

Pendekatan *Peaks Over Threshold* dan *Gamma Distribution Mapping* untuk Prediksi Hujan Ekstrem Subseasonal di Jawa Timur

Muhammad Zaky Arkananta¹, Fendy Arifianto^{1*}, Sayful Amri¹, Maman Sudarisman¹

¹Program Studi Klimatologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Banten, Indonesia.

DOI: <https://doi.org/10.29303/goescienceed.v7i4.3283>

Article Info

Received : August, 12th 2026

Revised : August, 31st 2026

Accepted: September, 11th 2026

Correspondence:

Fendy Arifianto

Phone: +6282124982510

Abstract: Extreme rainfall triggers most floods and landslides in East Java, yet its predictability two to six weeks ahead is rarely tested against documented disaster events. This study evaluates the ECMWF Subseasonal to Seasonal (S2S) model in detecting extreme rainfall linked to floods and landslides in East Java during 2025. Thresholds were derived from a 95th-percentile Peaks Over Threshold approach and the Generalized Pareto Distribution at six BMKG stations (1991-2024). Control forecast output at lead times of 14, 21, 28, 35, and 42 days was corrected sequentially by wet-day correction and Gamma Distribution Mapping, with parameters built per station and lead time. BNPB disaster records were screened by rain-gauge rainfall on the event day or the preceding day and by a 30 km distance limit, then verified through contingency tables. Bias correction cut the modelled wet-day fraction from 79-83% to 37-41% and brought intensity distributions closer to observations. Nevertheless, 205 event-lead time pairs yielded only 12 hits against 83 misses. Sensitivity peaked at the 28-day lead time (POD 0.21; CSI 0.17; FAR 0.50), and all BIAS values fell below one. The corrected model still underestimates extreme rainfall and suits an early-signal role rather than a sole determinant of disaster occurrence.

Keywords: Bias Correction, Contingency Table, Extreme Value Theory, Generalized Pareto Distribution, Subseasonal Prediction.

Citation: Arkananta, M. Z., Arifianto, F., Amri, S., & Sudarisman, M. (2026). Pendekatan Peaks Over Threshold dan Gamma Distribution Mapping untuk Prediksi Hujan Ekstrem Subseasonal di Jawa Timur. *Jurnal Pendidikan, Sains, Geologi, dan Geofisika (GeoScienceEd Journal)*, 7(4), 5713–5720. <https://doi.org/10.29303/goescienceed.v7i4.3283>

Pendahuluan

Hujan dengan intensitas sangat tinggi dalam waktu singkat merupakan pemicu utama banjir dan tanah longsor di wilayah tropis maritim (Dwinanda et al., 2024). Provinsi Jawa Timur menghadapi risiko tersebut secara berulang karena kombinasi variabilitas atmosfer skala global-regional dan topografi yang beragam (Hendrawan et al., 2025; Rejeki, 2021). Selama tahun 2025, Badan Nasional Penanggulangan Bencana (BNPB) mencatat 175 kejadian banjir dan 19 kejadian tanah longsor di provinsi Jawa Timur (BNPB, 2025). Kedua jenis bencana tersebut sangat berkaitan dengan

hujan lebat, meskipun tingkat kerentanannya turut ditentukan oleh tutupan lahan, kemiringan lereng, dan kapasitas drainase (Nocentini et al., 2024; Thomas et al., 2020).

Mitigasi yang efektif membutuhkan informasi prediksi yang tersedia jauh sebelum kejadian (Kirschbaum & Stanley, 2018; White et al., 2017). Prakiraan cuaca harian memberikan gambaran atmosfer yang rinci tetapi hanya untuk beberapa hari ke depan, sedangkan prakiraan musiman hanya menggambarkan kecenderungan bulanan hingga musiman. Rentang dua minggu hingga dua bulan di antara keduanya diisi oleh

Email: fendyarifianto.ipb@gmail.com

prediksi *Subseasonal to Seasonal* (S2S) yang dikembangkan untuk menghubungkan kesenjangan tersebut (Mariotti et al., 2018; Vitart et al., 2017).

Sejumlah studi menunjukkan bahwa model S2S mampu menangkap pola umum hujan ekstrem. Zheng et al. (2023) menemukan bahwa sebagian besar model dalam basis data S2S dapat memprediksi pola spasial akumulasi hujan ekstrem di Provinsi Henan satu hingga empat minggu sebelum kejadian, meskipun tingkat keparahannya tetap bersifat *underestimate*. Vuillaume et al. (2018) memperlihatkan potensi prediksi hujan ekstrem subseasonal di DAS Kelani, Sri Lanka, dengan memanfaatkan klasifikasi pola atmosfer. Di Indonesia, Reyhan (2024) menemukan bahwa model S2S ECMWF merepresentasikan variabilitas hujan ekstrem di Sumatera Barat dengan lebih baik pada skala bulanan setelah koreksi bias, tetapi masih meremehkan indeks R95p dan R99p. Pham-Thanh et al. (2022) serta Zhang et al. (2021) menegaskan bahwa keterampilan prediksi S2S menurun dan berfluktuasi seiring bertambahnya *lead time*.


Meskipun demikian, sebagian besar evaluasi tersebut berhenti pada perbandingan statistik antara model dan observasi, misalnya melalui korelasi atau indeks ekstrem agregat. Verifikasi yang menautkan luaran model secara langsung dengan kejadian bencana tercatat masih jarang dilakukan. Definisi hujan ekstrem juga kerap diseragamkan untuk satu wilayah luas sehingga mengabaikan perbedaan karakteristik antar lokasi (Langousis et al., 2016; Solari & Losada, 2012). Selain itu, koreksi bias sering difokuskan pada intensitas tanpa lebih dahulu memperbaiki frekuensi hari hujan, padahal model beresolusi kasar cenderung menghasilkan hujan ringan secara berlebihan (Ayedun & Abiodun, 2026; Lazoglou et al., 2024).

Penelitian ini tidak hanya mengevaluasi kemampuan model *Subseasonal to Seasonal* (S2S) ECMWF dalam mendeteksi hujan ekstrem secara statistik, tetapi juga menghubungkan hasil deteksi tersebut secara langsung dengan kejadian banjir dan tanah longsor di Jawa Timur tahun 2025. Dengan demikian, penelitian ini mampu memberikan gambaran yang lebih menyeluruh mengenai keterkaitan antara karakteristik hujan ekstrem lokal, efektivitas koreksi bias model, dan kemampuan model dalam memberikan sinyal dini terhadap risiko bencana pada berbagai *lead time*. Oleh karena itu, tujuan penelitian ini adalah untuk: (1) menganalisis karakteristik ambang hujan ekstrem di Jawa Timur berdasarkan pendekatan *Peaks Over Threshold* (POT); (2) mengevaluasi efektivitas koreksi bias dua tahap, yaitu *wet-day correction* yang dilanjutkan dengan *Gamma Distribution Mapping* (GDM) dalam memperbaiki distribusi curah hujan model S2S ECMWF; dan (3) mengidentifikasi kemampuan model S2S

ECMWF dalam mendeteksi kejadian hujan ekstrem yang berkaitan dengan bencana banjir dan tanah longsor pada *lead time* 14, 21, 28, 35, dan 42 hari.

Metode

Penelitian dilakukan di Provinsi Jawa Timur yang mencakup daratan utama dan Pulau Madura. Empat kelompok data digunakan, yaitu (1) curah hujan harian sepuluh stasiun BMKG di Jawa Timur periode 1991-2024 sebagai dasar klimatologis; (2) model S2S ECMWF variabel *total precipitation* (tp) jenis *control forecast* (cf) tahun 2025 yang diunduh dari Climate Data Store melalui API pada grid penyajian 0,05°; (3) catatan kejadian bencana tahun 2025 dari Geoportal Data Bencana Indonesia (BNPB, 2025); serta (4) curah hujan harian 2025 dari 1.039 pos hujan BMKG yang berfungsi sebagai observasi di sekitar lokasi bencana. Seluruh pengolahan dilakukan dengan Python 3.12 pada lingkungan Linux, sedangkan penyajian peta menggunakan ArcMap 10.8. Peta wilayah penelitian disajikan pada Gambar 1.



Gambar 1. Peta wilayah kajian dan sebaran stasiun pengamatan BMKG di Jawa Timur

Ambang hujan ekstrem ditetapkan secara terpisah pada setiap stasiun menggunakan pendekatan POT pada persentil ke-95 dari seluruh hari (*all-day percentile*). Pendekatan ini dipilih agar tingkat kelangkaan dihitung terhadap keseluruhan periode pengamatan antar lokasi yang memiliki frekuensi hari hujan berbeda tetap sebanding (Solari & Losada, 2012). Ambang tersebut dinyatakan sebagai P95, dan curah hujan yang melampauinya dihitung sebagai lampauan (*excess*) melalui persamaan berikut:

$$y_i = x_i - u, \quad x_i > u$$

Nilai lampauan dimodelkan dengan GPD parameter skala σ yang menggambarkan penyebaran lampauan dan parameter bentuk ξ yang menggambarkan perilaku ekor distribusi (Singirankabo

& Iyamuremye, 2022). Parameter tersebut diestimasi menggunakan *Maximum Likelihood Estimation* (MLE). Kesesuaian GPD diperiksa melalui uji Kolmogorov-Smirnov (KS) *parametric bootstrap* sebanyak 2.000 iterasi. (Healy et al., 2025). Hipotesis nol ditolak apabila nilai peluang *bootstrap* tidak lebih besar dari 0,05. Pemeriksaan dilengkapi QQ plot dan perbandingan fungsi distribusi kumulatif. Penetapan stasiun terpilih tidak hanya mengandalkan hasil uji tersebut, tetapi juga mempertimbangkan kelengkapan dan kesinambungan rekaman, kecukupan jumlah lampauan, serta keterwakilan spasial lokasi stasiun terhadap *grid* model S2S.

Curah hujan model S2S pada awalnya merupakan nilai akumulasi sejak tanggal inialisasi. Sehingga perlu dilakukan proses dekumulasi terlebih dahulu menjadi curah hujan harian, yaitu selisih akumulasi pada dua waktu prakiraan berurutan sebagaimana persamaan berikut:

$$CH_t = CH_{acc,t} - CH_{acc,t-1}$$

Hasil dekumulasi disusun menurut tanggal inialisasi, *lead time*, dan tanggal target, kemudian diekstraksi pada titik *grid* terdekat dengan koordinat sasaran. Ekstraksi dilakukan pada dua kelompok titik dengan fungsi berbeda: pada stasiun BMKG untuk membentuk parameter koreksi bias, dan pada koordinat setiap kejadian bencana untuk memperoleh nilai yang akan diverifikasi.

Koreksi bias dijalankan dalam dua tahap. Tahap pertama adalah *wet-day correction* yang digunakan untuk menyesuaikan frekuensi hari hujan. Fraksi hari hujan observasi dihitung dari data 1991-2024 dengan batas hari hujan 0,5 mm, lalu digunakan untuk menentukan *cutoff* hari hujan model S2S. Nilai model di bawah *cutoff* dinyatakan sebagai hari tanpa hujan sehingga kecenderungan model menghasilkan *drizzle* dapat berkurang (Ayedun & Abiodun, 2026). Tahap kedua adalah koreksi intensitas melalui *Gamma Distribution Mapping*. Distribusi *Gamma* dicocokkan secara terpisah pada observasi dan model. Distribusi observasi dibentuk dari curah hujan $\geq 0,5$ mm periode 1991-2024 dan hanya dibedakan menurut stasiun, sedangkan distribusi model dibentuk dari seluruh nilai model setelah *wet-day correction* dan dibedakan menurut kombinasi stasiun dan *lead time*. Kombinasi enam stasiun dan lima *lead time* menghasilkan 30 set parameter model. Nilai model yang lolos *cutoff* diterapkan pada invers fungsi distribusi kumulatif observasi mengikuti pendekatan Piani et al. (2010) yang konsisten dengan kajian pembandingan metode koreksi bias oleh Holthuijzen et al. (2021).

$$x_{bc} = F_{obs}^{-1} [F_{mod} (x_{wd})]$$

Nilai yang berada di bawah *cutoff* tetap bernilai 0 mm dan tidak dipetakan melalui distribusi *Gamma*. Parameter koreksi hanya dibentuk di stasiun BMKG karena memiliki rekaman jangka panjang sebagai distribusi acuan. Parameter tersebut kemudian diterapkan ke *grid* lokasi bencana dengan batas jarak 30 km.

Catatan bencana BNPB tahun 2025 diseragamkan lokasinya dan diubah menjadi koordinat geografis melalui *geocoding*, kemudian disaring menurut jenis sehingga hanya banjir dan tanah longsor yang dipertahankan. Setiap titik bencana dipasangkan dengan pos hujan terdekat, lalu diperiksa keberadaan hujan pada hari kejadian (H) dan sehari sebelumnya (H-1). Kejadian dipertahankan apabila terdapat curah hujan sekurang-kurangnya 0,5 mm pada salah satu dari kedua hari tersebut. Kriteria ini hanya menguji keberadaan hujan, bukan menentukan status ekstremnya. Nilai terbesar di antara keduanya ditetapkan sebagai curah hujan acuan (CH_{maks}) dan hari terjadinya ditetapkan sebagai tanggal acuan.

Kejadian yang lolos penyaringan dipasangkan dengan satu stasiun BMKG terpilih terdekat dengan batas maksimum 30 km. Batas tersebut membatasi ketidakpastian ketika ambang P95 dan parameter koreksi bias stasiun diterapkan pada lokasi kejadian. Tanggal inialisasi model untuk setiap *lead time* (LT) dihitung mundur dari tanggal acuan agar tanggal target model identik dengan tanggal observasi acuan.

$$t_{init,LT} = t_{acuan} - LT$$

Observasi dikategorikan ekstrem apabila CH_{maks} melampaui ambang P95 stasiun acuan, dan model dikategorikan ekstrem apabila curah hujan terkoreksi melampaui ambang yang sama. Penggunaan ambang yang sama tersebut menjaga konsistensi definisi kejadian pada kedua sisi perbandingan. Nilai yang tepat sama dengan P95 digolongkan tidak ekstrem karena POT mendefinisikan ekstrem sebagai nilai yang melampaui ambang. Perbandingan kedua kategori membentuk tabel kontingensi dengan komponen *hit* (H), *miss* (M), *false alarm* (F), dan *correct negative* (C), yang selanjutnya diringkas melalui lima metrik pada (Coelho et al., 2026; Wilks, 2019).

$$POD = H / (H + M)$$

$$FAR = F / (H + F)$$

$$CSI = H / (H + F + M)$$

$$BIAS = (H + F) / (H + M)$$

$$PSS = H / (H + M) - F / (F + C)$$

Kelima metrik dihitung terpisah untuk setiap *lead time* menggunakan kumpulan kejadian yang sama. Kategori tidak diinterpolasi karena analisis bersifat titik,


sehingga satu lokasi dapat memiliki kategori berbeda pada *lead time* yang berbeda.

Hasil dan Diskusi

Hasil penelitian ini diuraikan dalam beberapa sub pembahasan yang disusun berdasarkan fokus penelitian, yaitu:

Ambang hujan ekstrem dan penetapan stasiun


Ambang P95 sepuluh stasiun kandidat berkisar antara 23,8 hingga 55 mm/hari. Nilai tertinggi ditemukan di Stasiun Geofisika Pasuruan, sedangkan nilai terendah di Stasiun Meteorologi Banyuwangi. Rentang yang lebar tersebut menunjukkan bahwa satu ambang seragam untuk seluruh Jawa Timur tidak bisa diterapkan. Ambang yang terlalu rendah membuat hujan biasa di stasiun berambang tinggi ikut tergolong ekstrem, sedangkan ambang yang terlalu tinggi menghapus kejadian ekstrem di stasiun berambang rendah. Temuan ini sejalan dengan penekanan Langousis et al. (2016) mengenai pentingnya pemilihan ambang yang spesifik lokasi.



Gambar 2. Ambang persentil ke-95 (P95) pada seluruh stasiun BMKG di Jawa Timur

Pemodelan GPD menghasilkan parameter skala 16,68-27,53 mm dan parameter bentuk -0,121 hingga 0,199. Sebagian besar parameter bentuk berada dekat nol sehingga ekor lampauan cenderung mendekati bentuk eksponensial, dengan Banyuwangi sebagai satu-satunya stasiun berekor relatif berat. Uji Kolmogorov-Smirnov berbasis *parametric bootstrap* menolak kecocokan GPD pada Stasiun Geofisika Sawahan ($p = 0,0025$) dan Stasiun Meteorologi Perak II ($p = 0,0190$), sedangkan delapan stasiun lain menghasilkan nilai p 0,0675-0,4418. Meskipun begitu, Stasiun Meteorologi Tuban dikeluarkan karena kelengkapan datanya hanya 11,8% sehingga hanya menghasilkan 73 lampauan, dan Stasiun Meteorologi Sangkapura dikeluarkan karena berada di Pulau Bawean yang *grid* model S2S terdekatnya didominasi permukaan laut. Enam stasiun akhirnya ditetapkan, yaitu Stasiun Klimatologi Jawa Timur, Stasiun Meteorologi Banyuwangi, Stasiun Geofisika Pasuruan, Stasiun Meteorologi Juanda,


Stasiun Meteorologi Trunojoyo, dan Stasiun Meteorologi Tanjung Perak.



Gambar 3. Hasil uji Kolmogorov-Smirnov *parametric bootstrap* pada seluruh stasiun BMKG di Jawa Timur

Kinerja koreksi bias dua tahap


Sebelum dikoreksi, model S2S menghasilkan hari hujan jauh lebih sering daripada observasi. Di Stasiun Klimatologi Jawa Timur, fraksi hari hujan model mencapai 79-83%, hampir dua kali lipat klimatologi observasi sebesar 42%. Setelah *wet-day correction*, fraksi tersebut turun menjadi 37-41% dan mendekati nilai acuan. Nilai *cutoff* yang diperlukan berbeda-beda antar lokasi, berkisar 4,38-10,39 mm/hari, dengan nilai terendah di Banyuwangi dan tertinggi di Tanjung Perak serta Juanda. Perbedaan ini menegaskan bahwa besarnya hujan ringan berlebih tidak seragam, sehingga satu *cutoff* tunggal akan memangkas terlalu banyak nilai di satu lokasi sekaligus menyisakan *drizzle* di lokasi lain.



Gambar 4. Nilai *cutoff wet-day correction* dan perubahan fraksi hari hujan model

Tahap *Gamma Distribution Mapping* memperbaiki distribusi intensitas. Pada Stasiun Meteorologi Trunojoyo *lead time* 14, statistik Kolmogorov-Smirnov terhadap distribusi observasi turun dari 0,5589 menjadi 0,0959, dan QQ plot memperlihatkan kuantil model bergerak mendekati garis 1:1 terutama pada intensitas menengah hingga tinggi yang sebelumnya direpresentasikan terlalu

rendah. Secara keseluruhan, rentang bias rata-rata pada enam stasiun menyempit dari -4,86 hingga +2,15 mm/hari sebelum koreksi menjadi -2,62 hingga -0,30 mm/hari sesudah koreksi. Penyempitan tersebut menunjukkan variasi antar stasiun berkurang, meskipun nilai yang seluruhnya negatif menandakan model terkoreksi masih sedikit lebih rendah daripada observasi 2025.



Gambar 5. Fungsi distribusi kumulatif dan QQ plot curah hujan S25 sebelum dan sesudah koreksi bias di Stasiun Meteorologi Trunojoyo pada *lead time* 14

Pada kuantil tertinggi, sebagian titik hasil koreksi belum tepat mengikuti garis 1:1, sehingga bias pada kejadian paling ekstrem belum sepenuhnya hilang. Deret harian juga memperlihatkan bahwa sejumlah puncak model terkoreksi tidak bertepatan dengan puncak observasi. Hal ini konsisten dengan temuan Michalek et al. (2024) dan Howard et al. (2023) bahwa koreksi bias statistik memperbaiki karakteristik distribusi tanpa menjamin ketepatan waktu kejadian.

Penyaringan kejadian banjir dan tanah longsor


Dari 226 catatan bencana BNPB di Jawa Timur tahun 2025, sebanyak 194 kejadian merupakan banjir dan tanah longsor. Penyaringan berdasarkan keberadaan hujan pos hujan pada H atau H-1 mempertahankan 170 kejadian, sedangkan 24 kejadian lainnya dikeluarkan karena tidak ditemukan hujan pada kedua hari tersebut. Kejadian yang tersaring dapat berkaitan dengan banjir kiriman, kerusakan infrastruktur pengendali air, atau keterbatasan representasi pos hujan.

Tabel 1. Penyaringan kejadian bencana berdasarkan keberadaan hujan pada H dan H-1

Jenis bencana	Kejadian awal	Disertai hujan	Tidak disertai hujan
Banjir	175	153	22
Tanah longsor	19	17	2
Total	194	170	24

Pembatasan jarak 30 km terhadap stasiun BMKG terpilih menyisakan 41 kejadian yang terdiri atas 37 banjir dan 4 tanah longsor, sedangkan 129 kejadian

berada di luar radius. Besarnya jumlah kejadian yang tersisih menegaskan bahwa cakupan verifikasi bersifat lokal di sekitar enam stasiun dan belum merepresentasikan seluruh kejadian bencana di Jawa Timur. Dengan lima *lead time*, 41 kejadian tersebut membentuk 205 pasangan kejadian-*lead time* yang menjadi populasi verifikasi, terdiri atas 19 kejadian berkategori hujan ekstrem dan 22 kejadian tidak ekstrem.



Gambar 6. Sebaran kejadian banjir dan tanah longsor dalam radius 30 km dari stasiun BMKG terpilih

Kemampuan deteksi hujan ekstrem

Secara keseluruhan, 205 pasangan *lead time* menghasilkan 12 *hit*, 83 *miss*, 9 *false alarm*, dan 101 *correct negative*. Dari 95 pasangan dengan observasi ekstrem, hanya 12 yang berhasil ditangkap model. Komposisi ini menunjukkan bahwa kesalahan utama model bukan kecenderungan memberi peringatan berlebih, melainkan kegagalan menangkap kejadian yang benar-benar terjadi. Hasil per *lead time* disajikan pada Tabel 2 berikut.

Tabel 2. Hasil verifikasi kemampuan deteksi model S2S terkoreksi pada setiap *lead time*


<i>Lead Time</i>	H / F / M / C	POD	FAR	CSI	BIA S	PSS
14	3 / 1 / 16 / 21	0,16	0,25	0,15	0,21	0,11
21	2 / 2 / 17 / 20	0,11	0,50	0,10	0,21	0,01
28	4 / 4 / 15 / 18	0,21	0,50	0,17	0,42	0,03
28	0 / 1 / 19 / 21	0,00	1,00	0,00	0,05	-0,05
42	3 / 1 / 16 / 21	0,16	0,25	0,15	0,21	0,11

Keterangan: H = *hit*; F = *false alarm*; M = *miss*; C = *correct negative*.

Sensitivitas tertinggi terjadi pada *lead time* 28 hari dengan POD 0,21 dan CSI 0,17. Karena itu PSS pada *lead time* tersebut justru rendah yaitu 0,03, lebih kecil daripada *lead time* 14 dan 42 hari yang sama-sama mencapai 0,11. Kondisi terburuk terjadi pada *lead time* 35 hari ketika tidak satu pun dari 19 observasi ekstrem terdeteksi, sehingga POD dan CSI bernilai nol dan PSS menjadi negatif. Seluruh nilai BIAS berada di bawah satu (0,05-0,42), yang berarti model secara konsisten

memprediksi kejadian ekstrem lebih jarang daripada kenyataan.

Pola metrik tidak menurun secara teratur seiring bertambahnya *lead time*. Kemampuan yang sempat hilang sama sekali pada 35 hari muncul kembali pada 42 hari, dan hal serupa dilaporkan Zhang et al. (2021) yang menemukan bahwa keterampilan S2S berfluktuasi antar rentang prakiraan. Fluktuasi ini juga perlu dibaca dengan hati-hati mengingat ukuran sampel yang kecil. Perubahan satu atau dua kejadian dapat menggeser nilai metrik secara mencolok.



Gambar 7. Sebaran kategori verifikasi model S2S pada seluruh *lead time*

Rendahnya kemampuan deteksi dapat dibuktikan terhadap beberapa sumber. Model S2S dikembangkan dari *General Circulation Model* beresolusi kasar yang sulit merepresentasikan konveksi lokal di Benua Maritim, sehingga intensitas puncak cenderung diratakan (Howard et al., 2023; Manzananas et al., 2019). Koreksi bias memperbaiki bentuk distribusi tetapi tidak menggeser waktu kejadian, sehingga hujan ekstrem yang tersimulasi pada tanggal keliru tetap terhitung sebagai *miss* (Michalek et al., 2024).

Ukuran sampel yang terbatas turut mempengaruhi besarnya proporsi *miss*. Informasi S2S sebaiknya diposisikan sebagai sinyal peningkatan risiko pada rentang mingguan yang dikombinasikan dengan prakiraan jangka pendek dan informasi hidrologis, bukan sebagai penentu tunggal waktu dan lokasi bencana (White et al., 2017).

Kesimpulan

Ambang hujan ekstrem di Jawa Timur terbukti bersifat lokal, berkisar 23,8 hingga 55 mm/hari, sehingga penetapannya perlu dilakukan per stasiun dan bukan secara seragam untuk satu provinsi. Dari sepuluh stasiun kandidat, hanya enam yang memenuhi gabungan kriteria kelengkapan rekaman, kecocokan GPD melalui *parametric bootstrap*, dan keterwakilan

spasial terhadap *grid* model. Koreksi bias dua tahap bekerja sebagaimana dirancang: *wet-day correction* menurunkan fraksi hari hujan model dari 79-83% menjadi 37-41%, sedangkan *Gamma Distribution Mapping* memangkas jarak distribusi terhadap observasi hingga statistik Kolmogorov-Smirnov turun dari 0,5589 menjadi 0,0959 pada kasus contoh, meski bias pada kuantil tertinggi belum sepenuhnya hilang.

Dari 205 pasangan kejadian-*lead time*, model hanya menghasilkan 12 *hit* berbanding 83 *miss*, dengan sensitivitas tertinggi pada *lead time* 28 hari (POD 0,21; CSI 0,17) yang justru disertai FAR 0,50, dan kegagalan total pada *lead time* 35 hari. Seluruh nilai BIAS di bawah satu menegaskan kecenderungan model meremehkan frekuensi kejadian ekstrem (*underestimate*). Dengan demikian, model S2S ECMWF terkoreksi belum dapat diandalkan sebagai dasar tunggal peringatan dini banjir dan longsor, tetapi tetap bernilai sebagai sinyal awal peningkatan risiko yang perlu dipadukan dengan prakiraan jangka pendek dan informasi kerentanan wilayah. Penelitian lanjutan disarankan menggunakan *reforecast* untuk pembentukan parameter koreksi, mempertimbangkan akumulasi hujan beberapa hari sebelum kejadian, serta memanfaatkan anggota *perturbed forecast* untuk verifikasi probabilistik.

Ucapan Terima Kasih

Penulis mengucapkan puji syukur kepada Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan dengan baik. Ucapan terimakasih disampaikan kepada Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, dosen pembimbing, serta seluruh pihak yang mendukung dan berkontribusi selama proses penyusunan artikel ini. Semoga hasil penelitian ini dapat memberikan kontribusi terhadap ilmu pengetahuan di bidang klimatologi dan menyediakan data bagi pemerintah untuk menyusun kebijakan terkait mitigasi bencana banjir dan longsor.

Referensi

- Ayedun, R. F., & Abiodun, B. J. (2026). Assessing the impact of the NEX-GDDP CMIP6 bias correction on crop yield simulations across Africa. *Theoretical and Applied Climatology*, 157(9), 548.
- BNPB. (2025). *Geoportal Data Bencana Indonesia*. Badan Nasional Penanggulangan Bencana. <https://gis.bnpb.go.id/>
- Coelho, C. A. S., Junior, F. C. V., Cardoso, D. H., Martins, E. S. P. R., & Guimarães, B. S. (2026). Verification of Calibrated Multimodel Subseasonal Precipitation Predictions Cascaded From Global to Regional Scale Over Ceará State in Brazil. *Meteorological*

- Applications*, 33(2), e70179.
- Dwinanda, I. G., Adelia, K. A. C., Wilda, R. W., Afli, F., Kaloka, T. P., & Pratiwie, D. L. (2024). Predictive Mapping of Hydrometeorological Disaster Prone Areas in Central Kalimantan. *Jurnal Penelitian Pendidikan IPA*.
<https://doi.org/10.29303/jppipa.v10i2.6238>
- Healy, D., Prosdocimi, I., & Antoniano-Villalobos, I. (2025). Non-Stationarities in Extreme Hourly Precipitation Over the Piave Basin, Northern Italy. *Environmetrics*, 36(8), e70051.
- Hendrawan, V. S. A., Rahardjo, A. P., Mawandha, H. G., Aldrian, E., Muhari, A., & Komori, D. (2025). Past and future climate-related hazards in Indonesia. *EGUsphere*, 2025, 1-34.
- Holthuijzen, M. F., Beckage, B., Clemins, P. J., Higdon, D., & Winter, J. M. (2021). Constructing high-resolution, bias-corrected climate products: a comparison of methods. *Journal of Applied Meteorology and Climatology*, 60(4), 455-475.
- Howard, E., Woolnough, S., Klingaman, N., Shipley, D., Sanchez, C., Peatman, S. C., ... & Matthews, A. J. (2023). Evaluation of multi-season convection permitting atmosphere-mixed layer ocean simulations of the Maritime Continent. *Geoscientific Model Development Discussions*, 2023, 1-32.
- Jiang, Y., Hu, X., Liang, H., Ning, P., & Fan, X. (2023). A physically based model for the sequential evolution analysis of rainfall-induced shallow landslides in a catchment. *Water Resources Research*, 59(5), e2022WR032716.
- Kirschbaum, D., & Stanley, T. (2018). Satellite-based assessment of rainfall-triggered landslide hazard for situational awareness. *Earth's Future*, 6(3), 505-523.
- Langousis, A., Mamalakis, A., Puliga, M., & Deidda, R. (2016). Threshold detection for the generalized Pareto distribution: Review of representative methods and application to the NOAA NCDC daily rainfall database. *Water Resources Research*, 52(4), 2659-2681.
- Lazoglou, G., Economou, T., Anagnostopoulou, C., Tzyrkalli, A., Zittis, G., & Lelieveld, J. (2024). Bias correction of daily precipitation from climate models, using the Q-GAM method. *Environmetrics*, 35(7), e2881.
- Manzanas, R., Gutiérrez, J., Bhend, J., Hemri, S., Doblas-Reyes, F., Torralba, V., Penabad, E., & Brookshaw, A. (2019). Bias adjustment and ensemble recalibration methods for seasonal forecasting: a comprehensive intercomparison using the C3S dataset. *Climate Dynamics*, 1-19.
<https://doi.org/10.1007/s00382-019-04640-4>
- Mariotti, A., Ruti, P. M., & Rixen, M. (2018). Progress in subseasonal to seasonal prediction through a joint weather and climate community effort. *Npj Climate and Atmospheric Science*, 1(1), 4.
- Michalek, A. T., Villarini, G., & Kim, T. (2024). Understanding the impact of precipitation bias-correction and statistical downscaling methods on projected changes in flood extremes. *Earth's Future*, 12(3), e2023EF004179.
- Nocentini, N., Medici, C., Barbadori, F., Gatto, A., Franceschini, R., Del Soldato, M., ... & Segoni, S. (2024). Optimization of rainfall thresholds for landslide early warning through false alarm reduction and a multi-source validation: Optimization of rainfall thresholds. *Landslides*, 21(3), 557-571.
- Pham-Thanh, H., Phan-Van, T., van der Linden, R., & Fink, A. H. (2022). The performance of ECMWF subseasonal forecasts to predict the rainy season onset dates in Vietnam. *Weather and Forecasting*, 37(1), 113-124.
- Piani, C., Haerter, J., & Coppola, E. (2010). Statistical bias correction for daily precipitation in regional climate models over Europe. *Theoretical and Applied Climatology*, 99, 187-192.
<https://doi.org/10.1007/s00704-009-0134-9>
- Rejeki, H. A. (2021). Keterkaitan Periodisitas Curah Hujan Di Daerah Pesisir Dan Pegunungan Provinsi Jawa Timur Dengan Variabilitas Cuaca Skala Global Dan Regional. *Jurnal Sains & Teknologi Modifikasi Cuaca*.
<https://doi.org/10.29122/jstmc.v22i2.4422>
- Reyhan, C. (2024). Evaluasi Luaran Model S2S (Subseasonal To Seasonal) Ecmwf Dalam Menangkap Variabilitas Hujan Ekstrem Di Sumatera Barat. *Megasains*.
<https://doi.org/10.46824/megasains.v14i2.137>
- Singirankabo, E., & Iyamuremye, E. (2022). Modelling extreme rainfall events in Kigali city using generalized Pareto distribution. *Meteorological Applications*, 29(4), e2076.
- Solari, S., & Losada, M. A. (2012). A unified statistical model for hydrological variables including the selection of threshold for the peak over threshold method. *Water Resources Research*, 48(10).
- Thomas, M. A., Mirus, B. B., & Smith, J. B. (2020). Hillslopes in humid-tropical climates aren't always

- wet: Implications for hydrologic response and landslide initiation in Puerto Rico. *Hydrological Processes*, 34(22), 4307–4318.
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., Déqué, M., Ferranti, L., Fucile, E., & Fuentes, M. (2017). The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1), 163–173.
- Vuillaume, J.-F., Dorji, S., Komolafe, A., Komolafe, A., & Herath, S. (2018). Sub-seasonal extreme rainfall prediction in the Kelani River basin of Sri Lanka by using self-organizing map classification. *Natural Hazards*, 94, 385–404. <https://doi.org/10.1007/s11069-018-3394-9>
- White, C. J., Carlsen, H., Robertson, A. W., Klein, R. J. T., Lazo, J. K., Kumar, A., Vitart, F., Coughlan de Perez, E., Ray, A. J., & Murray, V. (2017). Potential applications of subseasonal-to-seasonal (S2S) predictions. *Meteorological Applications*, 24(3), 315–325.
- Wilks, D. S. (2019). *Statistical methods in the atmospheric sciences* (4th ed.). Elsevier.
- Zhang, L., Kim, T., Yang, T., Hong, Y., & Zhu, Q. (2021). Evaluation of Subseasonal-to-Seasonal (S2S) Precipitation Forecast from the North American Multi-Model Ensemble Phase II (NMME-2) over the contiguous U.S. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2021.127058>
- Zheng, L., Li, T., & Liu, D. (2023). Evaluation of sub-seasonal prediction skill for an extreme precipitation event in Henan province, China. *Frontiers in Earth Science*. <https://doi.org/10.3389/feart.2023.1241202>