Sistemasi: Jurnal Sistem Informasi ISSN:2302-8149
Volume 15, Nomor 10, 2026: 4327-4344 e-ISSN:2540-9719

Perbandingan *ConvLSTM*, *ConvLSTM Temporal Embedding*, dan *3D CNN* untuk Prediksi Curah Hujan Bulanan di Bekasi dan Sekitarnya

Comparison of ConvLSTM, ConvLSTM with Temporal Embedding, and 3D CNN for Monthly Rainfall Prediction in Bekasi and Surroundings Areas

[1]Niken Wahyuni*, [2]Kahfi Heryandi Suradiradja, [3]Ahmad Musyafa
[1,2,3]Magister Teknik Informatika, Program Pascasarjana, Universitas Pamulang
[1,2,3]Jl. Raya Puspitek, Buaran, Kec. Pamulang, Kota Tangerang Selatan, Banten 15310, Indonesia
e-mail: nikenwahyuni01@gmail.com*

(***received*:** 28 September 2026, ***revised*:** 25 October 2026, ***accepted*:** 27 October 2026)

Abstrak

Curah hujan bulanan wilayah tropis memiliki variabilitas spasio-temporal yang kompleks sehingga model perlu mempelajari heterogenitas spasial dan pola temporal secara bersamaan. Penelitian ini membandingkan ConvLSTM, ConvLSTM dengan Temporal Embedding dan 3D CNN untuk prediksi curah hujan bulanan berbasis CHIRPS v2.0 (1990–2025) pada domain grid 20×20 (5,75°–6,75° LS; 106,5°–107,5° BT) yang mencakup Bekasi dan sekitarnya. Dua belas peta bulanan digunakan untuk memprediksi peta bulan berikutnya dengan pembagian waktu, horizon, dan metrik yang sama. Tuning mencakup jumlah filter, learning rate, batch size, metode penskalaan, dan recurrent dropout hanya diuji pada model rekuren. ConvLSTM-TE menambahkan representasi kalender 16 dimensi dari embedding bulan dan musim serta fitur sinus–kosinus. Klimatologi dan persistensi digunakan sebagai pembanding sederhana. Pada domain 400 grid, konfigurasi terbaik ConvLSTM-TE yang dipilih berdasarkan RMSE data uji menghasilkan RMSE 82,368 mm/bulan, MAE 59,024 mm/bulan, r = 0,868, R^2 = 75,25%, dan RSR = 0,497, diikuti ConvLSTM (RMSE 86,048 mm/bulan) dan 3D CNN (RMSE 96,347 mm/bulan). Ketiga model lebih akurat daripada persistensi (RMSE 125,639 mm/bulan), tetapi hanya kedua model berbasis ConvLSTM yang melampaui klimatologi (RMSE 88,336 mm/bulan), dengan skill score RMSE 6,8% untuk ConvLSTM-TE dan 2,6% untuk ConvLSTM. ConvLSTM-TE juga memiliki median RMSE terendah dari 92 pelatihan dan tetap memiliki RMSE terendah pada seleksi berbasis validation loss, tetapi selisihnya terhadap ConvLSTM kecil. Model mempertahankan gradien spasial dan fase musiman, tetapi menghaluskan curah hujan ekstrem. Evaluasi independen ConvLSTM-TE terhadap CHIRPS Januari–Juni 2026 menghasilkan rata-rata galat absolut 57,15 mm/bulan, sebanding dengan data uji. Model terpilih diimplementasikan dalam prototipe Streamlit untuk visualisasi.

Kata kunci: 3D CNN, ConvLSTM, *deep learning* spasio-temporal, prediksi curah hujan bulanan, *temporal embedding*.

Abstract

Monthly rainfall in tropical regions exhibits complex spatiotemporal variability, requiring models to simultaneously capture spatial heterogeneity and temporal patterns. This study compares ConvLSTM, ConvLSTM with Temporal Embedding (ConvLSTM-TE), and 3D CNN for monthly rainfall prediction using CHIRPS v2.0 data (1990–2025) over a 20 × 20 grid domain (5.75°–6.75° S; 106.5°–107.5° E) covering Bekasi and its surrounding areas. Twelve monthly rainfall maps were used to predict the subsequent month's rainfall map, with consistent temporal splits, forecast horizons, and evaluation metrics across all models. Hyperparameter tuning covered the number of filters, learning rate, batch size, scaling methods, and recurrent dropout, the latter being tested only for recurrent models. ConvLSTM-TE incorporates a 16-dimensional calendar representation derived from month and season embeddings, along with sine–cosine features. Climatology and persistence were used as baseline benchmarks. Across the 400-grid domain, the best ConvLSTM-TE configuration, selected based on test-set RMSE, achieved an RMSE of 82.368 mm/month, an MAE of 59.024 mm/month, a correlation coefficient (r) of 0.868, an R^2 of 75.25%, and an RSR of 0.497. It was followed by

 ISSN:2302-8149
e-ISSN:2540-9719

ConvLSTM (RMSE: 86.048 mm/month) and 3D CNN (RMSE: 96.347 mm/month). All three models outperformed persistence (RMSE: 125.639 mm/month), but only the two ConvLSTM-based models outperformed climatology (RMSE: 88.336 mm/month), achieving RMSE skill scores of 6.8% for ConvLSTM-TE and 2.6% for ConvLSTM. ConvLSTM-TE also achieved the lowest median RMSE across 92 training runs and retained the lowest RMSE under validation-loss-based model selection, although its performance advantage over ConvLSTM was marginal. The models preserved spatial gradients and seasonal phases but tended to smooth extreme rainfall events. An independent evaluation of ConvLSTM-TE against CHIRPS data for January–June 2026 yielded a mean absolute error of 57.15 mm/month, comparable to its test-set performance. The selected model was implemented in a Streamlit prototype for visualization.
Keywords: *3D CNN, ConvLSTM, monthly rainfall prediction, spatiotemporal deep learning, temporal embedding.*

1 Pendahuluan

Prediksi curah hujan bulanan memiliki peran penting dalam pengelolaan sumber daya air, perencanaan pertanian, dan pengurangan risiko bencana, terutama di wilayah tropis yang intensitas hujannya berubah kuat menurut musim dan lokasi. Proyeksi iklim menunjukkan bahwa Pulau Jawa berpotensi menghadapi hujan ekstrem yang lebih intens pada musim basah sekaligus hari tanpa hujan lebih panjang pada periode kering [1], [2]. Curah hujan juga memiliki keterkaitan spasial antarlokasi yang sering tidak terwakili oleh model berbasis satu titik [3]. Bekasi dipilih sebagai wilayah kajian karena perkembangan kawasan metropolitan, suburbanisasi, dan industrialisasi telah membentuk penggunaan lahan yang beragam serta meningkatkan tekanan terhadap tata air wilayah [4]. Data BNPB mencatat 39 kejadian banjir dan cuaca ekstrem terjadi di Kota Bekasi serta 108 bencana hidrometeorologi dengan 8 kejadian kekeringan di Kabupaten Bekasi selama 2020–2025 [5].

Ketersediaan observasi permukaan yang tidak merata membatasi pemodelan hujan berbasis titik. Penelitian ini menggunakan CHIRPS karena menyediakan deret curah hujan jangka panjang dalam bentuk grid yang konsisten secara spasial. Pemanfaatan CHIRPS untuk Pulau Jawa juga telah menunjukkan keterkaitan yang baik dengan observasi [6]. Bentuk raster ini mempertahankan variasi antarbagian wilayah pada setiap waktu pengamatan, tetapi keluaran model tetap ditafsirkan sebagai reproduksi pola CHIRPS, bukan pengganti seluruh pengamatan permukaan.

Pada skala bulanan, metode statistik dan pembelajaran mesin berbasis satu deret dapat menangkap variasi temporal, tetapi tidak selalu mempertahankan struktur spasial [7], [8], [9]. ConvLSTM menjawab keterbatasan ini dengan mengganti operasi *fully connected* pada LSTM menjadi operasi konvolusi [10]. Sementara itu, representasi posisi waktu dan 3D CNN menjadi dua arah pengembangan yang relevan bagi data bulanan berbentuk grid [11], [12], [13], [14].

Berdasarkan keterbatasan tersebut, penelitian ini membandingkan ConvLSTM, ConvLSTM-TE, dan 3D CNN untuk memprediksi curah hujan bulanan berbasis CHIRPS di wilayah Bekasi dan sekitarnya menggunakan data, pembagian sampel, horizon prediksi, serta metrik evaluasi yang sama. Klimatologi dan persistensi per grid digunakan sebagai pembanding standar verifikasi prakiraan [15]. Penelitian ini berfokus pada tiga hal, yaitu: (1) membandingkan kinerja ketiga arsitektur, (2) memverifikasi secara independen prediksi rekursif model terpilih untuk Januari–Juni 2026, dan (3) mengimplementasikan model terpilih dalam prototipe Streamlit Cloud untuk visualisasi spasial curah hujan di Bekasi. Penelitian ini menilai *temporal embedding* sebagai bagian dari arsitektur ConvLSTM-TE yang utuh dan tidak melakukan *ablation study* terhadap komponen embedding bulan, musim, dan sinus–kosinus.

Dengan demikian, penelitian ini tidak mengklaim keunggulan absolut salah satu arsitektur. Kontribusinya terletak pada perbandingan sistematis tiga arsitektur spasio-temporal pada domain lokal berukuran kecil dengan protokol evaluasi transparan, serta pada indikasi bahwa pada hujan bulanan monsunal lokal, siklus musiman menjelaskan sebagian besar variasi sehingga nilai tambah arsitektur deep learning bersifat moderat.

2 Tinjauan Literatur

Prediksi curah hujan bulanan berkembang dari model statistik menuju *machine learning* dan *deep learning*. Mahmud et al. [16] menggunakan ARIMA di Bangladesh dan menunjukkan bahwa pola musiman dapat dimodelkan, tetapi kinerjanya bergantung pada kestasioneran deret. Di Indonesia,

 ISSN:2302-8149
e-ISSN:2540-9719

Kurnia [8] menunjukkan bahwa regresi dengan suhu muka laut dan tekanan permukaan laut dapat memprediksi hujan di ZOM 313 Sulawesi Tenggara, dengan jeda waktu sebagai faktor penting. Abebe dan Endalie [7] memperlihatkan kemampuan ANN dan algoritme *machine learning* dalam mempelajari hubungan nonlinier dalam prediksi hujan di Ethiopia. Namun, unit analisis studi tersebut masih berupa deret titik atau stasiun, sehingga variasi antargrid belum dipertahankan.

Ketergantungan jangka panjang pada deret hujan dipelajari menggunakan Long Short-Term Memory (LSTM). Chen et al. [9] menerapkan LSTM dengan *fixed sliding window* di Turki dan memperoleh korelasi 0,788, lebih tinggi daripada Random Forest sebesar 0,748. Keterbatasannya, LSTM standar memproses masukan sebagai vektor, sehingga hubungan antargrid perlu diratakan dan tidak dijaga secara eksplisit.

Shi et al. [10] memperkenalkan ConvLSTM dengan mengganti operasi *fully connected* pada gerbang LSTM menjadi operasi konvolusi, sehingga *hidden state dan cell state* tetap memiliki dimensi ruang (Tabel 1). Fredyan dan Kusuma [17] menerapkannya pada curah hujan bulanan di Kalimantan Timur (Tabel 1). Studi tersebut menegaskan bahwa konvolusi dan memori temporal dapat saling melengkapi pada urutan bidang spasial.

ConvLSTM mempelajari urutan nilai masukan, tetapi tidak selalu memperoleh posisi kalender secara eksplisit. Rui et al. [11] memprediksi ENSO, fenomena iklim global yang berpusat di Pasifik ekuator, melalui model dua tahap. Tahap pertama memprediksi anomali suhu muka laut dan kandungan panas laut di kawasan Samudra Pasifik (55° LS–60° LU) beresolusi 5° menggunakan ConvLSTM ber-self-attention dengan *temporal embedding* hibrida, yaitu fungsi sinus–kosinus tetap serta embedding bulan dan musim yang dapat dipelajari. Ablation study mereka menunjukkan bahwa tanpa embedding lebih baik pada lead pendek, sedangkan konfigurasi hybrid lebih baik pada lead panjang, manfaat embedding karena itu bergantung pada horizon. Tahap kedua memetakan hasilnya menjadi indeks Niño 3.4. Phermphoonphiphat et al. [12] mengembangkan SP-CRN yang mempelajari representasi periodik dari siklus sebelumnya (*periodic representation dictionary*) dan *metadata* bulan *one-hot* untuk memprediksi tinggi geopotensial 300 hPa di Belahan Bumi Utara dan suhu muka laut global beresolusi 1°. Kedua studi menangani domain berskala besar dengan resolusi kasar, sedangkan penelitian ini mengadaptasi *konsep hibrida* Rui et al. [11] pada ConvLSTM satu tahap tanpa *self-attention* untuk curah hujan bulanan lokal beresolusi 0,05° di wilayah bertipe hujan monsunal.

Sebagai pembanding nonrekuren, 3D CNN melakukan konvolusi secara bersamaan pada dimensi waktu, tinggi, dan lebar. Tran et al. [18] menunjukkan kemampuannya mengekstraksi fitur spasio-temporal dari volume data, sedangkan Yu dan Hao [13] menerapkannya pada prediksi variabel lingkungan berbasis raster. Berbeda dari ConvLSTM, 3D CNN tidak memperbarui *cell state* secara berurutan.

Dengan demikian, *temporal embedding* telah digunakan untuk variabel iklim pada domain berskala besar, tetapi penerapannya pada curah hujan lokal bertipe monsunal masih terbatas. Penelitian ini membandingkan ketiga arsitektur pada domain, pembagian waktu, horizon, dan metrik yang sama, dengan ruang pencarian yang disesuaikan per arsitektur (Tabel 2), serta melengkapinya dengan pembanding klimatologi dan persistensi dan evaluasi terhadap CHIRPS aktual 2026. Ringkasan penelitian terdahulu disajikan pada Tabel 1.

Tabel 1 Ringkasan penelitian terdahulu

Peneliti (Tahun)	Metode	Dataset	Hasil	Keterbatasan dan Perbedaan Cakupan
Shi et al. [10] (2015)	ConvLSTM	Radar Hong Kong dan Moving-MNIST	ConvLSTM mengungguli FC-LSTM dan ROVER pada *nowcasting* spasio-temporal.	Horizon 1–6 jam, belum menguji hujan bulanan CHIRPS lokal.
Fredyan dan Kusuma [17] (2022)	ConvLSTM + *Attention*	CHIRPS Kalimantan Timur	ConvLSTM-AT mengungguli GRU, LSTM, dan LSTM-AT.	Belum menggunakan *temporal embedding* kalender.
Rui et al. [11] (2024)	ConvLSTM + *self-attention*	ENSO, SSTA/HCA	Model dua tahap mempertahankan korelasi Niño 3.4 >0,5 hingga 24 bulan; ablasi menunjukkan tanpa embedding lebih baik pada lead pendek dan	ENSO global, resolusi 5°, model dua tahap, bukan prediksi hujan lokal.

 ISSN:2302-8149
e-ISSN:2540-9719

Peneliti (Tahun)	Metode	Dataset	Hasil	Keterbatasan dan Perbedaan Cakupan
			embedding hibrida lebih baik pada lead panjang.	
Phermphoonphiphat et al. [12] (2021)	Soft Periodic ConvRNN + metadata bulan	Geopotential height dan SST	SP-CRN-1+3-Meta menghasilkan RMSE terendah dan mengungguli CNN, ConvGRU, ConvLSTM, serta seluruh varian SP-CRN yang diuji	Domain Belahan Bumi Utara (ZH300) dan global (SST) beresolusi 1°.
Penelitian ini (2026)	ConvLSTM, ConvLSTM-TE, dan 3D CNN	CHIRPS Bulanan Bekasi, periode 1990–2025, grid 20×20	ConvLSTM-TE terendah (RMSE 82,368); ConvLSTM 86,048; 3D CNN 96,347 mm/bulan.	Evaluasi masih menggunakan satu *holdout* belum ada pengulangan *multi-seed* atau *ablation study*.

3 Metode Penelitian

3.1 Data dan Wilayah Penelitian

Data utama adalah produk CHIRPS v2.0 global bulanan dari Climate Hazards Center dalam format raster netCDF, bersatuan mm/bulan, dengan resolusi 0,05°. Produk ini menggabungkan estimasi inframerah satelit dan observasi stasiun [6], [19]. Periode Januari 1990–Desember 2025 (432 bulan) untuk pelatihan, validasi, dan pengujian diunduh sekaligus dalam format netCDF, sedangkan data Januari–Juni 2026 untuk evaluasi *out-of-sample* diunduh bertahap melalui prototipe dalam format GeoTIFF per bulan. Keduanya diperoleh dari https://data.chc.ucsb.edu/products/CHIRPS-2.0/global_monthly/ dan berasal dari produk, versi, resolusi, serta satuan yang sama, sehingga hanya berbeda pada format berkas. Seluruh data dipotong pada domain yang sama menjadi grid 20×20 pada 5,75°–6,75° LS dan 106,5°–107,5° BT, yang meliputi Kota dan Kabupaten Bekasi beserta wilayah sekitarnya agar konvolusi memperoleh konteks spasial pada batas administratif.

Tahap kendali mutu mencakup pemeriksaan kelengkapan urutan waktu, nilai hilang, dan nilai yang tidak sesuai dengan karakter curah hujan. Wilayah administratif Bekasi merupakan fokus utama di dalam domain raster, sedangkan sel di sekitarnya dipertahankan sebagai konteks spasial. Untuk metrik perbandingan arsitektur, seluruh 400 sel domain digunakan (400 × 84 = 33.600 pasangan nilai), termasuk sel laut di utara domain yang bernilai 0, untuk analisis administratif dan prototipe, mask batas Bekasi diterapkan pada keluaran raster, dan batas kecamatan digunakan untuk agregasi serta narasi spasial.

3.2 Pembentukan Dataset dan Normalisasi

Deret 432 bulan (Januari 1990–Desember 2025) disusun menjadi pasangan prediktor–target menggunakan *sliding window* 12 bulan dan horizon satu bulan, sehingga diperoleh 420 sampel. Setiap sampel masukan berbentuk 12×20×20×1, sedangkan targetnya berupa peta 20×20×1 pada bulan berikutnya. Pembagian kronologis menghasilkan 336 sampel latih (target Januari 1991–Desember 2018) dan 84 sampel uji (target Januari 2019–Desember 2025). Sebanyak 20% sampel latih terakhir (68 sampel) digunakan sebagai validasi melalui *validation_split*=0,2 dan *shuffle=False*, sehingga 268 sampel dipakai untuk memperbarui bobot model.

Penskalaan dilakukan setelah pembagian data. Parameter MinMaxScaler (Persamaan (1)) dan RobustScaler (Persamaan (2)) dihitung dari 336 sampel latih, termasuk 68 sampel validasi, lalu diterapkan pada data uji. Kedua metode diperlakukan sebagai bagian dari eksperimen karena curah hujan mengandung nilai ekstrem, dan RobustScaler yang berbasis median serta rentang interkuartil kurang sensitif terhadap pencilan [20]. Keluaran model dikembalikan ke satuan mm/bulan setelah inferensi.

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

$$RS(x_i) = \frac{x_i - med(x)}{Q_3 - Q_1} \quad (2)$$

3.3 Arsitektur Model

Ketiga arsitektur dipilih karena sesuai untuk data raster spasio-temporal, sedangkan model statistik dan *machine learning* konvensional umumnya beroperasi pada deret titik. ConvLSTM

 ISSN:2302-8149
e-ISSN:2540-9719

digunakan sebagai model acuan [10], sedangkan klimatologi serta persistensi sebagai pembanding sederhana. Ketiga arsitektur berbeda dalam jumlah parameter dan ruang pencarian serta tidak diulang secara sistematis dengan beberapa *seed*, sehingga selisih kinerja dibaca sebagai kecenderungan pada eksperimen ini, bukan atribusi mekanisme arsitektur.

Mekanisme gerbang ConvLSTM2D yang digunakan dirumuskan pada Persamaan (3)–(7). Formulasi asli ConvLSTM [10] memuat koneksi *peephole* dari *cell state* ke gerbang, sedangkan ConvLSTM2D TensorFlow/Keras menerapkan transformasi masukan dan rekuren secara konvolusional seperti lapisan LSTM [21] tanpa koneksi tersebut. Persamaan (3)–(7) merepresentasikan varian ConvLSTM tanpa peephole, varian peephole tidak diuji dalam penelitian ini. X_t adalah masukan (1 kanal pada ConvLSTM dan 17 kanal pada ConvLSTM-TE), H_t dan C_t adalah *hidden state dan cell state*, W kernel konvolusi 3×3, b bias, $*$ operasi konvolusi, dan $\circ$ perkalian Hadamard. Gerbang i_t, f_t, dan o_t menggunakan fungsi aktivasi rekuren σ (*recurrent_activation)* [21], sedangkan kandidat *cell state* dan keluaran sel menggunakan ReLU sesuai parameter *activation* (Gambar 1). ReLU dipilih karena curah hujan tidak negatif dan telah digunakan pada ConvLSTM2D untuk prediksi presipitasi [22], stabilitasnya dijaga dengan *gradient clipping* (*clipnorm* = 1,0). Pada kelompok dengan *recurrent dropout*, *masker dropout* diterapkan pada H_{t-1} sebelum konvolusi rekuren [21].

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + b_i) \quad (3)$$
$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + b_f) \quad (4)$$
$$C_t = f_t \circ C_{t-1} + i_t \circ ReLU(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (5)$$
$$o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + b_o) \quad (6)$$
$$H_t = o_t \circ \text{ReLU}\,(C_t) \quad (7)$$

Arsitektur yang diuji menggunakan dua lapisan ConvLSTM2D dengan kernel 3×3, *padding same*, dan aktivasi ReLU. Lapisan pertama memiliki F filter (32 atau 64) dan mengembalikan seluruh sekuens (*return_sequences=True)*, sedangkan lapisan kedua memiliki F/2 filter dan menghasilkan representasi akhir (*return_sequences=False*). Representasi tersebut diteruskan ke *dropout* 0,3 dan Conv2D 1×1 beraktivasi linear untuk menghasilkan peta curah hujan satu bulan ke depan.

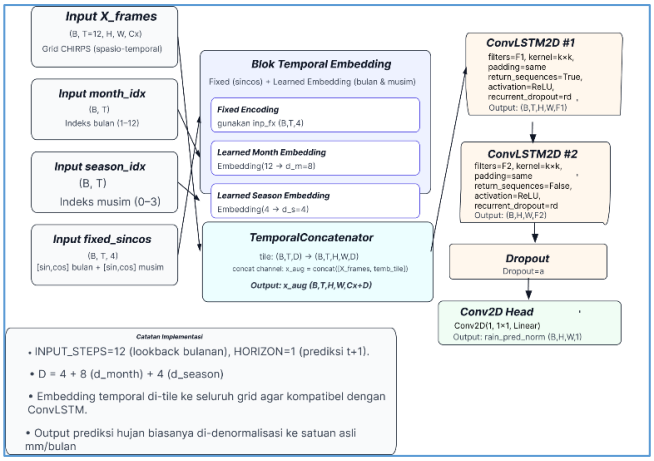
ConvLSTM-TE mempertahankan struktur dasar ConvLSTM, tetapi setiap *timestep* memperoleh konteks kalender sebelum memasuki lapisan rekuren. *Learnable embedding* bulan (8 dimensi), *embedding* musim (4 dimensi), serta empat fitur sinus–kosinus digabungkan menjadi vektor temporal 16 dimensi. Vektor tersebut direplikasi ke seluruh grid 20×20 dan dikonkatenasikan dengan satu kanal curah hujan, sehingga masukan pada setiap *timestep* memiliki 17 kanal. Representasi hibrida menggabungkan pola periodik tetap dengan representasi kalender yang dipelajari model.

Komponen periodik mengikuti periode 12 untuk bulan dan periode 4 untuk musim seperti dirumuskan pada Persamaan (8) dan (9) [11]. Pasangan sinus–kosinus menjaga kontinuitas siklik kalender, sehingga posisi waktu pada akhir dan awal tahun tidak hanya ditentukan oleh jarak indeks numerik.

$$month_i = [\sin(w_{1i}), \cos(w_{1i})], \quad w_1 = \frac{2\pi}{12} \quad (8)$$
$$season_j = \left[\sin\left(w_{2j}\right), \cos\left(w_{2j}\right)\right], \quad w_2 = \frac{2\pi}{4} \quad (9)$$

Untuk merepresentasikan siklus kalender, informasi musim pada ConvLSTM-TE dikodekan ke dalam empat fase tiga bulanan, yaitu DJF (Desember, Januari, Februari), MAM (Maret, April, Mei), JJA (Juni, Juli, Agustus), dan SON (September, Oktober, November). Pembagian tersebut merupakan pengelompokan fase kalender, bukan penetapan empat musim klimatologis. Wilayah Bekasi tetap memiliki pola hujan monsunal dengan dua musim, yaitu musim hujan dan musim kemarau [23]. Dalam klimatologi curah hujan Indonesia, DJF merupakan periode puncak musim hujan, JJA merupakan periode puncak musim kemarau, sedangkan MAM dan SON merupakan periode peralihan [24]. Pembagian empat musim ini juga lazim digunakan dalam analisis variabilitas curah hujan musiman di Indonesia [25], sehingga empat indeks musim membedakan fase naik dan turun curah hujan. Awal musim aktual dapat bergeser antartahun, sehingga pembagian tetap ini merupakan pendekatan yang dilengkapi *embedding* bulan.

 ISSN:2302-8149
e-ISSN:2540-9719



Gambar 1 Arsitektur ConvLSTM *temporal embedding*

Gambar 1 memperlihatkan arsitektur ConvLSTM-TE yang menggabungkan blok temporal embedding dengan dua lapisan ConvLSTM2D hingga menghasilkan peta curah hujan bulan berikutnya.

Pada 3D CNN, konvolusi diperluas ke dimensi waktu, tinggi, dan lebar sehingga fitur diekstraksi dari volume data spasio-temporal [13], [18]. Berbeda dari ConvLSTM, 3D CNN tidak memiliki memori rekuren, waktu diproses sebagai bagian dari volume konvolusi. Formulasi umum operasi Conv3D ditunjukkan pada Persamaan (10) sebagai berikut:

$$c_{xyz} = f(\sum_{i,j,k} w_{ijk} a_{x+i,y+j,z+k} + b) \quad (10)$$

Pada Persamaan (10), c_{xyz} adalah keluaran pada posisi (x, y, z), $a(x+i, y+j, z+k)$ merupakan nilai *input*, w_{ijk} adalah bobot *kernel*, b adalah bias, dan f adalah fungsi aktivasi. Persamaan ini menunjukkan bahwa proses konvolusi dilakukan pada suatu kubus data, sehingga hubungan antar dimensi dapat dipelajari secara simultan.

Arsitektur 3D CNN terdiri atas dua blok Conv3D dengan kernel 3×3×3 dan aktivasi ReLU. Blok pertama memuat dua lapisan Conv3D dengan F filter yang masing-masing diikuti *BatchNormalization*, kemudian MaxPooling3D (1,2,2) dan *dropout* 0,2. Blok kedua memuat dua lapisan Conv3D dengan F/2 filter beserta *BatchNormalization*, kemudian UpSampling3D (1,2,2) dan *dropout* 0,2. Dimensi waktu diringkas menggunakan TemporalAverage, lalu satu lapisan Conv2D 3×3 (F/2 filter, ReLU) dan *dropout* 0,2 menyempurnakan fitur sebelum keluaran Conv2D 1×1 beraktivasi linear.

3.4 Pelatihan dan Pencarian Hiperparameter

Model dibangun dengan TensorFlow/Keras menggunakan Adam (*clipnorm* 1,0), loss MSE, maksimum 100 *epoch*, *EarlyStopping* (*patience* 10, *restore_best_weights=True*), dan *ReduceLROnPlateau* (faktor 0,5, *patience* 5, *learning rate* minimum 10^{-6}). Ketiganya menggunakan pembagian kronologis, horizon prediksi, dan metrik evaluasi yang sama. Tuning mencakup jumlah filter (32 dan 64), *learning rate*, *batch size*, dan metode penskalaan dalam empat kelompok eksperimen (Tabel 2). *Recurrent dropout* hanya diuji pada model rekuren karena parameter tersebut tidak tersedia pada 3D CNN. Secara keseluruhan, ConvLSTM dan ConvLSTM-TE masing-masing dilatih 92 kali dan 3D CNN 76 kali. Sebagian konfigurasi dilatih lebih dari satu kali karena muncul pada dua kelompok di Tabel 2. Kombinasi *learning rate* 0,002–0,0005 dengan *batch size* 8 dan 16 terdapat pada MinMax tanpa RD-1 dan MinMax tanpa RD-2, sehingga 16 konfigurasi (2 *filter* × 4 *learning rate* × 2 *batch size*) dilatih dua kali pada setiap arsitektur. Pada 3D CNN, kombinasi *batch size* 16 juga terdapat pada kelompok Robust tanpa RD dan Robust dengan RD karena 3D CNN tidak menggunakan recurrent *dropout*, sehingga terdapat tambahan 8 konfigurasi ulang.

Validation loss, yaitu MSE pada data ternormalisasi untuk sampel validasi bertarget Mei 2013–Desember 2018, digunakan untuk *EarlyStopping* dan pemulihan bobot terbaik. Untuk perbandingan utama, satu konfigurasi per arsitektur dipilih berdasarkan RMSE terendah pada data uji. Karena pemilihan ini dapat bersifat optimistis, Tabel 4 juga melaporkan median dan rentang interkuartil (IQR = Q3 − Q1) RMSE data uji dari seluruh pelatihan serta RMSE data uji dari pelatihan dengan

 ISSN:2302-8149
e-ISSN:2540-9719

validation loss terendah, yang dipilih terpisah per kelompok scaler karena nilai *validation loss* bergantung pada skala hasil MinMaxScaler atau RobustScaler. Ketiga ringkasan tersebut merupakan perkiraan kinerja dengan prosedur pemilihan berbeda: konfigurasi terbaik sebagai batas atas, seleksi *validation loss* sebagai kinerja yang diharapkan tanpa informasi data uji, dan median sebagai kinerja tipikal di seluruh ruang hiperparameter. Model terpilih juga diverifikasi pada CHIRPS Januari–Juni 2026 yang tidak digunakan dalam pelatihan maupun pemilihan (Subbab 4.5*)*. Ruang pencarian dirangkum pada Tabel 2.

Tabel 2 Kelompok eksperimen dan ruang pencarian hiperparameter

Kelompok eksperimen	Penskalaan	*Learning rate*	*Filter*	*Batch size*	*Recurrent dropout*	Jumlah pelatihan (ConvLSTM / ConvLSTM-TE / 3D CNN)
MinMax tanpa RD-1	MinMaxScaler	0,002; 0,001; 0,0008; 0,0005	32; 64	8; 16; 32	0	24 / 24 / 24
MinMax tanpa RD-2	MinMaxScaler	0,002; 0,001; 0,0008; 0,0005; 0,0001	32; 64	8; 16	0	20 / 20 / 20
Robust tanpa RD	RobustScaler	0,002; 0,001; 0,0008; 0,0005	32; 64	8; 16	0	16 / 16 / 16
Robust dengan RD	RobustScaler	0,002; 0,001; 0,0008; 0,0005	32; 64	16; 32	0,2; 0,3 (model rekuren)	32 / 32 / 16
Total						92 / 92 / 76

3.5 Metrik Evaluasi

Evaluasi dilakukan pada skala curah hujan aktual menggunakan lima metrik yang mencakup besar galat, variasi terjelaskan, hubungan linear, dan galat relatif [26], ditambah *skill score* terhadap prakiraan acuan. RMSE digunakan sebagai kriteria utama pemilihan dan pengurutan konfigurasi, sedangkan MAE dan r digunakan untuk memeriksa konsistensi pada galat tipikal dan kesesuaian pola. Karena seluruh model dievaluasi pada data uji yang sama, R^2 dan RSR dilaporkan untuk memudahkan interpretasi dan perbandingan dengan studi lain, bukan sebagai kriteria pengurutan yang terpisah.

a. *Mean Absolute Error* (MAE) menyatakan rata-rata galat absolut dalam satuan curah hujan dirumuskan pada Persamaan (11).

$$MAE = \frac{\sum|y_i - \hat{y}_i|}{n} \tag{11}$$

b. *Root Mean Square Error* (RMSE) memberi penalti lebih besar pada galat besar. RMSE dihitung menggunakan Persamaan (12).

$$RMSE = \sqrt{\frac{\sum(y_i - \hat{y}_i)^2}{n}} \tag{12}$$

c. Koefisien Determinasi *(R^2):* menyatakan proporsi variasi observasi yang dijelaskan oleh hasil prediksi model. Formulasinya diberikan pada Persamaan (13).

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y}\ )^2} \tag{13}$$

d. Korelasi Pearson *(r):* mengukur kekuatan hubungan linear antara prediksi dan observasi. Perhitungannya mengikuti Persamaan (14).

$$r = \frac{\sum(y_i - \bar{y}\ )(\hat{y}_i - \bar{\hat{y}}\ )}{\sqrt{\sum(y_i - \bar{y}\ )^2 \sum(\hat{y}_i - \bar{\hat{y}}\ )^2}} \tag{14}$$

e. *RMSE-observations Standard Deviation Ratio* (RSR)

RSR membandingkan RMSE dengan simpangan baku observasi [27]. RSR dihitung menggunakan Persamaan (15). RSR juga digunakan dalam studi prediksi curah hujan bulanan [9].

$$RSR = \frac{RMSE}{STDEV_{obs}} = \frac{\left[\sqrt{\sum_{i=1}^{n}(Y_i^{obs} - Y_i^{sim})^2}\right]}{\left[\sqrt{\sum_{i=1}^{n}(Y_i^{obs} - Y^{mean})^2}\right]} \tag{15}$$

 ISSN:2302-8149
e-ISSN:2540-9719

f. Skill Score RMSE (SS)

SS dihitung mengikuti bentuk umum *skill score*, yaitu $(A_{model} - A_{ref})/(A_{sempurna} - A_{ref})$, dengan klimatologi sebagai prakiraan acuan [15]. Dengan ukuran akurasi A = RMSE dan Asempurna = 0, diperoleh Persamaan (16). Acuan yang digunakan adalah klimatologi atau persistensi. Klimatologi adalah rata-rata per grid untuk setiap bulan kalender periode 1990–2018, sedangkan persistensi menggunakan peta bulan sebelumnya sebagai prediksi bulan berikutnya. Nilai SS positif menunjukkan nilai tambah terhadap prakiraan acuan, sedangkan nilai nol atau negatif menunjukkan tidak ada nilai tambah.

$$SS_{ref} = 1 - \frac{RMSE_{model}}{RMSE_{ref}} \quad (16)$$

3.6 Prediksi Rekursif dan Prototipe

Konfigurasi ConvLSTM-TE terpilih digunakan untuk prediksi rekursif Januari–Juni 2026. Prediksi pertama menggunakan dua belas peta CHIRPS aktual terakhir (Januari–Desember 2025) sebagai masukan. Pada setiap langkah berikutnya, peta hasil prediksi ditambahkan ke ujung jendela masukan dan peta tertua dikeluarkan, sehingga prediksi bulan ke-k menggunakan k − 1 peta hasil prediksi. Fitur kalender dibentuk dari bulan target setiap langkah, dan keluaran dikembalikan ke satuan mm/bulan. Hasil prediksi dibandingkan dengan CHIRPS aktual Januari–Juni 2026 menggunakan rata-rata galat bertanda dan galat absolut seluruh grid, lalu diintegrasikan ke prototipe Streamlit.

4 Hasil dan Pembahasan

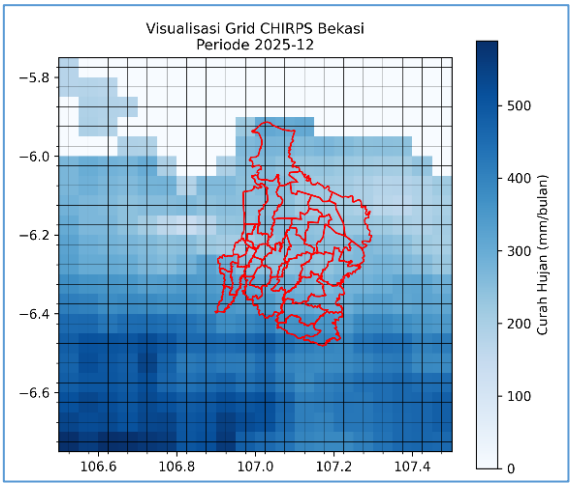
4.1 Karakteristik Data Curah Hujan

Ringkasan statistik data CHIRPS pada domain grid 20×20 wilayah Bekasi dan sekitarnya disajikan pada Tabel 3.

Tabel 3 Ringkasan statistik deskriptif data hujan CHIRPS (mm/bulan)

Jumlah Bulan	Jumlah Grid	Jumlah Data	Rata-Rata	min	maks	Std.Deviasi
432	400	172.800	179,50	0	1.373,41	169,03

Tabel 3 menunjukkan bahwa 172.800 nilai raster (432 bulan × 400 sel) memiliki rata-rata 179,50 mm/bulan, simpangan baku 169,03 mm/bulan, dan rentang 0–1.373,41 mm/bulan. Distribusi yang lebar dan menceng ini menuntut model menangani periode kering sekaligus lonjakan hujan, sehingga RMSE yang peka terhadap galat besar dibaca bersama MAE, r, R^2, dan RSR. Contoh data masukan ditampilkan pada Gambar 2.



Gambar 2 Contoh data CHIRPS pada domain penelitian 20×20 grid (Desember 2025)

Gambar 2 digunakan untuk memperlihatkan contoh bidang masukan, setiap sel mewakili nilai CHIRPS pada satu posisi lintang–bujur, sedangkan batas Bekasi memberi konteks wilayah. Peta dipilih sebagai representasi data karena heterogenitas antargrid tidak terlihat jika seluruh bidang diringkas menjadi satu deret. Data ini tidak hanya berupa deret waktu, tetapi juga memiliki struktur spasial, sehingga setiap sampel disusun sebagai urutan 12 peta bulanan. Evaluasi dilanjutkan dengan metrik galat dan korelasi agar kecocokan rata-rata tidak menutupi galat per-grid.

 ISSN:2302-8149
e-ISSN:2540-9719

4.2 Perbandingan Kinerja Model

Tabel 4 menyajikan kinerja konfigurasi terbaik setiap arsitektur, pembanding klimatologi dan persistensi, serta ringkasan seluruh konfigurasi, yaitu median RMSE dan RMSE dari *validation loss* terendah per kelompok s*caler*.

Tabel 4 Perbandingan model, pembanding sederhana, dan ringkasan seluruh pelatihan

Model	RMSE	MAE	R^2	r	RSR	Median RMSE (IQR)	RMSE *val_loss* terendah (MinMax / Robust)	SS terhadap rata-rata klimatologi	SS terhadap Persistensi
ConvLSTM-TE	82,368	59,024	75,25%	0,868	0,497	86,568 (2,49)	85,805/ 85,914	0,068	0,344
ConvLSTM	86,048	59,841	72,99%	0,857	0,520	88,790 (2,70)	86,420/ 86,311	0,026	0,315
3D CNN	96,347	67,986	66,14%	0,815	0,582	158,821 (45,08)	109,196/ 101,999	-0,091	0,233
Persistensi	125,639	77,956	42,42%	0,711	0,759				
Rata-rata Klimatologi	88,336	58,503	71,54%	0,847	0,533				

Catatan: Kolom RMSE hingga RSR dihitung pada data uji (2019–2025) untuk konfigurasi dengan RMSE uji terendah. Median RMSE (IQR) dihitung dari RMSE data uji seluruh pelatihan (n = 92, 92, dan 76). RMSE *val_loss* terendah adalah RMSE data uji dari satu pelatihan dengan *validation loss* terendah pada data validasi (Mei 2013–Desember 2018), dipilih terpisah untuk kelompok MinMax dan Robust, setiap pelatihan, termasuk konfigurasi yang dilatih ulang, diperlakukan sebagai kandidat terpisah. SS klimatologi dan SS persistensi adalah *skill score* RMSE terhadap masing-masing acuan menggunakan Persamaan (16).

Ketiga model jauh lebih akurat daripada persistensi (RMSE 125,639 mm/bulan, SS terhadap persistensi 0,23–0,34), yang gagal mengikuti perubahan tajam pada transisi musim. Klimatologi merupakan pembanding yang jauh lebih kuat (RMSE 88,336 mm/bulan; R^2 = 71,54%) karena siklus musiman monsunal menjelaskan sebagian besar variasi hujan bulanan. ConvLSTM-TE dan ConvLSTM melampaui klimatologi (SSklim 0,068 dan 0,026), sedangkan 3D CNN tidak (−0,091). MAE klimatologi (58,503 mm/bulan) sedikit lebih rendah daripada ConvLSTM-TE dan ConvLSTM, sehingga keunggulan kedua model terutama berasal dari pengurangan galat besar yang ditekankan RMSE.

Ketiga ringkasan pada Tabel 4 membentuk urutan yang sama pada setiap arsitektur: konfigurasi terbaik < seleksi *validation loss* < median. Selisih antara konfigurasi terbaik dan seleksi *validation loss* menunjukkan optimisme pemilihan pada data uji, yaitu 3,4–3,5 mm/bulan pada ConvLSTM-TE, 0,3–0,4 mm/bulan pada ConvLSTM, dan 5,7–12,8 mm/bulan pada 3D CNN. Pada seleksi *validation loss* maupun median, ConvLSTM-TE tetap memiliki RMSE terendah, tetapi selisihnya terhadap ConvLSTM menyempit dari 3,680 mm/bulan menjadi sekitar 0,5 mm/bulan dan 2,2 mm/bulan. Kedua selisih ini lebih kecil daripada IQR masing-masing arsitektur (2,49 dan 2,70 mm/bulan), sehingga perbedaan ConvLSTM-TE dan ConvLSTM dibaca sebagai kecenderungan. Median ConvLSTM-TE berada di bawah RMSE klimatologi, sedangkan median ConvLSTM sedikit di atasnya.

3D CNN memiliki median RMSE 158,821 mm/bulan dengan IQR 45,08 mm/bulan, jauh lebih lebar daripada kedua model berbasis ConvLSTM, sehingga kinerjanya paling sensitif terhadap pilihan hiperparameter. Seleksi *validation loss* menurunkan RMSE 3D CNN jauh di bawah mediannya (101,999–109,196 mm/bulan), tetapi tetap di atas klimatologi. Penelitian ini belum menguji apakah selisih tersebut berasal dari mekanisme rekuren, jumlah parameter, atau pilihan hiperparameter.

Tabel 5 menyajikan sepuluh pelatihan dengan RMSE uji terendah dari seluruh arsitektur untuk menggambarkan sensitivitas kinerja terhadap pilihan hiperparameter. Karena diurutkan berdasarkan data uji, tabel ini bersifat deskriptif dan tidak digunakan sebagai estimasi kinerja yang bebas bias, estimasi tersebut diberikan oleh median dan seleksi *validation loss* pada Tabel 4.

 ISSN:2302-8149
e-ISSN:2540-9719

Tabel 5 Sepuluh konfigurasi dengan RMSE data uji terendah

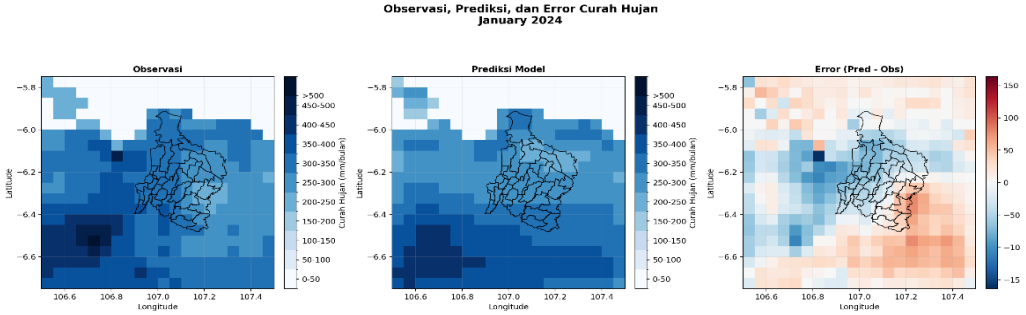
No	Model	Konfigurasi	Eksperimen	RMSE	MAE	R^2	R	RSR
1	ConvLSTM-TE	F32 LR0.001 BS8	Robust tanpa RD	82,368	59,024	75,25%	0,868	0,497
2	ConvLSTM-TE	F64 LR0.0005 BS8	MinMax tanpa RD	83,245	58,738	74,72%	0,865	0,503
3	ConvLSTM-TE	F64 LR0.001 BS8	Robust tanpa RD	83,601	60,119	74,51%	0,864	0,505
4	ConvLSTM-TE	F32 LR0.001 BS16	MinMax tanpa RD	84,266	60,089	74,10%	0,861	0,509
5	ConvLSTM-TE	F32 LR0.0008 BS8	MinMax tanpa RD	84,387	60,032	74,02%	0,860	0,510
6	ConvLSTM-TE	F64 LR0.0008 BS8	MinMax tanpa RD	84,475	59,797	73,97%	0,861	0,510
7	ConvLSTM-TE	F64 LR0.0008 BS16 RD0.3	Robust dengan RD	84,551	59,909	73,92%	0,862	0,511
8	ConvLSTM-TE	F32 LR0.002 BS16 RD0.3	Robust dengan RD	84,583	61,025	73,90%	0,862	0,511
9	ConvLSTM-TE	F32 LR0.002 BS8	MinMax tanpa RD	84,741	60,170	73,81%	0,859	0,512
10	ConvLSTM-TE	F64 LR0.001 BS8	MinMax tanpa RD	84,794	58,840	73,77%	0,859	0,512

Kesepuluh posisi teratas ditempati ConvLSTM-TE dengan RMSE 82,368–84,794 mm/bulan, sehingga kinerja baik tidak bergantung pada satu konfigurasi. Nilai r relatif stabil (0,859–0,868), menunjukkan bahwa kesepuluh konfigurasi mengikuti pola musiman dengan tingkat kesesuaian yang serupa. Namun, urutan berdasarkan MAE tidak identik dengan urutan RMSE, konfigurasi peringkat 2 (58,738 mm/bulan) dan peringkat 10 (58,840 mm/bulan) memiliki MAE lebih rendah daripada peringkat 1 (59,024 mm/bulan). Hal ini menunjukkan bahwa keunggulan konfigurasi teratas terutama berasal dari pengurangan galat besar yang ditekankan RMSE, bukan dari galat tipikal. MinMaxScaler muncul pada enam konfigurasi dan RobustScaler pada empat, termasuk peringkat pertama, sedangkan recurrent *dropout* hanya terdapat pada dua konfigurasi (peringkat 7 dan 8), sehingga tidak ada metode penskalaan atau recurrent *dropout* yang selalu unggul pada ruang pencarian ini.

Urutan ConvLSTM-TE, ConvLSTM, dan 3D CNN konsisten pada ketiga cara pemilihan. Selisih kedua model berbasis ConvLSTM terhadap 3D CNN konsisten pada ketiga ringkasan, sedangkan selisih ConvLSTM-TE terhadap ConvLSTM kecil. Konfigurasi ConvLSTM-TE terbaik digunakan untuk analisis lanjutan sebagai studi kasus penerapan, dan kinerjanya diperiksa pada CHIRPS 2026 *out-of-sample*. Pemeriksaan ini hanya mencakup enam bulan dan satu model, sehingga tidak menghilangkan bias seleksi pada data uji.

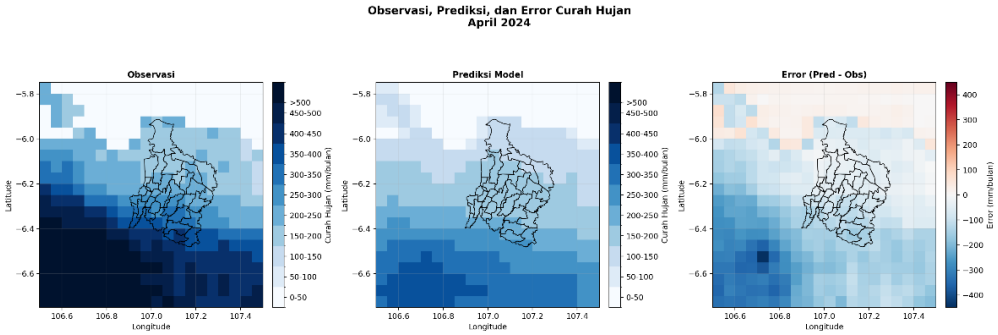
4.3 Analisis Spasial dan Temporal Model ConvLSTM-TE Terpilih

Analisis lanjutan membandingkan peta observasi, prediksi, dan galat pada periode representatif. Tujuannya bukan hanya menilai kedekatan nilai rata-rata, tetapi juga memeriksa apakah struktur spasial CHIRPS tetap muncul pada hasil model. Perbandingan ditampilkan pada Gambar 3.



(a) Januari 2024

 ISSN:2302-8149
e-ISSN:2540-9719



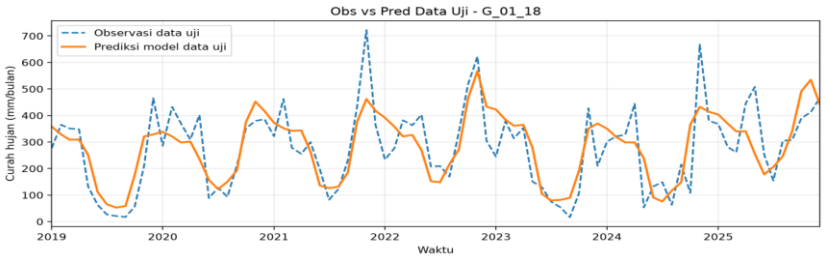
(b) April 2024

Gambar 3 Perbandingan CHIRPS aktual, prediksi, dan galat pada Data uji (a) Januari 2024 dan (b) April 2024

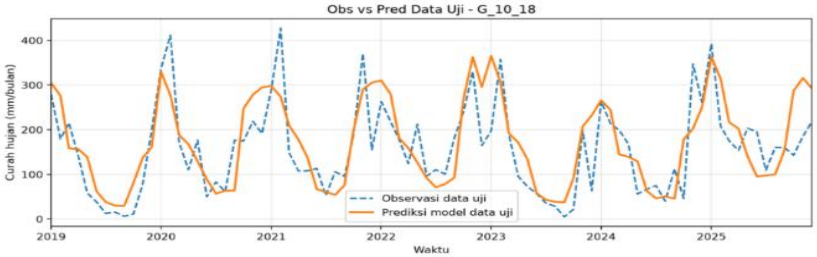
Gambar 3 membandingkan CHIRPS aktual, prediksi, dan galat pada Januari 2024 (hujan sedang) dan April 2024 (hujan tinggi di selatan domain). Pada Januari 2024, lokasi intensitas tinggi dan rendah pada prediksi sejalan dengan CHIRPS, sehingga model mempertahankan pola spasial dan tidak sekadar menghasilkan rata-rata domain.

Pada April 2024, area basah tetap dikenali, tetapi puncak prediksi lebih rendah daripada observasi. Penghalusan ekstrem ini konsisten dengan model regresi berbasis MSE pada distribusi yang menceng, tetapi pengaruhnya tidak dapat dipisahkan dari karakter data dan arsitektur.

Peta galat menunjukkan *underestimate* pada lokasi hujan tinggi dan *overestimate* pada sebagian grid yang lebih kering, sehingga kesalahan tidak tersebar acak.



(a) Piksel G_01_18 (latitude -6,675, longitude 107,425)



(b) Piksel G_10_18 (latitude -6,225, longitude 107,425)

Gambar 4 Grafik CHIRPS aktual dan prediksi data uji di piksel G_01_18 dan G_10_18

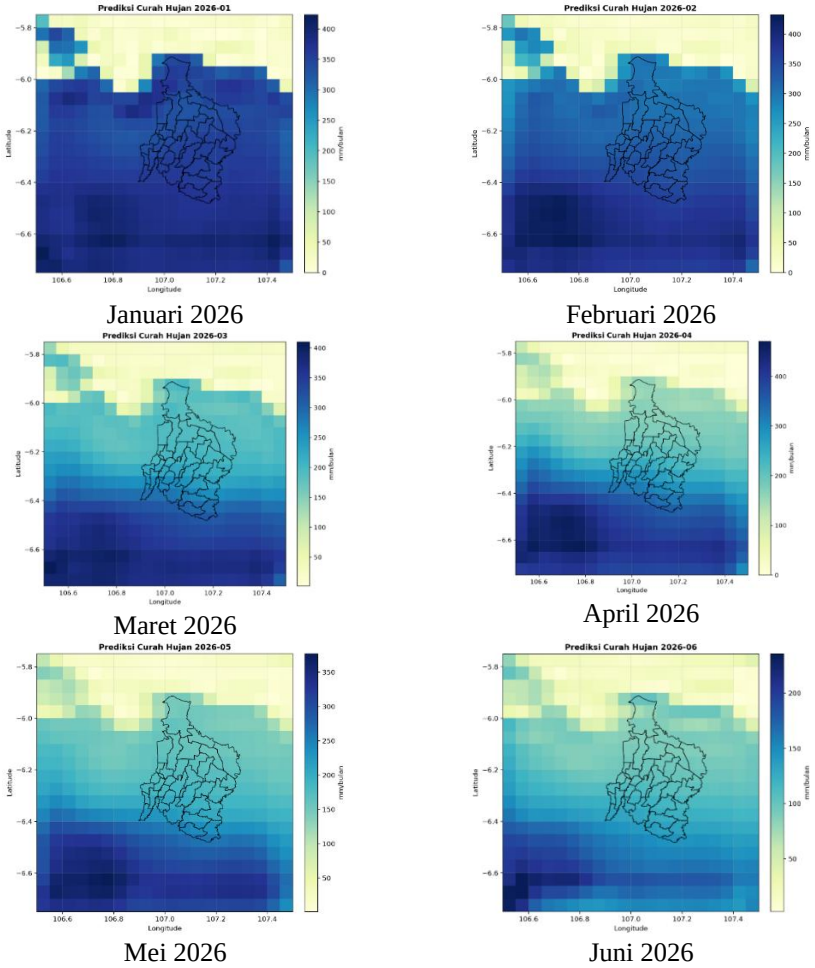
Gambar 4 merupakan grafik *time series* data CHIRPS dan hasil model pada data uji di dua piksel yaitu piksel G_01_18 (latitude -6,675, longitude 107,425) dan piksel G_10_18 (latitude -6,225, longitude 107,425). Grafik *time series* tersebut menunjukkan bahwa waktu kenaikan menuju periode basah dan penurunan menuju periode kering secara umum selaras antara CHIRPS aktual dan prediksi pada kedua piksel. Model terpilih mampu mengikuti fase musiman, tetapi puncak yang lebih rendah menunjukkan keterbatasan dalam merepresentasikan nilai ekstrem. Kontribusi konteks kalender terhadap kesesuaian fase ini belum dapat dipisahkan dari peran memori rekuren karena penelitian tidak melakukan *ablation study*.

4.4 Prediksi Rekursif Januari–Juni 2026

Prediksi rekursif Januari–Juni 2026 menggunakan konfigurasi ConvLSTM-TE terpilih. Konfigurasi ini digunakan karena ConvLSTM-TE tetap menempati urutan pertama pada ringkasan berbasis RMSE uji, *validation loss*, dan median. Data 2026 tidak digunakan dalam pelatihan maupun

 ISSN:2302-8149
e-ISSN:2540-9719

pemilihan sehingga menjadi pemeriksaan tambahan di luar data yang digunakan untuk pemilihan model. Karena hanya mencakup enam bulan dan satu model, pemeriksaan ini tidak menghilangkan bias seleksi pada data uji. Pada setiap langkah, peta prediksi dimasukkan kembali ke jendela masukan, horizon dibatasi enam bulan karena proporsi masukan hasil prediksi terus bertambah (Gambar 5).



Gambar 5 Peta prediksi rekursif curah hujan Januari–Juni 2026

Gambar 5 menunjukkan bahwa gradien spasial tetap terjaga hingga bulan keenam, dengan bagian selatan–barat daya lebih basah daripada utara dan intensitas menurun menuju pertengahan tahun.

4.5 Evaluasi terhadap CHIRPS Aktual Tahun 2026

Evaluasi dilakukan dalam dua tahap. Tahap pertama membandingkan ketiga arsitektur pada data uji 2019–2025, dan ConvLSTM-TE dipilih karena memiliki nilai terbaik pada kelima metrik untuk konfigurasi dengan RMSE uji terendah pada masing-masing arsitektur (Tabel 4). Tahap kedua memverifikasi model terpilih terhadap CHIRPS Januari–Juni 2026, yang merupakan *out-of-sample*, tidak digunakan pada pelatihan, validasi, maupun pengujian, sehingga tidak dimaksudkan untuk membandingkan ulang arsitektur. Rata-rata galat absolut 2026 sebesar 57,15 mm/bulan, sebanding dengan MAE data uji (59,02 mm/bulan), walaupun prediksi dihasilkan secara rekursif (Tabel 6 dan Gambar 6).

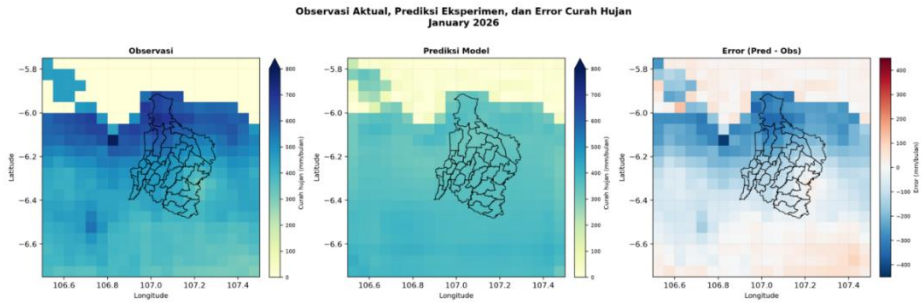
Tabel 6 Perbandingan data CHIRPS aktual dan prediksi rekursif januari–juni 2026

Periode	Rata-rata Seluruh Grid CHIRPS Aktual (mm/bulan)	Rata-rata Seluruh Grid Prediksi Rekursif (mm/bulan)	Rata-rata Galat Seluruh Grid (mm/bulan)	Rata-rata Galat Absolut Seluruh Grid (mm/bulan)
2026-01	375,33	294,79	-80,54	99,44
2026-02	244,67	282,72	38,05	51,11
2026-03	226,74	224,85	-1,88	24,96

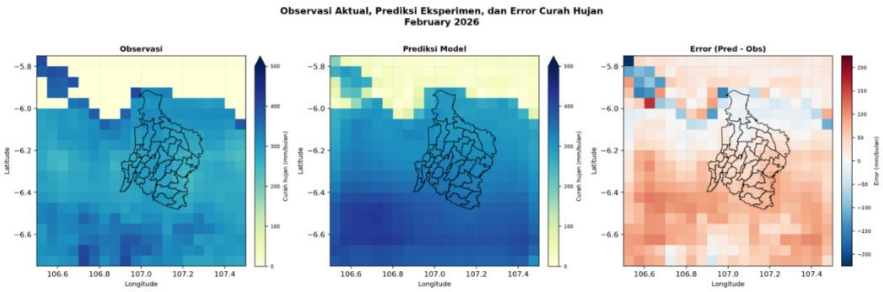
 ISSN:2302-8149
e-ISSN:2540-9719

2026-04	241,06	239,71	-1,35	52,13
2026-05	169,56	189,83	20,26	28,25
2026-06	23,03	110,06	87,03	87,03

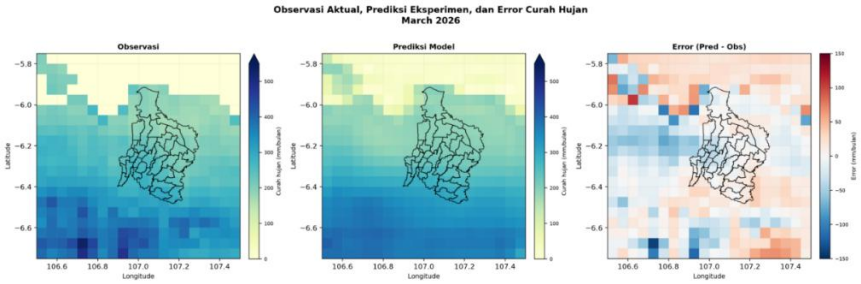
Rata-rata galat bertanda dan galat absolut pada Tabel 6 sama-sama dihitung dari galat pada 400 sel grid setiap bulan. Rata-rata galat bertanda pada Tabel 6 menunjukkan *underestimate* pada Januari (−80,54 mm/bulan) dan *overestimate* pada Juni (87,03 mm/bulan). Galat bertanda Maret hanya −1,88 mm/bulan, tetapi galat absolutnya 24,96 mm/bulan, sehingga galat positif dan negatif dapat saling meniadakan dan Tabel 6 perlu dibaca bersama Gambar 6. Pada prediksi rekursif, hasil prediksi setiap bulan digunakan kembali sebagai masukan bulan berikutnya, sehingga galat dapat menyebar atau terakumulasi antarlangkah, tetapi peningkatannya tidak harus monoton [28]. Namun, peningkatan galat seiring langkah rekursif tidak terlihat pada evaluasi ini: Januari 2026, langkah pertama dengan seluruh masukan berupa CHIRPS aktual, justru memiliki galat absolut terbesar (99,44 mm/bulan), sedangkan Februari–Mei, yang masukannya sudah memuat hasil prediksi, memiliki galat lebih rendah (24,96–52,13 mm/bulan).



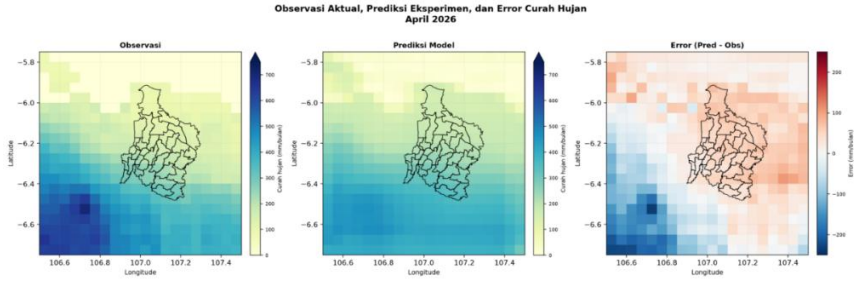
Januari 2026



Februari 2026

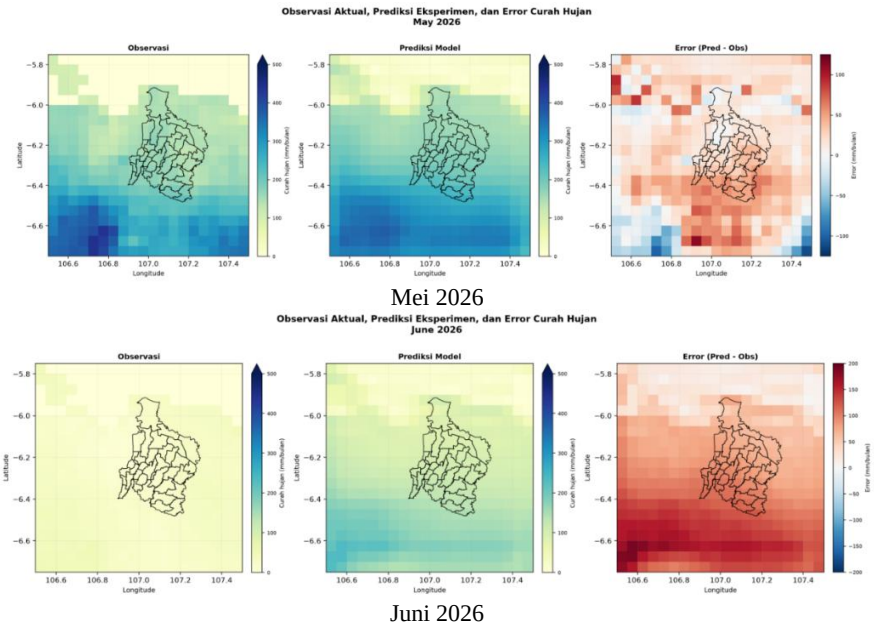


Maret 2026



April 2026

 ISSN:2302-8149
e-ISSN:2540-9719



Gambar 6 Perbandingan CHIRPS aktual, prediksi, dan galat (Januari–Juni 2026)

Galat absolut tertinggi terjadi pada Januari (99,44 mm/bulan) dan Juni (87,03 mm/bulan), sedangkan Februari–Mei lebih rendah (24,96–52,13 mm/bulan). Pola ini tidak mengikuti peningkatan galat seiring langkah rekursif. Januari adalah langkah pertama dengan seluruh masukan berupa CHIRPS aktual, tetapi justru memiliki galat terbesar. Dalam enam bulan yang diuji, besarnya galat tampak lebih berasosiasi dengan intensitas curah hujan bulan yang diprediksi. Januari berada pada periode puncak musim hujan [23] dengan curah hujan CHIRPS aktual 375,33 mm/bulan. Laporan BMKG mengklasifikasikan Januari 2026 dengan sifat hujan Atas Normal [29] sehingga besarnya galat *underestimate* konsisten dengan kondisi bulan basah ekstrem yang cenderung dihaluskan oleh model. Juni berada pada periode puncak musim kemarau [23], dengan curah hujan CHIRPS aktual hanya 23,03 mm/bulan. Laporan BMKG mengklasifikasikan Juni 2026 dengan sifat hujan Bawah Normal [30], sehingga peta galat Juni 2026 *overestimate* pada seluruh grid konsisten dengan kondisi bulan kering ekstrem. Temuan evaluasi prediksi rekursif enam bulan ini mengindikasikan bahwa model belum merepresentasikan nilai ekstrem tinggi maupun rendah, sejalan dengan penghalusan ekstrem pada data uji. Propagasi galat pada langkah keenam tetap mungkin berkontribusi, tetapi tidak dapat dipisahkan dari pengaruh kondisi Juni yang ekstrem.

4.6 Perbandingan Metrik Berdasarkan Cakupan Spasial

Tabel 7 membandingkan metrik ConvLSTM-TE terpilih antara domain raster penuh (400 sel) dan wilayah administratif Bekasi setelah mask batas diterapkan. Perbandingan ini bukan untuk memilih model, melainkan untuk melihat sejauh mana cakupan spasial memengaruhi nilai metrik.

Tabel 7 Perbandingan metrik ConvLSTM-TE terpilih berdasarkan cakupan spasial

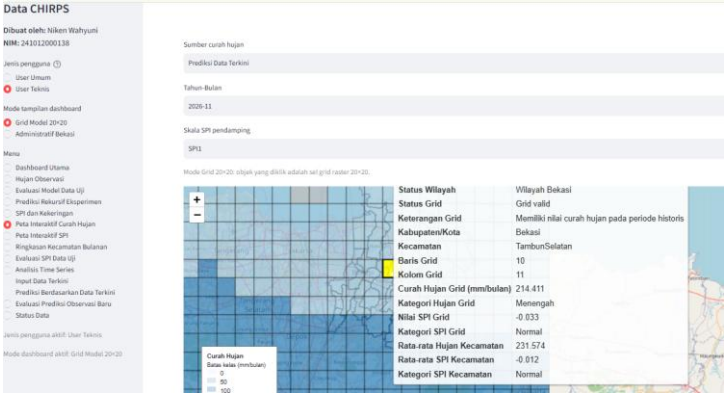
Cakupan	RMSE	MAE	r	R^2	RSR
Domain Model 20×20	82,368	59,024	0,868	75,25%	0,497
Wilayah Administratif Bekasi	77,967	60,421	0,775	58,38%	0,645

Tabel 7 menunjukkan bahwa metrik wilayah administratif tidak identik dengan metrik domain penuh. RMSE turun menjadi 77,967 mm/bulan karena bagian selatan domain yang paling basah dan bergalat tertinggi tidak tercakup, tetapi MAE naik menjadi 60,421 mm/bulan, r dan R^2 turun (0,775 dan 58,38%), dan RSR naik menjadi 0,645. Hal ini terjadi karena keragaman hujan di wilayah administratif lebih kecil dan sel laut bernilai nol tidak ikut dihitung. Tabel 7 hanya menggambarkan kinerja ConvLSTM-TE di Bekasi dan tidak digunakan untuk memilih model.

 ISSN:2302-8149
e-ISSN:2540-9719

4.7 Prototipe Dashboard

Konfigurasi ConvLSTM-TE terpilih diintegrasikan ke prototipe Streamlit untuk visualisasi spasial prediksi curah hujan bulanan di Kota dan Kabupaten Bekasi (Gambar 7). Setiap sel grid dipetakan ke kecamatan berdasarkan batas administrasi, sebagaimana ditunjukkan pada Gambar 7. Prototipe dapat diakses secara daring di https://prediksi-hujan-bekasi.streamlit.app/.



Gambar 7 Tampilan prototipe peta prediksi curah hujan interaktif

Gambar 7 memperlihatkan peta interaktif yang menampilkan distribusi curah hujan prediksi pada setiap grid wilayah Bekasi. Pengguna dapat memilih periode prediksi dan mengamati perbedaan intensitas hujan antarlokasi (berbasis batas administrasi kecamatan di wilayah Kota dan Kabupaten Bekasi). Prototipe ini mendemonstrasikan pemanfaatan model, sedangkan evaluasi kinerja tetap mengacu pada eksperimen dan verifikasi CHIRPS aktual.

4.8 Pembahasan

Pada eksperimen ini, kedua model rekuren-konvolusional menghasilkan galat lebih rendah daripada 3D CNN untuk urutan raster hujan bulanan. Fredyan dan Kusuma [17] melaporkan MAE 67,97 untuk ConvLSTM-attention pada CHIRPS 89×89, sedangkan ConvLSTM-TE memperoleh MAE 59,02 mm/bulan, perbandingan ini tidak setara karena domain dan periode berbeda, tetapi menunjukkan bahwa pendekatan kalender tetap kompetitif pada domain kecil (20×20) dan data relatif pendek (432 bulan). *Attention* memilih informasi antartimestep, sedangkan *temporal embedding* menyediakan posisi kalender, sehingga kombinasi keduanya layak diuji.

Temporal embedding merepresentasikan posisi kalender secara siklik melalui sinus–kosinus dan *embedding* yang dipelajari. Pada konfigurasi terbaik masing-masing arsitektur, RMSE ConvLSTM-TE sekitar 4,3% lebih rendah daripada ConvLSTM dan RSR-nya 0,497 dibandingkan 0,520. RSR 0,497 berada dekat ambang 0,50 pada kriteria Moriasi et al.[27], tetapi kriteria tersebut dikembangkan untuk simulasi hidrologi DAS, sehingga RSR hanya digunakan sebagai galat relatif untuk membandingkan model. Rui et al. [11], melaporkan bahwa pada lead time pendek, variasi iklim lebih dipengaruhi faktor meteorologi masukan sehingga model tanpa embedding memberikan hasil terbaik, sedangkan *temporal embedding* baru unggul pada lead time panjang. Pada penelitian ini, yang menggunakan *lead time* satu bulan, ConvLSTM-TE justru sedikit lebih baik daripada ConvLSTM, tetapi selisihnya kecil dan masih berada dalam rentang IQR. Hal ini sejalan dengan peran fitur kalender yang terbatas pada lead time pendek, meskipun arah hasilnya tidak sepenuhnya sama dengan Rui et al. Tanpa *ablation study* dan pengulangan *multi-seed*, kontribusi *embedding* tidak dapat dipisahkan dari kinerja arsitektur lengkap pada domain penelitian.

Perbandingan dengan rata-rata klimatologi menunjukkan bahwa sebagian besar kinerja model berasal dari kemampuan merepresentasikan siklus musiman, karena rata-rata klimatologi saja menjelaskan 71,54% variasi hujan bulanan pada periode uji. Nilai tambah ConvLSTM-TE dan ConvLSTM terhadap rata-rata klimatologi relatif kecil dan terutama berasal dari pengurangan galat besar pada anomali antartahun, sedangkan SS negatif 3D CNN menunjukkan bahwa konvolusi tiga dimensi belum melampaui pola rata-rata musiman pada dataset ini. Temuan ini menegaskan pentingnya pembanding klimatologi, karena r dan R^2 yang tinggi pada hujan bulanan dapat sebagian besar berasal dari siklus musiman. Model juga menghaluskan curah hujan ekstrem, baik pada data uji maupun evaluasi 2026 (*underestimate* Januari dan *overestimate* Juni). Penghalusan ini mungkin

 ISSN:2302-8149
e-ISSN:2540-9719

berkaitan dengan loss MSE pada distribusi menceng, tetapi pengaruhnya belum dapat dipisahkan dari karakter data dan arsitektur, dan evaluasi independen baru mencakup enam bulan.

5 Kesimpulan

Perbandingan pada domain CHIRPS 20×20 Bekasi dan sekitarnya (1990–2025) menunjukkan bahwa konfigurasi terbaik ConvLSTM-TE yang dipilih berdasarkan RMSE data uji menghasilkan galat terkecil (RMSE 82,368 mm/bulan, MAE 59,024 mm/bulan, r = 0,868, R^2 = 75,25%, RSR = 0,497), diikuti ConvLSTM (86,048 mm/bulan) dan 3D CNN (96,347 mm/bulan). Nilai ini merupakan batas atas karena pemilihan menggunakan data uji. Ketiga model lebih akurat daripada persistensi, tetapi hanya kedua model berbasis ConvLSTM yang melampaui klimatologi (skill score RMSE 6,8% dan 2,6%) dengan MAE yang setara, sedangkan 3D CNN belum melampaui klimatologi dan paling sensitif terhadap hiperparameter. Pada median seluruh pelatihan (86,568 mm/bulan) dan seleksi berbasis *validation loss*, ConvLSTM-TE tetap memiliki RMSE terendah, tetapi selisihnya terhadap ConvLSTM lebih kecil daripada IQR kedua arsitektur sehingga dibaca sebagai kecenderungan pada satu *holdout*. Model mempertahankan gradien spasial dan fase musiman, tetapi menghaluskan ekstrem. Pemeriksaan pada CHIRPS 2026 menghasilkan MAE 57,15 mm/bulan, sebanding dengan MAE pada data uji. Penelitian lanjutan perlu menguji pengulangan *multi-seed*, *ablation study*, *weighted loss*, prediktor iklim global untuk meningkatkan skill terhadap klimatologi, dan *direct multi-step forecasting*. Model terpilih telah diterapkan pada prototipe Streamlit untuk visualisasi curah hujan bulanan berdasarkan batas administratif kecamatan di wilayah Bekasi.

Referensi

[1] BMKG, *Atlas Proyeksi Bencana Hidrometeorologi*. Jakarta: Pusat Perubahan Iklim, 2022.

[2] A. Kurniadi, E. Weller, J. Salmond, and E. Aldrian, "*Future Projections of Extreme Rainfall Events in Indonesia*," *International Journal of Climatology*, Vol. 44, No. 1, pp. 160–182, 2024, DOI: 10.1002/joc.8321.

[3] M. Gebremichael and W. F. Krajewski, "*Assessment of the Statistical Characterization of Small-Scale Rainfall Variability from Radar: Analysis of TRMM Ground Validation Datasets*," *Journal of Applied Meteorology and Climatology*, Vol. 43, No. 8, pp. 1180–1199, 2004, DOI: 10.1175/1520-0450(2004)043<1180:AOTSCO>2.0.CO;2.

[4] A. Kurniawan *et al.*, "Analisis Perkembangan Wilayah Kabupaten Bekasi dan Kota Bekasi berdasarkan Peraturan Presiden Nomor 60 Tahun 2020," *Spatial Review for Sustainable Development*, Vol. 1, No. 1, pp. 44–57, 2024, DOI: 10.61511/srsd.v1i1.2024.715.

[5] Badan Nasional Penanggulangan Bencana, "Data dan Informasi Bencana Indonesia (DIBI)." Accessed: Jan. 03, 2026. [Online]. Available: https://dibi.bnpb.go.id

[6] S. Siswanto *et al.*, "*Satellite-based Meteorological Drought Indicator to Support Food Security in Java Island*," *PLoS ONE*, Vol. 17, No. 6, p. e0260982, 2022, DOI: 10.1371/journal.pone.0260982.

[7] W. T. Abebe and D. Endalie, "*Artificial Intelligence Models for Prediction of Monthly Rainfall without Climatic Data for Meteorological Stations in Ethiopia*," *Journal of Big Data*, Vol. 10, No. 2, 2023, DOI: 10.1186/s40537-022-00683-3.

[8] W. G. Kurnia, "Prediksi Curah Hujan Bulanan menggunakan Multi Prediktor di Zom 313 Sulawesi Tenggara," *Megasains*, Vol. 13, No. 01, pp. 1–5, 2022, DOI: 10.46824/megasains.v13i01.44.

[9] C. Chen *et al.*, "*Forecast of Rainfall Distribution based on Fixed Sliding Window Long Short-Term Memory*," *Engineering Applications of Computational Fluid Mechanics*, Vol. 16, No. 1, pp. 248–261, 2022, DOI: 10.1080/19942060.2021.2009374.

[10] X. Shi, Z. Chen, H. Wang, D. Y. Yeung, W. K. Wong, and W. C. Woo, "*Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting*," in *Advances in Neural Information Processing Systems*, 2015, pp. 802–810. DOI: 10.48550/arXiv.1506.04214.

[11] C. Rui, Z. Sun, W. Zhang, A. A. Liu, and Z. Wei, "*Enhancing ENSO Predictions with Self-Attention ConvLSTM and Temporal Embeddings*," *Frontiers in Marine Science*, Vol. 11, pp. 1–16, 2024, DOI: 10.3389/fmars.2024.1334210.

[12] E. Phermphoonphiphat, T. Tomita, T. Morita, M. Numao, and K. I. Fukui, "*Soft Periodic*

 ISSN:2302-8149
e-ISSN:2540-9719

Convolutional Recurrent Network for Spatiotemporal Climate Forecast," *Applied Sciences (Switzerland)*, Vol. 11, No. 20, 2021, DOI: 10.3390/app11209728.

[13] F. Yu and H. Hao, "*An Ensemble 3D Convolutional Neural Network for Spatiotemporal Soil Temperature Forecasting*," *Sustainability*, Vol. 13, No. 16, p. 9174, 2021, DOI: 10.3390/su13169174.

[14] D. Niu, L. Diao, L. Xu, Z. Zang, X. Chen, and S. Liang, "*Precipitation Forecast based on Multi-Channel ConvLSTM and 3D-CNN*," in *International Conference on Unmanned Aircraft Systems (ICUAS)*, Athens, Greece, 2020, pp. 367–371. DOI: 10.1109/ICUAS48674.2020.9213930.

[15] A. H. Murphy, "*Skill Scores based on the Mean Square Error and Their Relationships to the Correlation Coefficient*," *Monthly Weather Review*, Vol. 116, No. 12, pp. 2417–2424, 1988, DOI: 10.1175/1520-0493(1988)116<2417:SSBOTM>2.0.CO;2.

[16] I. Mahmud, S. H. Bari, and M. T. Ur Rahman, "*Monthly Rainfall Forecast of Bangladesh using Autoregressive Integrated Moving Average Method*," *Environmental Engineering Research*, Vol. 22, No. 2, pp. 162–168, 2017, DOI: 10.4491/eer.2016.075.

[17] R. Fredyan and G. P. Kusuma, "*Spatiotemporal Convolutional LSTM with Attention Mechanism for Monthly Rainfall Prediction*," *Communications in Mathematical Biology and Neuroscience*, Vol. 2022, p. 118, 2022, DOI: 10.28919/cmbn/7761.

[18] D. Tran, L. Bourdev, R. Fergus, L. Torresani, and M. Paluri, "*Learning Spatiotemporal Features with 3D Convolutional Networks*," in *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile: IEEE, 2015, pp. 4489–4497. DOI: 10.1109/ICCV.2015.510.

[19] C. Funk *et al.*, "*The Climate Hazards Infrared Precipitation with Stations - A New Environmental Record for Monitoring Extremes*," *Scientific Data*, Vol. 2, pp. 1–21, 2015, DOI: 10.1038/sdata.2015.66.

[20] S. T. da Silva *et al.*, "*Rainfall Forecast in Brazil using Machine Learning*," *Chaos An Interdisciplinary Journal of Nonlinear Science*, Vol. 35, No. 073116, pp. 1–12, 2025, DOI: 10.1063/5.0259222.

[21] TensorFlow, "*tf.keras.layers.ConvLSTM2D*." [Online]. Available: https://www.tensorflow.org/api_docs/python/tf/keras/layers/ConvLSTM2D

[22] N. de A. Moreira *et al.*, "*Convolutional Long-Short-Term Memory Networks (ConvLSTM) for Weather Prediction using Radar and Satellite Images*," *Proceedings do XXIV Congresso Brasileiro de Automática*, 2022, DOI: 10.20906/cba2022/3299.

[23] Badan Meteorologi Klimatologi dan Geofisika, *Pemutakhiran Zona Musim Indonesia, Periode 1991–2020*. Jakarta, Indonesia: BMKG, 2022. [Online]. Available: https://iklim.bmkg.go.id/bmkgadmin/storage/buletin/Buku_ZOM9120_versi_cetak.pdf

[24] R. Hidayat and K. Ando, "Variabilitas Curah Hujan Indonesia dan Hubungannya dengan ENSO/IOD: Estimasi menggunakan Data *JRA-25/JCDAS*," *Journal Agromet*, Vol. 28, No. 1, pp. 1–8, 2014, DOI: 10.29244/j.agromet.28.1.1-8.

[25] E. Aldrian, L. Dümenil Gates, and F. H. Widodo, "*Seasonal Variability of Indonesian Rainfall in ECHAM4 Simulations and in the Reanalyses: The Role of ENSO*," *Theoretical and Applied Climatology*, Vol. 87, No. 1–4, pp. 41–59, 2007, DOI: 10.1007/s00704-006-0218-8.

[26] A. N. Aïzansi, K. O. Ogunjobi, and F. K. Ogou, "*Monthly Rainfall Prediction using Artificial Neural Network (Case Study: Republic of Benin)*," *Environmental Data Science*, Vol. 3, No. 11, pp. 1–25, 2024, DOI: 10.1017/eds.2024.10.

[27] D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, and T. L. Veith, "*Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations*," *Transactions of the ASABE*, Vol. 50, No. 3, pp. 885–900, 2007, DOI: 10.13031/2013.23153.

[28] S. Ben Taieb, G. Bontempi, A. F. Atiya, and A. Sorjamaa, "*A Review and Comparison of Strategies for Multi-Step Ahead Time Series Forecasting based on the NN5 Forecasting Competition*," *Expert Systems with Applications*, Vol. 39, No. 8, pp. 7067–7083, 2012, DOI: 10.1016/j.eswa.2012.01.039.

[29] Stasiun Klimatologi Jawa Barat, *Buletin Informasi Iklim*, Februari. Bogor: Stasiun Klimatologi Jawa Barat, 2026. [Online]. Available: https://staklimjabar.id/2026/02/21/buletin-iklim-

ISSN:2302-8149
e-ISSN:2540-9719

bulanan-edisi-februari-2026/#flipbook-df_37/1/

[30] Stasiun Klimatologi Jawa Barat, *Buletin Informasi Iklim*, Juli 2026. Bogor: Stasiun Klimatologi Jawa Barat, 2026. [Online]. Available: https://staklimjabar.id/2026/07/22/buletin-iklim-bulanan-edisi-juli-2026/#flipbook-df_77/1/