebih lemah dengan data observasi, ditandai dengan RMSE sebesar 148,23 mm, NRMSE sebesar 1,50, dan MAE sebesar 147,67 mm yang lebih besar, yang mengindikasikan kecenderungan *underestimate* yang lebih besar. Produk GSMaP, dengan CC sebesar 0,28, memiliki korelasi yang lebih rendah dan kesalahan yang sangat tinggi, terutama dengan RMSE sebesar 203,70 mm dan MAE sebesar 200,97 mm, yang menunjukkan kecenderungan *overestimate* yang signifikan pada skala temporal bulanan. Secara keseluruhan, GPM-IMERG adalah produk yang paling akurat pada skala bulanan.

3.2.4. Temporal Musiman

Tabel 6. Evaluasi akurasi skala temporal musiman

No	Produk	CC	RMSE	NRMSE	MAE
1	CHIRPS	0,39	453,45	0,59	383,34
2	PERSIANN-CCS	0,25	545,57	0,65	378,89
3	GSMaP	0,38	657,36	0,83	550,42
4	GPM-IMERG	0,84	383,27	0,52	317,35

Sumber: hasil pengolahan data

Pada skala temporal musiman, produk GPM-IMERG menunjukkan performa yang paling baik dengan CC sebesar 0,84, yang menunjukkan korelasi yang sangat baik terhadap data observasi. RMSE sebesar 383,27 mm dan NRMSE sebesar 0,52 mengindikasikan bahwa GPM-IMERG memiliki kesalahan yang relatif rendah dalam prediksinya, yang berarti kesalahan tersebut cukup kecil bila dibandingkan dengan data observasi. Semakin besar nilai RMSE, semakin besar pula kesalahan prediksi yang dihasilkan, namun untuk GPM-IMERG, angka ini masih tergolong akurat. Selain itu, MAE sebesar 317,35 mm menunjukkan bahwa kesalahan rata-rata absolut GPM-IMERG lebih kecil dibandingkan produk lainnya, mengindikasikan akurasi yang lebih baik dalam pemodelan curah hujan musiman, dengan cenderung *underestimate* yang lebih rendah.

Sebaliknya, produk CHIRPS, dengan CC sebesar 0,39, menunjukkan korelasi yang lebih rendah, meskipun masih cukup baik. RMSE sebesar 453,45 mm dan NRMSE sebesar 0,59 menunjukkan bahwa kesalahan prediksi CHIRPS lebih besar dibandingkan GPM-IMERG, yang mengindikasikan kecenderungan *underestimate* pada data yang diprediksi. MAE sebesar 383,34 mm juga menunjukkan tingkat kesalahan absolut yang relatif tinggi. Produk PERSIANN-CCS, dengan CC sebesar 0,25, menunjukkan korelasi yang lebih lemah dengan data observasi. RMSE sebesar 545,57 mm, NRMSE sebesar 0,65, dan MAE sebesar 378,89 mm yang tinggi mengindikasikan bahwa PERSIANN-CCS memiliki kesalahan prediksi yang cukup besar dan cenderung *underestimate*. Produk GSMaP, dengan CC sebesar 0,38, memiliki korelasi yang rendah dan menghasilkan kesalahan prediksi yang sangat besar, seperti yang ditunjukkan oleh RMSE sebesar 657,36

mm dan MAE sebesar 550,42 mm, yang mengindikasikan kecenderungan *overestimate* pada skala musiman. Secara keseluruhan, GPM-IMERG terbukti lebih akurat dibandingkan dengan produk lainnya, sementara CHIRPS, PERSIANN-CCS, dan GSMaP memiliki performa yang kurang optimal.

3.3. Uji Metrik Tabel Kontingensi Data Curah Hujan Observasi dan Berbagai Data Satelit Curah Hujan

Tabel 7. Tabel kontingensi data curah hujan

No	Produk	POD	FAR	CSI	FOH	HSS
1	CHIRPS	0,68	0,42	0,46	0,68	0,15
2	PERSIANN-CCS	0,59	0,42	0,42	0,59	0,13
3	GSMaP	0,61	0,41	0,43	0,61	0,15
4	GPM-IMERG	0,76	0,41	0,50	0,76	0,21

Sumber: hasil pengolahan data

Produk GPM-IMERG menunjukkan performa terbaik dalam mendeteksi dan memprediksi curah hujan. Dengan POD sebesar 0,76, GPM-IMERG mampu mendeteksi 76% kejadian curah hujan mendekati nilai data observasi. Selain itu, nilai CSI sebesar 0,50 menunjukkan kemampuan yang baik dalam mengidentifikasi curah hujan observasi sambil meminimalkan kesalahan prediksi. Tingginya HSS sebesar 0,21 juga menegaskan kemampuan GPM-IMERG dalam memberikan prediksi yang lebih akurat dibandingkan produk satelit curah hujan lainnya.

Produk CHIRPS dan GSMaP menunjukkan performa yang cukup baik, meskipun masih di bawah GPM-IMERG. CHIRPS memiliki POD sebesar 0,68, menunjukkan kemampuan deteksi kejadian curah hujan yang lebih baik dibandingkan GSMaP, yang memiliki POD sebesar 0,61. Namun, nilai FAR kedua produk relatif tinggi, yaitu masing-masing 0,42 dan 0,41, menunjukkan tingkat kejadian *false alarm* yang signifikan. Dalam hal CSI, CHIRPS mencatat nilai 0,46 sementara GSMaP mencapai 0,43, menunjukkan bahwa akurasi CHIRPS sedikit lebih baik dibandingkan GSMaP. Kedua produk memiliki HSS sebesar 0,15, menandakan tingkat keakuratan antara data observasi dan data satelit yang hampir sama.

Produk PERSIANN-CCS memiliki performa terendah dibandingkan ketiga produk lainnya. Dengan POD sebesar 0,59, PERSIANN-CCS hanya mampu mendeteksi 59% kejadian curah hujan dalam data observasi. Nilai FAR sebesar 0,42 menunjukkan bahwa sekitar 42% prediksi curah hujan oleh PERSIANN-CCS merupakan *false alarm*. Selain itu, nilai CSI sebesar 0,42 dan HSS sebesar 0,13 mengindikasikan tingkat akurasi dan keandalan yang lebih rendah dibandingkan produk lainnya. Secara keseluruhan, GPM-IMERG menempati posisi tertinggi dalam hal akurasi dan keandalan prediksi curah hujan, sementara PERSIANN-CCS menunjukkan performa yang paling lemah.

4. PEMBAHASAN

Hasil verifikasi menunjukkan bahwa keempat produk satelit secara umum mampu mengikuti pola variasi curah hujan di Sumatera Barat, namun tingkat akurasinya sangat berbeda akibat pengaruh algoritma masing-masing serta kondisi topografi wilayah yang kompleks. Sumatera Barat memiliki karakteristik geografis berupa Pegunungan Bukit Barisan yang membentang dari utara–selatan dan dataran pesisir barat yang langsung berhadapan dengan Samudra Hindia. Kondisi ini menghasilkan kombinasi presipitasi orografis, konveksi pesisir, dan pola bayangan hujan di sisi timur yang menantang bagi algoritma satelit. Dalam konteks ini, GPM-IMERG muncul sebagai produk satelit dengan performa paling unggul. Selain itu, IMERG menggunakan metode penggabungan multi-satelit yang membuat estimasinya lebih stabil terhadap bias spasial, serta menggunakan penyesuaian berdasarkan data *gauge* global sehingga memperkecil penyimpangan terhadap data observasi. Karakteristik ini membuat IMERG lebih sensitif terhadap fenomena hujan orografis dan konvektif yang umum terjadi di wilayah pegunungan. Konsistensi kinerja IMERG pada berbagai skala temporal juga sejalan dengan penelitian terdahulu di Serang, Pekanbaru, Ambon, serta Nusa Tenggara Timur, yang menunjukkan bahwa IMERG cenderung memiliki korelasi tertinggi dan kesalahan estimasi terendah dibanding produk lain [27], [37].

Sebaliknya, CHIRPS cenderung menghasilkan bias *underestimate* pada periode curah hujan tinggi. Hal ini berkaitan dengan algoritma CHIRPS yang berbasis pengolahan data inframerah (IR) dengan penyesuaian *gauge*. Sensor IR hanya mendeteksi suhu puncak awan, bukan intensitas presipitasi, sehingga pada kondisi awan orografis yang puncaknya relatif hangat tetapi menghasilkan hujan intens, nilai curah hujan yang dideteksi cenderung lebih rendah. Fenomena ini umum terjadi di sekitar Bukit Barisan, di mana proses *warm rain* dominan dan sulit diidentifikasi oleh sensor IR. Bias *underestimate* CHIRPS ini konsisten dengan penelitian TerraClimate di Kalimantan Barat yang melaporkan underestimasi kuat pada curah hujan kategori tinggi [38]. Produk GSMaP menunjukkan kecenderungan *overestimate* di pesisir barat Sumatera Barat,

terutama akibat algoritmanya yang sensitif terhadap awan konvektif maritim. Pada kawasan pesisir yang menghadapi Samudra Hindia, konveksi sering berkembang tinggi dan masif sehingga algoritma *cloud filtering* GSMaP mengasumsikan intensitas hujan yang lebih besar dari kenyataan. Selain itu, GSMaP juga kurang optimal dalam merepresentasikan curah hujan pada wilayah lereng curam. Temuan ini sejalan dengan studi di Kalimantan Barat, Serang, dan Ambon, yang melaporkan pola bias serupa berupa *overestimate* ketika konveksi sangat aktif.

Produk PERSIANN-CCS menunjukkan bias terbesar dibanding ketiga satelit lainnya karena algoritmanya sepenuhnya berbasis deteksi suhu awan IR melalui *neural network*. Kelemahannya terletak pada ketidakmampuannya membedakan awan dingin tanpa hujan dan awan dingin dengan hujan, sehingga meningkatkan jumlah *false alarm* dan *misses* [39]. Pada daerah pegunungan, pengelompokan awan yang kompleks sering tidak berbanding lurus dengan curah hujan permukaan, sehingga algoritma PERSIANN-CCS menghasilkan bias *overestimate* pada konveksi pesisir dan *underestimate* pada hujan orografis. Hal ini juga selaras dengan penelitian pada kasus Siklon Tropis Seroja di NTT, di mana PERSIANN-CCS menjadi salah satu produk dengan tingkat akurasi terendah [37].

Secara keseluruhan, perbedaan kinerja produk satelit sangat dipengaruhi oleh dinamika atmosfer lokal dan struktur geografis Sumatera Barat. GPM-IMERG, dengan asimilasi data radar aktif dan koreksi *gauge* global, paling mampu menyesuaikan diri terhadap variasi curah hujan akibat konveksi maritim, proses orografis, dan bayangan hujan. CHIRPS dan PERSIANN-CCS yang berbasis IR lebih rentan terhadap bias karena topografi memengaruhi hubungan antara suhu puncak awan dan intensitas hujan. Sementara GSMaP, meskipun berbasis *microwave*, tetap menunjukkan keterbatasan pada representasi awan konvektif pesisir dan efek orografis. Dengan demikian, hasil penelitian ini memperkuat temuan studi terdahulu bahwa GPM-IMERG merupakan produk satelit yang paling sesuai digunakan di wilayah bertopografi kompleks di Sumatera Barat.

5. PENUTUP

Analisis *time series* curah hujan di tiga stasiun observasi di Sumatera Barat menunjukkan variasi intensitas curah hujan yang signifikan berdasarkan musim. Pada Stasiun Meteorologi Minangkabau, curah hujan tertinggi terjadi pada dasarian kedua Mei 2023 dengan observasi melebihi 300 mm, sedangkan musim JJA menunjukkan curah hujan yang lebih rendah dan stabil. Data satelit, seperti GPM-IMERG dan CHIRPS, menunjukkan estimasi yang cukup dekat dengan data observasi, meskipun terdapat perbedaan pada musim dengan curah hujan tinggi, seperti MAM. Di Stasiun Maritim Teluk Bayur, puncak curah hujan tertinggi juga terjadi pada dasarian kedua Mei 2023, dengan observasi mencapai lebih dari 500 mm. Produk satelit GPM-IMERG dan PERSIANN-CCS menunjukkan estimasi mendekati observasi, meskipun GSMaP memiliki deviasi yang lebih besar. Tren serupa terlihat di Stasiun Klimatologi Sumatera Barat, dengan musim MAM menjadi periode dengan intensitas curah hujan tertinggi dan perbedaan mencolok antara data observasi dan satelit.

Pada uji metrik akurasi, GPM-IMERG menunjukkan performa terbaik di semua skala temporal (harian, dasarian, bulanan, dan musiman). Pada skala dasarian, GPM-IMERG memiliki korelasi tertinggi ($CC = 0,77$) dengan kesalahan relatif rendah ($NRMSE = 0,18$). Sementara itu, CHIRPS menjadi produk kedua terbaik pada skala harian, meskipun cenderung *underestimate*. Produk GSMaP dan PERSIANN-CCS secara konsisten menunjukkan performa yang kurang baik, dengan korelasi rendah dan kesalahan prediksi yang besar, terutama pada musim dengan curah hujan tinggi seperti MAM. Hasil ini menunjukkan bahwa GPM-IMERG adalah produk satelit yang paling akurat untuk memodelkan curah hujan di Sumatera Barat, diikuti oleh CHIRPS, dengan GSMaP dan PERSIANN-CCS memiliki keterbatasan yang signifikan.

2. SARAN

Penelitian selanjutnya disarankan untuk berfokus pada pengembangan metodologi verifikasi, tidak hanya pada penambahan variabel analisis. Pendekatan lanjutan yang dapat diterapkan meliputi penerapan koreksi bias berbasis statistik maupun machine learning, integrasi multi-sumber data satelit melalui teknik *satellite merging*, serta penggunaan metode geostatistik untuk memetakan distribusi galat secara lebih representatif pada wilayah bertopografi kompleks. Selain itu, pemanfaatan produk satelit dengan resolusi spasial dan temporal yang lebih tinggi, serta integrasi dengan model hidrologi atau model numerik atmosfer, berpotensi meningkatkan akurasi evaluasi dan memperkuat generalisasi hasil penelitian. Meskipun penelitian ini telah mengombinasikan analisis visual dan metrik statistik, pengembangan metodologi seperti validasi berbasis tipe cuaca (*weather-type-based validation*) atau evaluasi kinerja satelit pada kejadian ekstrem dinilai penting untuk memberikan gambaran yang lebih komprehensif terhadap kemampuan masing-masing produk satelit dalam berbagai kondisi atmosfer.

DAFTAR PUSTAKA

- [1] D. Adlina, R. Oktaverina, E. Suhartanto, dan S. Wahyuni, “Validasi Data Curah Hujan Satelit TRMM (Tropical Rainfall Measuring Mission) dengan Pos Stasiun Hujan pada Sub DAS Keduang Kabupaten Wonogiri, Provinsi Jawa Tengah,” 2022. [Daring]. Tersedia pada: <https://jtresda.ub.ac.id/>
- [2] S. Sosrodarsono dan K. Takeda, *Hidrologi Untuk Pengairan*. Jakarta: PT. Pradya Paramita, 1993.
- [3] K. Suryanti, D. Fitriyani, R. Muharsyah, dan M. Marzuki, “Analisis Variasi Diurnal Curah Hujan di Sumatera Barat Menggunakan Data Rain Gauge dan IMERG,” *POSITRON*, 2020, Diakses: 27 Oktober 2024. [Daring]. Tersedia pada: <http://dx.doi.org/10.26418/positron.v10i2.38469>
- [4] F. Muhammad, A. Hadi, dan D. Irfan, “Pengembangan Sistem Informasi Panduan Mitigasi Bencana Alam Provinsi Sumatera Barat Berbasis Android,” 2018. Diakses: 27 Oktober 2024. [Daring]. Tersedia pada: <https://doi.org/10.24036/tip.v11i1.93>
- [5] A. Mulsandi, M. Mamenun, L. Fitriano, R. Hidayat, dan others, “Perbaikan Estimasi Curah Hujan Berbasis Data Satelit Dengan Memperhitungkan Faktor Pertumbuhan Awan,” *Jurnal Sains & Teknologi Modifikasi Cuaca*, vol. 20, no. 2, hlm. 67–78, 2019.
- [6] J. F. Sanchez-Moreno, C. M. Mannaerts, dan V. G. Jetten, “Influence of topography on rainfall variability in Santiago Island, Cape Verde,” *International journal of climatology*, vol. 34, no. 4, hlm. 1081–1097, 2014.
- [7] R. N. Rahman dan Indra, “Validasi Performa Satelit Presipitasi GSMaP Dalam Mengestimasi Curah Hujan di Jabodetabek,” *Jurnal Widya Climago*, vol. 2, no. 2, hlm. 77–85, 2020.
- [8] D. H. U. Ningsih dan A. T. Setyadi, “Remote Sensing (Penginderaan Jauh),” 2003. [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:61064868>
- [9] P. Nguyen *dkk.*, “The PERSIANN family of global satellite precipitation data: a review and evaluation of products,” *Hydrol Earth Syst Sci*, vol. 22, no. 11, hlm. 5801–5816, 2018, doi: 10.5194/hess-22-5801-2018.
- [10] N. A. Arrokhman, S. Wahyuni, dan E. Suhartanto, “Evaluasi Kesesuaian Data Satelit untuk Curah Hujan dan Evaporasi Terhadap Data Pengukuran di Kawasan Waduk Sutami,” *Jurnal Teknologi dan Rekayasa Sumber Daya Air*, 2021, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:244266282>
- [11] S. D. Marta, E. Suhartanto, dan J. S. Fidari, “Validasi Data Curah Hujan Satelit dengan Data Stasiun Hujan di DAS Ngasinan Hulu, Kabupaten Trenggalek, Jawa Timur,” *Jurnal Teknologi dan Rekayasa Sumber Daya Air*, 2023, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:255648334>
- [12] N. Suwargana, “Resolusi Spasial, Temporal, dan Spektral Pada Citra Satelit Landsat, Spot, dan Ikonos,” 2013, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:129469648>
- [13] R. W. Saragih, J. Daud Malago, dan D. Subaer, “Identifikasi Karakteristik Mesoscale Convective Complex (MCC) di Wilayah Papua dan Sekitarnya,” 2022. [Daring]. Tersedia pada: <https://journal.unnes.ac.id/nju/index.php/jf/index>
- [14] A. Patombongi dan A. M. Islah, “Monitoring Data Citra Satelit Himawari 8 Dengan Metode Optical Flow,” *Simtek: jurnal sistem informasi dan teknik komputer*, 2023, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:257909120>
- [15] F. Chen dan X. Li, “Evaluation of IMERG and TRMM 3B43 Monthly Precipitation Products over Mainland China,” *Remote. Sens.*, vol. 8, hlm. 472, 2016, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:16604161>
- [16] R. K. Pradhan *dkk.*, “Review of GPM IMERG performance: A global perspective,” *Remote Sens Environ*, 2022, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:244964940>
- [17] C. Funk *dkk.*, “The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes,” *Sci Data*, vol. 2, no. 1, hlm. 1–21, 2015.
- [18] Giarno, N. W. M. Simanjuntak, M. Sudarisman, Y. Darmawan, dan I. J. A. Saragih, “Accuracy of CHIRPS rainfall data and its utilization in determining the onset of the wet and dry seasons in North Sumatra,” *MAUSAM*, 2024, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:270840409>
- [19] C. López-Bermeo, R. D. Montoya, F. J. Caro-Lopera, dan J. A. Díaz-García, “Validation of the accuracy of the CHIRPS precipitation dataset at representing climate variability in a tropical mountainous region of South America,” *Physics and Chemistry of the Earth, Parts A/B/C*, 2022, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:249796434>
- [20] Kuolin *dkk.*, “G-WADI PERSIANN-CCS GeoServer for extreme precipitation event monitoring,” *Sci Cold Arid Reg*, vol. 5, hlm. 6–15, 2013, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:127559939>

- [21] Y. Hong, K. Hsu, S. Sorooshian, dan X. Gao, "Precipitation Estimation from Remotely Sensed Imagery Using an Artificial Neural Network Cloud Classification System," *Journal of Applied Meteorology*, vol. 43, hlm. 1834–1853, 2004, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:11229720>
- [22] T. Kubota *dkk.*, "Recent progress in global satellite mapping of precipitation (GSMaP) product," *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, hlm. 2712–2715, 2017, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:31322094>
- [23] T. Tashima, T. Kubota, dan R. Oki, "Precipitation Extremes Monitoring Using Global Satellite Mapping of Precipitation (GSMaP) Products," *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, hlm. 4463–4466, 2019, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:208034309>
- [24] Fatkhuroyan dan TrinahWati, "Accuracy Assessment of Global Satellite Mapping of Precipitation (GSMaP) Product Over Indonesian Maritime Continent," *IOP Conf Ser Earth Environ Sci*, vol. 187, 2018, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:134087743>
- [25] R. Z. Karimah, "Pemodelan spasial prediksi curah hujan melalui metode inverse distance weighting di wilayah Sumatera Barat tahun 2026," *Geomedia: Majalah Ilmiah dan Informasi Kegeografian*, vol. 22, no. 1, 2024.
- [26] R. Mahindraguna, R. H. Dananjaya, dan G. Chrismaningwang, "Validasi data hujan satelit IMERG terkalibrasi dengan metode geographically weighted regression terhadap data hujan stasiun," dalam *Proceeding Civil Engineering Research Forum*, 2023, hlm. 149–159.
- [27] W. Sulistiyono dan M. Fadli, "Verifikasi Produk Estimasi Curah Hujan GSMaP, GPM-IMERG, dan Himawari-8 Pada Wilayah Serang, Pekanbaru, dan Ambon," *OPTIKA: Jurnal Pendidikan Fisika*, 2023, Diakses: 27 Oktober 2024. [Daring]. Tersedia pada: <https://doi.org/10.37478/optika.v7i2.3119>
- [28] BMKG, "Peraturan Kepala Badan Meteorologi dan Geofisika Nomor SK.32/ TL.202/ KB/ BMG-2006 Tentang Tata Cara Tetap Pelaksanaan Pengamatan dan Pelaporan Data Iklim dan Agroklimat," Jan 2006. [Daring]. Tersedia pada: www.bmg.go.id
- [29] B. S. Wiwoho, I. S. Astuti, I. A. G. Alfarizi, dan H. R. Sucahyo, "Validation of Three Daily Satellite Rainfall Products in a Humid Tropic Watershed, Brantas, Indonesia: Implications to Land Characteristics and Hydrological Modelling," *Hydrology*, 2021, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:244604771>
- [30] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," 19 Juli 2022, *Copernicus GmbH*. doi: 10.5194/gmd-15-5481-2022.
- [31] E. Kragh dan P. A. F. Christie, "Seismic repeatability, normalized rms, and predictability," *Geophysics*, vol. 21, hlm. 640–647, 2002, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:119778607>
- [32] D. W. Pratiwi, J. Sujono, dan A. P. Rahardjo, "Evaluasi Data Hujan Satelit untuk Prediksi Data Hujan Pengamatan Menggunakan Cross Correlation," Seminar Nasional Sains dan Teknologi, 2017. [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:126541180>
- [33] C. J. Willmott dan K. Matsuura, "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance," *Clim Res*, vol. 30, hlm. 79–82, 2005, [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:120556606>
- [34] H. Abdi dan L. J. Williams, "Coefficients of Correlation , Alienation and Determination," 2006. [Daring]. Tersedia pada: <https://api.semanticscholar.org/CorpusID:13032664>
- [35] D. S. Wilks, *Statistical Methods in the Atmospheric Sciences*, Fourth Edition. Elsevier, 2006.
- [36] V. Bharti dan C. Singh, "Evaluation of error in TRMM 3B42V7 precipitation estimates over the Himalayan region," *Journal of Geophysical Research: Atmospheres*, vol. 120, no. 24, hlm. 12458–12473, 2015.
- [37] A. Gerland, A. E. S. Dengo, dan Y. D. Haryanto, "Validasi Data Model Prediksi Curah Hujan Satelit GPM, GSMaP, dan CHIRPS Selama Periode Siklon Tropis Seroja 2021 di Provinsi Nusa Tenggara Timur," *GEOGRAPHIA : Jurnal Pendidikan dan Penelitian Geografi*, vol. 4, no. 1, hlm. 44–50, Jun 2023, doi: 10.53682/gjppg.v4i1.5778.
- [38] J. Suryanto dan A. Faisol, "Validasi Curah Hujan Data TerraClimate dengan Data Pengamatan BMKG di Provinsi Kalimantan Barat," *Jurnal Pertanian Terpadu*, vol. 10, no. 1, hlm. 52–63, 2022, [Daring]. Tersedia pada: <http://ojs.stiperkutim.ac.id/index.php/jpt/article/view/395>
- [39] M. Mahrooghy, V. G. Anantharaj, N. H. Younan, J. Aanstoos, dan K.-L. Hsu, "On an enhanced PERSIANN-CCS algorithm for precipitation estimation," *J Atmos Ocean Technol*, vol. 29, no. 7, hlm. 922–932, 2012.