

BAB V

PENUTUP

5.1 Kesimpulan

Pada penelitian ini penulis dapat menyimpulkan bahwa

1. Data GSMap memiliki tingkat kesalahan yang lebih kecil dibandingkan GPM IMERG ketika dibandingkan dengan data AWS. Hal ini ditunjukkan oleh nilai MAE yang lebih rendah yaitu sebesar 0,5252 mm/jam dan RMSE sebesar 1,4997 mm/jam, serta nilai MBE = -0,0168 mm/jam. Sebaliknya, GPM IMERG menghasilkan nilai error yang lebih tinggi dengan MAE sebesar 0.8804 mm/jam dan RMSE sebesar 2,8260 mm/jam, di mana nilai MBE positif (+0,5134 mm/jam) mengindikasikan cenderung mengalami kecenderungan *overestimation*. Dari aspek keselarasan pola temporal linier, GPM IMERG unggul dengan korelasi Pearson yang lebih kuat 0,4105, dibandingkan GSMap 0,3083, Hal ini menunjukkan bahwa GPM IMERG lebih sensitif dan akurat dalam mengidentifikasi waktu terjadinya puncak-puncak peristiwa hujan, meskipun besaran volumenya cenderung lebih tinggi.
2. Pengujian awal menggunakan model Pre-Trained pada data AWS memberikan performa dasar yang seimbang, di mana XGBoost *pre-trained* memperoleh F1-Score 0,563 (ROC-AUC 0,809) dan LSTM *pre-trained* memperoleh F1-Score 0,560 (ROC-AUC 0,771). Setelah melalui tahap *fine-tuning*, LSTM *fine-tuned* menjadi model terbaik dan paling presisi melalui peningkatan kinerja klasifikasi yang signifikan F1-Score naik ke 0,618

dengan ROC-AUC ke 0,867 serta keberhasilan menekan deviasi eror regresi volume hujan hingga paling minimal (MAE turun dari 1,931 ke 1,530 mm/jam; RMSE dari 3,429 ke 3,186 mm/jam). Sebaliknya, *fine-tuning* pada XGBoost membuat model lebih konservatif dengan *Precision* tertinggi (0,695), namun sensitivitas deteksinya menurun dengan nilai Recall dari 0,521 turun ke 0,452 dan nilai F1-Score dari 0,563 turun ke 0,548. Seluruh model mencatatkan bias negatif yang mengindikasikan *underestimation* ringan. Secara keseluruhan, mekanisme memori sekuensial waktu pada algoritma LSTM terbukti lebih adaptif dalam mentransfer pola pre-trained ke dinamika atmosfer lokal dibandingkan algoritma XGBoost.

5.2 Saran

Pada penelitian selanjutnya penulis memiliki saran bagi penulis selanjutnya jika ingin melanjutkan atau menggunakan sebagian metode dari penelitian ini yang antara lain.

1. Dapat menggunakan data observasi curah hujan dari beberapa titik lokasi pengamatan untuk meningkatkan akurasi analisis.
2. Meskipun model LSTM dan XGBoost telah berhasil melihat pola dinamika atmosfer secara tersirat melalui variabel makro dan satelit, keterbatasan resolusi spasial data reanalisis membuat variabilitas cuaca lokal yang bersifat lokal belum sepenuhnya tertangkap. Oleh karena itu, penelitian selanjutnya disarankan menggunakan metode *downscaling spasial* yang lain, misal mengintegrasikan data radar cuaca lokal sebagai data validasi tambahan selain data AWS.

3. Untuk penelitian selanjutnya, disarankan tidak hanya bertumpu pada metrik statistik sains data standar (Precision, Recall, F1-Score), melainkan mengintegrasikan metrik verifikasi kategorikal standar WMO (*World Meteorological Organization*). Penggunaan metrik seperti *Heidke Skill Score* (HSS), *Probability of Detection* (POD), *Critical Success Index* (CSI), dan *Equitable Threat Score* (ETS) sangat direkomendasikan untuk menguji kemampuan fisis (*forecast skill*) model dalam memprediksi kejadian cuaca ekstrem skala lokal tanpa terdistorsi oleh masalah ketidakseimbangan data (*zero-inflation*

