

Mekanisme *Quality Control* LightGBM Berbasis Fitur Geospasial untuk Meningkatkan Akurasi Lokalisasi Hybrid TDOA-AOA Sumber Frekuensi Radio Siaran FM

Nurul Muttaqien*, Ema Utami

Fakultas Ilmu Komputer, PJJ Informatika, Universitas Amikom Yogyakarta, Yogyakarta, Indonesia

Email: ^{1,*}muttaqien@students.amikom.ac.id, ²ema.u@amikom.ac.id

Email Penulis Korespondensi: muttaqien@students.amikom.ac.id

Submitted 07-08-2026; Accepted 22-08-2026; Published 31-08-2026

Abstrak

Lokalisasi sumber frekuensi radio Hybrid *Time Difference of Arrival* (TDOA) dan *Angle of Arrival* (AOA) pada lingkungan *Non Line of Sight* (NLOS) mengalami penurunan akurasi akibat propagasi multipath dan hambatan topografi. Penelitian ini mengusulkan *quality control* berbasis *Light Gradient Boosting Machine* (LightGBM) dengan mengintegrasikan fitur geospasial *Digital Elevation Model Nasional* (DEMNAS) beresolusi 8 m untuk meningkatkan akurasi estimasi posisi. Evaluasi dilakukan menggunakan 15.519 sampel pengukuran radio siaran FM di wilayah Yogyakarta dengan validasi silang *spatial block* 10 lipatan. Hasil penelitian menunjukkan bahwa model yang mengintegrasikan fitur sinyal dan geospasial dapat menurunkan RMSE dari 521,58 m menjadi 118,81 m atau sebesar 77,22%. Model juga mencapai *F1-Score* sebesar 0,9991 dengan kontribusi fitur geospasial sebesar 49,8% terhadap proses klasifikasi. Pada kondisi NLOS ekstrem, RMSE berkurang dari 1449 m menjadi 205,81 m atau sebesar 85,8%, serta mempertahankan kemampuan generalisasi pada pengujian *Leave One Block Out* (LOBO) dengan RMSE di bawah 170 m. Hasil penelitian menunjukkan bahwa integrasi LightGBM dan fitur geospasial efektif meningkatkan akurasi hasil lokalisasi Hybrid TDOA-AOA sebagai mekanisme *quality control* pasca lokalisasi. Secara praktis, hasil penelitian dapat mendukung lokalisasi yang lebih efektif dalam pengawasan spektrum frekuensi radio. Keterbatasan penelitian terletak pada kemampuan model dalam mengidentifikasi kondisi multipath masih memiliki *recall* sebesar 72,54% sehingga pengembangan fitur geospasial yang lebih representatif berpotensi meningkatkan kinerja model pada penelitian selanjutnya.

Kata Kunci: Lokalisasi Frekuensi Radio; Hybrid TDOA-AOA; LightGBM; *Quality Control*; Fitur Geospasial

Abstract

The localization of radio frequency sources using Hybrid Time Difference of Arrival (TDOA) and Angle of Arrival (AOA) in Non-Line-of-Sight (NLOS) environments suffers from reduced accuracy due to multipath propagation and topographic obstacles. This study proposes a quality control method based on Light Gradient Boosting Machine (LightGBM) by integrating geospatial features from the 8 m resolution National Digital Elevation Model (DEMNAS) to improve the accuracy of position estimates. The evaluation was conducted using 15,519 samples of FM radio broadcast measurements in the Yogyakarta region with 10-fold spatial block cross-validation. The results show that the model integrating signal and geospatial features can reduce the RMSE from 521.58 m to 118.81 m, a reduction of 77.22%. The model also achieved an F1-Score of 0.9991, with geospatial features contributing 49.8% to the classification process. Under extreme NLOS conditions, the RMSE decreased from 1,449 m to 205.81 m, representing a reduction of 85.8%, while maintaining generalization capability in the Leave One Block Out (LOBO) test with an RMSE below 170 m. The research results show that the integration of LightGBM and geospatial features effectively improves the accuracy of Hybrid TDOA-AOA localization results as a post-localization quality control mechanism. Practically, the research results can support more effective localization in radio frequency spectrum monitoring. A limitation of this study is that the model's ability to identify multipath conditions still has a recall of 72.54%. Therefore, the development of more representative geospatial features has the potential to improve the model's performance in future research..

Keywords: Radio Frequency Localization; Hybrid TDOA-AOA; LightGBM; Quality Control; Geospatial Features

1. PENDAHULUAN

Lokalisasi sumber frekuensi radio merupakan bagian penting dalam monitoring spektrum, penanganan interferensi, penegakan regulasi, dan layanan berbasis lokasi [1]. Akurasi estimasi posisi sangat menentukan efektivitas pengawasan spektrum karena kesalahan lokalisasi dapat meningkatkan waktu dan biaya operasional [2]. Metode berbasis geometri seperti *Time Difference of Arrival* (TDOA) dan *Angle of Arrival* (AOA) banyak digunakan untuk mengestimasi posisi pemancar berdasarkan informasi waktu dan sudut kedatangan sinyal [3]. Integrasi keduanya melalui skema Hybrid TDOA-AOA dapat memberikan estimasi posisi lebih akurat dibandingkan penggunaan TDOA atau AOA secara terpisah [3]. Namun, penerapannya di lingkungan nyata masih dipengaruhi oleh propagasi *multipath*, kondisi *Non Line of Sight* (NLOS) dan kesalahan pengukuran akibat bertambahnya jarak antara pemancar dan stasiun penerima [4], [5].

Beberapa penelitian telah menerapkan *machine learning* untuk meningkatkan kinerja lokalisasi sumber frekuensi radio [6], [7]. Singh et al. mengembangkan XGBLoc berbasis XGBoost dioptimalkan menggunakan *Principal Component Analysis* (PCA) untuk klasifikasi posisi berbasis *Received Signal Strength Indicator* (RSSI) [8]. Pada pendekatan berbasis *ensemble learning*, de Sousa et al. menggabungkan *ray tracing fingerprint*, Random Forest dan *gradient boosting* untuk meningkatkan akurasi lokalisasi TDOA pada lingkungan *outdoor* kompleks [9]. Sedangkan, Chen et al. menggunakan Random Forest dalam sistem RadioLoc untuk pemrosesan sinyal FM [10]. Lebih lanjut, Wang et al. dan Cui et al. menerapkan LightGBM untuk estimasi *Direction of Arrival* (DOA) dan penentuan posisi UWB Wireless dengan mempertimbangkan kondisi NLOS [11], [12]. Berbeda dengan pendekatan tersebut, Chen et al. menggunakan *deep*

learning berbasis CNN untuk mengatasi kesalahan NLOS [13], sedangkan Son et al. mengembangkan D-TLoc berbasis DNN untuk memetakan pengukuran TDOA menjadi koordinat tiga dimensi [1].

Masing-masing pendekatan memiliki karakteristik dan keterbatasan. Singh et al. menyampaikan bahwa XGBoost memerlukan penyetelan *hyperparameter* untuk memperoleh kinerja konsisten dan mengurangi risiko *overfitting* [8]. Chen et al. menunjukkan bahwa Random Forest relatif robust terhadap *outlier*, tetapi kinerjanya masih dipengaruhi oleh *multipath* [10]. Selanjutnya, Wang et al. melaporkan bahwa LightGBM memiliki efisiensi komputasi lebih baik, tetapi kinerjanya dapat menurun pada kondisi *Signal to Noise Ratio* (SNR) rendah [11]. Di sisi lain, Son et al. menunjukkan bahwa DNN dapat digunakan untuk estimasi posisi tetapi membutuhkan data pelatihan dan sumber daya komputasi lebih besar [1].

Integrasi fitur geospasial ke dalam model *machine learning* dapat dilakukan untuk memberikan informasi tambahan mengenai kondisi lingkungan yang memengaruhi propagasi sinyal. Topografi, elevasi, dan obyek fisik seperti perbukitan dan bangunan dapat berkaitan dengan kondisi LOS, NLOS, dan *multipath* serta memengaruhi kesalahan lokalisasi [13]. Informasi spasial tersebut dapat digunakan sebagai fitur untuk mengidentifikasi hubungan antara kondisi lingkungan dan kesalahan estimasi posisi [13]. Dengan demikian, fitur geospasial dapat digunakan untuk membedakan tingkat keandalan hasil lokalisasi dan mendukung proses penyaringan estimasi posisi yang kurang akurat. [13].

Berdasarkan tinjauan penelitian terdahulu, sebagian besar pendekatan berfokus pada peningkatan akurasi estimasi posisi melalui pengembangan algoritma lokalisasi, *deep learning* atau *ensemble learning*. Namun, masih terbatas penelitian yang menggunakan model *machine learning* sebagai mekanisme *quality control* untuk menilai keandalan hasil Hybrid TDOA-AOA setelah proses lokalisasi. Selain itu, pemanfaatan informasi geospasial sebagai bagian dari proses lokalisasi juga masih terbatas. Oleh karena itu, penelitian ini mengembangkan *Quality Control* LightGBM berbasis fitur geospasial yang berfungsi sebagai mekanisme *gating* untuk mengidentifikasi estimasi Hybrid TDOA-AOA yang reliabel sehingga dapat meningkatkan akurasi lokalisasi dibandingkan sistem awal (*baseline*). LightGBM dipilih karena mampu memproses dataset berskala besar secara efisien dengan kebutuhan memori rendah [11]. Namun, performanya dapat menurun akibat keberadaan *outlier* dan anomali propagasi yang menyebabkan hasil lokalisasi menjadi tidak stabil [12]. Kontribusi penelitian ini meliputi: (1) pengembangan mekanisme *quality control* berbasis LightGBM untuk menilai keandalan hasil lokalisasi Hybrid TDOA-AOA, (2) integrasi fitur geospasial DEMNAS sebagai representasi kondisi lingkungan dalam proses klasifikasi, (3) evaluasi generalisasi model menggunakan *10-fold Spatial Block Cross-Validation* dan *Leave One Block Out* (LOBO) untuk menguji kinerja pada wilayah spasial yang tidak digunakan dalam pelatihan, dan (4) evaluasi pengaruh mekanisme *quality control* terhadap akurasi hasil lokalisasi untuk mendukung pengawasan spektrum frekuensi radio.

2. METODOLOGI PENELITIAN


Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif untuk mengembangkan dan mengevaluasi *Quality Control (QC) Classifier* berbasis LightGBM pada sistem lokalisasi Hybrid TDOA-AOA. Penelitian diawali dengan pengumpulan dataset primer hasil lokalisasi Hybrid TDOA-AOA dari Stasiun Monitoring Frekuensi Radio (SMFR) Balai Monitor Spektrum Frekuensi Radio Kelas I Yogyakarta, kemudian dilanjutkan dengan *preprocessing* data, ekstraksi fitur geospasial, pembentukan label kualitas lokalisasi berdasarkan nilai kesalahan posisi, pelatihan dan optimasi model LightGBM, serta evaluasi kinerja model menggunakan metrik klasifikasi. Selanjutnya, model yang telah dilatih diintegrasikan sebagai mekanisme *quality control* untuk mengidentifikasi hasil lokalisasi yang reliabel sebelum digunakan pada proses analisis berikutnya. Rangkaian tahapan penelitian yang diusulkan ditunjukkan pada Gambar 1.

2.1 Dataset

Dataset yang digunakan terdiri atas 15.519 sampel hasil pengukuran Hybrid TDOA-AOA pada pita frekuensi radio siaran FM 87,5-108 MHz di wilayah Yogyakarta. Setiap sampel memuat fitur TDOA dan AOA dari tiga stasiun monitoring, korelasi puncak, estimasi posisi awal sistem (*sys_latitude* dan *sys_longitude*), serta koordinat pengguna frekuensi berlisensi sebagai *ground truth*. Selain itu, fitur geospasial berasal dari *Digital Elevation Model Nasional* (DEMNAS) beresolusi 8 m diekstraksi menjadi bentuk numerik, kemudian diintegrasikan dengan fitur TDOA-AOA sebagai masukan model LightGBM untuk merepresentasikan karakteristik lingkungan yang memengaruhi propagasi sinyal.

Penelitian ini menggunakan studi kasus di Balai Monitor Spektrum Frekuensi Radio Kelas I Yogyakarta. Pemilihan wilayah Yogyakarta didasarkan pada tingkat heterogenitas topografi yang tinggi sehingga dapat menjadi lokasi representatif untuk mengevaluasi kinerja sistem lokalisasi pada berbagai kondisi propagasi. Secara geografis, wilayah ini mencakup lereng Gunung Merapi di bagian utara, Perbukitan Menoreh di barat laut yang memberikan variasi elevasi berdasarkan DEM, kawasan perkotaan padat di pusat kota yang berpotensi menimbulkan refleksi, difraksi, dan hamburan sinyal akibat kepadatan bangunan serta wilayah vegetasi dan pesisir di bagian selatan dengan karakteristik propagasi berbeda. Keberagaman kondisi geospasial tersebut memberikan lingkungan pengujian yang komprehensif untuk mengevaluasi kemampuan model LightGBM dalam memanfaatkan informasi spasial sebagai *prior* lingkungan pada proses *quality control*. Dengan demikian, validitas model yang dikembangkan tidak hanya dievaluasi pada lingkungan perkotaan ideal, tetapi juga pada wilayah dengan karakteristik geospasial kompleks sehingga hasil penelitian diharapkan lebih mencerminkan kondisi operasional sistem monitoring frekuensi radio di lapangan.

2.2 Tahapan Penelitian



Gambar 1. Tahapan Penelitian

2.3 Preprocessing dan Feature Engineering

Tahap *preprocessing* dilakukan untuk memastikan kualitas dan konsistensi data sebelum pelatihan model. *Outlier* diidentifikasi menggunakan metode *Interquartile Range* (IQR) dengan ambang $1,5 \times \text{IQR}$. Sampel yang memiliki galat lebih dari 314 m tidak dihapus untuk menghindari hilangnya karakteristik propagasi ekstrem tetapi ditangani melalui *target clipping* pada kuantil 99,5% untuk tugas regresi residual dan pembentukan label biner *good* (galat ≤ 314 m) dan *bad* (galat > 314 m) pada *QC Classifier*. Seluruh fitur numerik kemudian dinormalisasi menggunakan *Min-Max Scaling* ke rentang $[0,1]$, sedangkan sudut AOA ditransformasikan ke representasi sinus dan cosinus untuk mempertahankan sifat periodik dan menghindari diskontinuitas pada sudut 0° dan 360° .

Selain tahap *preprocessing*, dilakukan *feature engineering* untuk meningkatkan representasi karakteristik propagasi sinyal. Fitur sinyal dibangun dari pengukuran TDOA, AOA, nilai korelasi puncak, parameter *RMS error*, parameter elips galat dan berbagai fitur turunan seperti rasio TDOA antar pasangan sensor, statistik distribusi TDOA (*mean*, *standard deviation*), representasi berbobot konfidensi AOA serta indikator kualitas pengukuran. *Feature engineering* bertujuan meningkatkan kemampuan model dalam menangkap hubungan nonlinier antara karakteristik sinyal dan kualitas estimasi posisi sehingga lebih representatif dibandingkan penggunaan fitur mentah (*raw features*) secara langsung.

2.4 Hybrid TDOA-AOA

Hybrid TDOA-AOA merupakan metode lokalisasi yang menggabungkan pengukuran TDOA dan AOA untuk memperoleh estimasi posisi sumber frekuensi secara lebih akurat dibandingkan penggunaan masing-masing metode secara terpisah [3]. Hybrid TDOA-AOA memanfaatkan informasi geometris yang saling melengkapi, yaitu kurva hiperbola hasil pengukuran TDOA dan garis arah (*bearing line*) hasil pengukuran AOA sehingga mampu mengurangi ambiguitas estimasi serta meningkatkan robustitas proses lokalisasi [3]. Penelitian-penelitian terkini menunjukkan bahwa integrasi kedua jenis pengukuran tersebut mampu meningkatkan akurasi lokalisasi pada berbagai skenario, termasuk lingkungan dengan propagasi kompleks dan kondisi NLOS [4], [14].

Persamaan dasar TDOA yang menunjukkan hubungan antara selisih waktu kedatangan dan jarak dinyatakan sebagai berikut: [3]

$$\Delta d_{ij} = c \Delta t_{ij} \quad (1)$$

dimana Δd_{ij} adalah selisih jarak antara sensor i dan sensor referensi j (m), c adalah kecepatan rambat gelombang elektromagnetik (m/s), dan Δt_{ij} adalah selisih waktu kedatangan sinyal (s) [3]. Selanjutnya model geometris TDOA dirumuskan sebagai: [3]

$$[|p - s_i| - |p - s_j| = c \Delta t_{ij}] \quad (2)$$

dengan $p = [x, y]^T$ merupakan koordinat sumber sinyal dan $s_i = [x_i, y_i]^T$ adalah koordinat sensor ke- i [3]. Sedangkan, model pengukuran AOA dinyatakan sebagai: [3]

$$\theta_i = \tan^{-1} \left(\frac{y - y_i}{x - x_i} \right) \quad (3)$$

dengan θ_i adalah sudut kedatangan sinyal yang diukur oleh sensor ke- i [3]. Integrasi pengukuran TDOA dan AOA dilakukan menggunakan fungsi objektif *Weighted Least Squares* (WLS) sebagai berikut: [3]

$$J(p) = r^T W r \quad (4)$$

dimana r merupakan vektor residual pengukuran TDOA dan AOA, sedangkan W adalah matriks bobot yang diperoleh dari invers matriks kovarians *error* [3]. Estimasi posisi sumber diperoleh dengan mencari koordinat minimal fungsi objektif tersebut, yaitu: [3]

$$\hat{p} = \arg \min_p J(p) \quad (5)$$

Persamaan (1) hingga (5) menjadi dasar proses lokalisasi sistem Hybrid TDOA-AOA yang digunakan dalam penelitian ini. Hasil estimasi posisi algoritma hybrid selanjutnya digunakan sebagai masukan model *Quality Control LightGBM* untuk mengidentifikasi estimasi dengan tingkat kepercayaan tinggi sebelum dilakukan analisis lebih lanjut.

2.5 Quality Control LightGBM

2.5.1 Konsep Quality Control Classifier

Akurasi sistem lokalisasi sumber frekuensi pada lingkungan NLOS sangat dipengaruhi propagasi *multipath*, difraksi, hamburan sinyal dan bias pengukuran TDOA maupun AOA sehingga setiap hasil estimasi memiliki tingkat keandalan yang berbeda [15], [16]. Pendekatan konvensional umumnya menggunakan model regresi atau algoritma mitigasi kesalahan untuk mengoreksi seluruh hasil estimasi, namun pendekatan tersebut kurang efektif pada kondisi propagasi kompleks karena adanya ketidakpastian aleatorik (*aleatoric uncertainty*) dan perubahan karakteristik spasial (*spatial domain shift*) [15]. Sebagai alternatif, paradigma *selective prediction* atau *selective classification* memberikan kemampuan model hanya menghasilkan prediksi pada sampel dengan tingkat kepercayaan tinggi, sedangkan sampel dengan tingkat kepercayaan rendah dapat ditolak (*reject*) atau diproses lebih lanjut [17], [18].

Berdasarkan paradigma tersebut, penelitian ini menerapkan *QC Classifier* sebagai mekanisme *gating* untuk mengevaluasi keandalan hasil estimasi awal Hybrid TDOA-AOA [17], [18]. *QC Classifier* mengklasifikasikan setiap estimasi ke dalam dua kategori yaitu *good* dan *bad*. Estimasi *good* apabila prediksi memiliki tingkat keandalan tinggi dan dipertahankan sebagai hasil akhir, sedangkan estimasi *bad* diperkirakan mengandung kesalahan besar sehingga ditolak atau diproses lebih lanjut menggunakan metode koreksi lainnya [17], [19].

2.5.2 GBM (Gradient Boosting Machine)

Gradient Boosting Machine (GBM) merupakan metode *ensemble learning* yang membangun model prediksi secara iteratif dengan menggabungkan sejumlah *weak learner*, umumnya berupa pohon keputusan dangkal menjadi *strong learner* [20]. Pada setiap iterasi, model baru dilatih untuk memprediksi residual dari model sebelumnya menggunakan prinsip *gradient descent* pada ruang fungsi [20], [21]. Untuk dataset $\{(x_i, y_i)\}_{i=1}^N$, fungsi prediksi GBM dirumuskan sebagai berikut: [21]

$$F(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (6)$$

dengan $h_m(x)$ menyatakan *weak learner* ke- m dan γ_m sebagai bobot yang diperoleh melalui minimisasi fungsi *loss* $L(y, F(x))$ [21]. Pada setiap iterasi, model menambahkan *weak learner* yang paling efektif dalam mengurangi gradien *loss* sehingga kesalahan prediksi berkurang secara bertahap [20], [21]. GBM memiliki akurasi tinggi, fleksibel terhadap berbagai fungsi *loss*, serta mampu menangani data dengan distribusi tidak normal [22]. Namun, proses pelatihannya relatif lambat dan membutuhkan sumber daya komputasi yang lebih besar pada dataset berskala besar sehingga mendorong pengembangan algoritma yang lebih efisien seperti XGBoost dan LightGBM [22].

2.5.3 LightGBM (Light Gradient Boosting Machine)

LightGBM merupakan pengembangan dari GBM yang dirancang untuk meningkatkan efisiensi pelatihan pada dataset berskala besar [11], [12]. LightGBM menggunakan dua mekanisme utama yaitu *Gradient based One Side Sampling* (GOSS) dan *Exclusive Feature Bundling* (EFB) [11], [12]. GOSS mempertahankan sampel dengan gradien besar serta mengambil sebagian sampel bergradien kecil secara acak sehingga mampu mengurangi jumlah data pelatihan tanpa menurunkan akurasi secara signifikan [11]. Sementara itu, EFB menggabungkan fitur-fitur yang saling eksklusif ke dalam satu kelompok untuk mengurangi dimensi fitur, sehingga mempercepat proses pelatihan dan menekan penggunaan memori [11]. Melalui mekanisme tersebut, LightGBM mampu menghasilkan model yang akurat dengan waktu komputasi lebih efisien dibandingkan GBM konvensional [11], [12]. Secara matematis, LightGBM membangun model secara aditif melalui kumpulan pohon keputusan yang dinyatakan dengan persamaan sebagai berikut: [12]

$$f_T(x) = \sum_{t=1}^T T_t(x) \quad (7)$$

dengan T menyatakan jumlah pohon keputusan dan $T_t(x)$ merupakan fungsi prediksi dari pohon ke- t . Pada setiap iterasi, pohon baru ditambahkan untuk meminimalkan fungsi *loss* berdasarkan kesalahan prediksi model sebelumnya sehingga performa model meningkat secara bertahap [12].

Pada penelitian ini, LightGBM digunakan sebagai *QC Classifier* untuk memprediksi probabilitas bahwa hasil estimasi awal Hybrid TDOA-AOA memenuhi ambang galat kurang dari 314 m. Model menerima fitur sinyal terdiri atas parameter TDOA, korelasi puncak, representasi sinus dan cosinus AOA dari tiga stasiun monitoring, frekuensi, estimasi posisi awal sistem, *root mean square* (RMS) error, parameter elips galat, serta fitur geospasial yang diekstraksi dari DEM. Hyperparameter model dioptimalkan menggunakan *grid search* dengan *5-fold cross-validation*, menghasilkan konfigurasi *num_leaves* = 31, *learning_rate* = 0,05, *n_estimators* = 200, *max_depth* = 8, *min_child_samples* = 20, *subsample* = 0,8, *colsample_bytree* = 0,8, *reg_alpha* = 0,1, *reg_lambda* = 0,1, dan *scale_pos_weight* yang disesuaikan dengan distribusi kelas. Selanjutnya, ambang probabilitas optimum ditentukan melalui maksimisasi *F2-score* sehingga diperoleh nilai *threshold* sebesar 0,55.

2.6 Fitur Geospasial

Fitur geospasial digunakan untuk merepresentasikan karakteristik lingkungan yang memengaruhi propagasi gelombang radio dan kualitas hasil lokalisasi sumber pancaran [23]. Informasi geospasial berupa elevasi dan topografi berperan penting dalam membentuk karakteristik propagasi seperti *path loss*, *shadowing*, *multipath*, dan kondisi NLOS, sehingga banyak dimanfaatkan dalam pemodelan propagasi radio dan pengembangan model berbasis *machine learning* [23], [24], [25]. Pada penelitian ini, data elevasi diperoleh dari DEMNAS yang dikembangkan oleh Badan Informasi Geospasial (BIG) [26]. DEMNAS merupakan *national seamless DEM* yang dibangun melalui integrasi data IFSAR, TerraSAR-X, ALOS PALSAR, dan *mass point*, serta tersedia dalam format GeoTIFF dengan resolusi spasial 0,27 arc-second atau sekitar 8 m sehingga mampu merepresentasikan variasi topografi wilayah penelitian secara konsisten [26].

Pada penelitian ini, proses ekstraksi fitur geospasial dari DEMNAS dilakukan menggunakan pustaka GDAL, Rasterio, dan GeoPandas berdasarkan koordinat estimasi awal Hybrid TDOA-AOA. Untuk setiap titik estimasi dihitung sekumpulan atribut numerik yang merepresentasikan karakteristik topografi dan kondisi propagasi di sekitar lintasan sinyal. Fitur yang diekstraksi meliputi elevasi titik estimasi (*elevation*), perbedaan elevasi antara posisi estimasi dan sumber (*elev_delta_m*), nilai absolut perbedaan elevasi (*abs_elev_delta_m*), fraksi jalur LOS bebas hambatan (*los_clear_fraction*), variasi elevasi sepanjang lintasan propagasi (*los_terrain_diff_m*), *Terrain Ruggedness Index* (TRI) dan beberapa indikator topografi lainnya yang digunakan sebagai representasi kompleksitas medan. Seluruh fitur geospasial kemudian digabungkan dengan fitur sinyal membentuk satu vektor fitur sebagai masukan bagi model LightGBM. Pendekatan ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa pemanfaatan informasi geospasial dapat meningkatkan representasi karakteristik propagasi dan mendukung peningkatan kinerja model dalam mempelajari hubungan antara kondisi lingkungan dan kualitas estimasi lokasi [23], [24], [25].

2.7 Pelatihan dan Evaluasi Model

Kemampuan generalisasi spasial model dievaluasi menggunakan *10-fold spatial block cross-validation* dengan ukuran blok 1000 m × 1000 m untuk mengurangi *spatial autocorrelation bias* yang umum terjadi pada validasi acak [12]. Wilayah penelitian dibagi menjadi sepuluh blok geografis yang saling eksklusif. Pada setiap iterasi, model dilatih menggunakan data dari sembilan blok dan diuji pada satu blok yang tidak digunakan selama pelatihan. Proses ini diulang hingga seluruh blok berperan sebagai data uji tepat satu kali sehingga menghasilkan estimasi kemampuan generalisasi yang lebih representatif pada wilayah yang belum pernah diamati sebelumnya.

Kinerja model dievaluasi menggunakan *Root Mean Square Error* (RMSE), *Median Error* (MDE), dan *Residual Error Reduction* (RER) untuk mengukur akurasi, ketahanan terhadap *outlier* dan persentase penurunan galat dibandingkan estimasi awal sistem [12]. Selain itu, persentil ke-90 (P90), persentil ke-95 (P95), dan *retention rate* digunakan untuk mengevaluasi performa model pada distribusi galat ekstrem serta proporsi estimasi yang diterima oleh *QC Classifier* [12]. Adapun kinerja *QC Classifier* dievaluasi menggunakan *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Area Under the Receiver Operating Characteristic Curve* (AUC-ROC) untuk menilai kemampuan model dalam mengklasifikasikan estimasi valid dan tidak valid secara akurat [12].

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Dataset dan Distribusi Error

Dataset penelitian terdiri atas 15.519 sampel hasil estimasi awal sistem. Distribusi *initial error* menunjukkan karakteristik *heavy tailed* dengan kemencengan ke arah kanan (*right skewed*). Median Error tercatat sebesar 101,25 m dengan nilai MDE mencapai 233,11 m, menunjukkan bahwa rata-rata galat dipengaruhi oleh keberadaan *outlier* dengan nilai yang sangat besar. Kinerja awal sistem menghasilkan RMSE sebesar 521,58 m, P95 sebesar 786,40 m dan galat maksimum mencapai 4.980,68 m. Berdasarkan *threshold quality control* sebesar 314 m, sebanyak 15,3% sampel dikategorikan sebagai estimasi tidak valid. Rasio P95/P50 ≈ 7,8 menunjukkan bahwa sebagian kecil sampel memiliki galat jauh lebih besar dibandingkan distribusi utama sehingga membentuk ekor distribusi panjang (*long tailed distribution*).

Karakteristik di atas sesuai dengan kondisi propagasi sinyal pada wilayah penelitian. Berdasarkan analisis parameter *Line of Sight* (LOS) dari data DEM, sebanyak 68,56% sampel berada pada kondisi *LOS Clear*, sedangkan sisanya berada pada kondisi *Multipath* (19,01%), *NLOS* (9,47%), dan *NLOS + Multipath* (2,96%). Dominasi kondisi LOS menghasilkan estimasi dengan galat relatif rendah, sedangkan propagasi *NLOS* dan *multipath* berkontribusi terhadap munculnya *outlier* ekstrem. Kondisi tersebut menunjukkan bahwa tantangan utama terletak pada penanganan *outlier* ekstrem sehingga pendekatan *Quality Control* (QC) berbasis klasifikasi lebih dipilih dibandingkan pendekatan regresi residual deterministik. *QC Classifier* dirancang untuk mengidentifikasi dan menyaring estimasi yang berpotensi menghasilkan galat tinggi sebelum digunakan sebagai hasil lokalisasi akhir.

3.2 Penetapan *Threshold Quality Control*

Proses *quality control* memerlukan batas (*threshold*) untuk membedakan estimasi yang reliabel (*good*) dan estimasi yang memerlukan koreksi (*bad*). Dalam penelitian ini, digunakan *threshold* sebesar 314 m sebagai batas toleransi kesalahan posisi untuk pembentukan label klasifikasi, dimana estimasi dengan galat ≤ 314 m dikategorikan sebagai *good*, sedangkan galat > 314 m dikategorikan sebagai *bad*. Nilai *threshold* ditetapkan sebagai parameter tetap sebelum proses pelatihan model dan digunakan secara konsisten pada seluruh tahapan pelatihan serta validasi, sehingga pembentukan label bersifat independen terhadap proses pembelajaran maupun hasil evaluasi model. Dengan demikian, kinerja model dievaluasi secara objektif menggunakan *10-fold spatial block cross-validation* agar terhindar dari potensi *circular reasoning*.

3.3 Kinerja Skenario Koreksi Residual

Kinerja *QC Classifier* dievaluasi menggunakan *10-fold spatial block cross-validation* dengan *threshold* probabilitas sebesar 0,55. Empat skenario koreksi residual (S1–S4) dibandingkan untuk mengevaluasi pengaruh mekanisme QC terhadap peningkatan akurasi lokalisasi. Seluruh pengujian dilakukan menggunakan validasi silang berbasis blok spasial untuk memastikan pemisahan antara data pelatihan dan data pengujian sehingga mengurangi potensi *spatial leakage*. Ringkasan hasil evaluasi masing-masing skenario ditunjukkan pada Tabel 1.

Tabel 1. Perbandingan Metrik Kesalahan Posisi pada Setiap Skenario

Skenario	RMSE (m)	MDE (m)	Median (m)	STD (m)	RER (%)
S1 : Baseline (estimasi sistem)	521,58	233,11	101,25	466,59	0,00
S2 : MLP (hanya sinyal)	521,5	232,64	101,34	466,74	0,01
S3 : LightGBM parsial (hanya sinyal)	525,14	237,26	105,9	468,49	−0,68
S4 : LightGBM Gating + Sinyal + Spasial (usulan)	118,81	101,97	88,47	60,98	77,22

Hasil pengujian menunjukkan bahwa S4 memberikan kinerja terbaik dengan penurunan RMSE sebesar 77,22% dibandingkan metode baseline, jauh melampaui target RER sebesar 30%. Untuk memverifikasi bahwa peningkatan tersebut bersifat signifikan, dilakukan uji *Wilcoxon signed rank* terhadap hasil setiap lipatan validasi. Hasil pengujian menunjukkan perbedaan signifikan antara S4 dan S1 ($p = 0,000977$), serta antara S4 dan S3 ($p = 0,000977$). Hasil tersebut menunjukkan bahwa peningkatan akurasi yang dicapai oleh skenario S4 bersifat konsisten dan bukan disebabkan oleh variasi acak pada proses validasi.


3.4 Kinerja *Quality Control Classifier*

QC Classifier dikembangkan untuk memprediksi apakah hasil estimasi awal sistem (*baseline*) memenuhi kriteria *good* ($error \leq 314$ m) atau *bad* ($error > 314$ m). Untuk mengevaluasi pengaruh informasi geospasial terhadap kinerja klasifikasi, dibandingkan dua skenario, yaitu QC-A menggunakan 55 fitur sinyal dan QC-B mengombinasikan 55 fitur sinyal dengan 18 fitur geospasial sehingga menghasilkan 73 fitur. Ringkasan hasil evaluasi berdasarkan *10-fold spatial block cross-validation* disajikan pada Tabel 2.

Tabel 2. Metrik Evaluasi *QC Classifier* pada *10-Fold Spatial Block Cross-Validation*

Skenario	Akurasi	Presisi	Recall	F1-Score	AUC-ROC
QC-A (hanya sinyal)	0,7419	0,7996	0,7230	0,7197	0,7464
QC-B (Sinyal + Spasial)	0,9985	0,9987	0,9996	0,9991	0,9999
Peningkatan absolut	0,2566	0,1991	0,2766	0,2794	0,2535

Hasil evaluasi menunjukkan bahwa penambahan fitur geospasial memberikan peningkatan kinerja signifikan. Dibandingkan QC-A, model QC-B mampu meningkatkan *F1-Score* dari 0,7197 menjadi 0,9991 menunjukkan kemampuan sangat baik dalam membedakan estimasi *good* dan *bad*. Temuan ini menunjukkan bahwa informasi geospasial berperan penting dalam meningkatkan kemampuan diskriminatif *QC Classifier* sehingga estimasi dengan potensi galat tinggi dapat diidentifikasi secara lebih akurat sebelum digunakan sebagai hasil lokalisasi akhir.



Gambar 2. Kinerja Quality Control Classifier

3.5 Kontribusi Fitur Sinyal dan Geospasial

Analisis *feature importance* dilakukan untuk mengevaluasi kontribusi relatif fitur sinyal dan geospasial terhadap kinerja model. Pada model S4 (*gating classifier*), fitur geospasial memberikan kontribusi sebesar 49,8%, sedangkan fitur sinyal berkontribusi sebesar 50,2%, menunjukkan bahwa kedua kelompok fitur memiliki peran hampir seimbang dalam proses pengambilan keputusan model. Sementara itu, pada QC Classifier, kontribusi fitur geospasial mencapai 37,9%, mengindikasikan bahwa informasi geospasial tetap memberikan pengaruh signifikan terhadap proses klasifikasi meskipun kontribusinya lebih rendah dibandingkan fitur sinyal.

Analisis lebih lanjut menunjukkan bahwa lima fitur geospasial dengan kontribusi terbesar pada model S4 adalah *los_clear_fraction* (518,1), *los_terrain_diff_m* (188,2), *abs_elev_delta_m* (122,1), *elev_delta_m* (108,8), dan *tri_sys_m* (97,2). Dominasi fitur-fitur tersebut menunjukkan bahwa karakteristik LOS, perbedaan elevasi, dan kompleksitas topografi merupakan faktor utama yang mempengaruhi besarnya residual pada estimasi lokalisasi. Hasil yang diperoleh mengonfirmasi bahwa integrasi informasi geospasial mampu meningkatkan kemampuan model dalam mengidentifikasi kondisi propagasi yang berpotensi menghasilkan galat tinggi sehingga mendukung peningkatan akurasi proses koreksi residual.

3.6 Kinerja Model pada Berbagai Kondisi Propagasi

Kinerja model dianalisis berdasarkan empat kondisi propagasi yaitu LOS Clear, Multipath, NLOS, dan NLOS + Multipath. Perbandingan nilai RMSE antara metode *baseline*, LightGBM parsial (S3), dan LightGBM Gating berbasis fitur sinyal dan geospasial (S4) disajikan pada Tabel 3. Hasil evaluasi menunjukkan bahwa S3 belum memberikan peningkatan akurasi dibandingkan *baseline*, sedangkan S4 secara konsisten menghasilkan penurunan RMSE pada seluruh kondisi propagasi.

Tabel 3. Perbandingan Nilai RMSE (m) pada Setiap Kondisi Propagasi

Lingkungan	S1 (Baseline)	S3 (LightGBM parsial)	S4 LightGBM Gating + Sinyal + Spasial	Reduksi RMSE S4 vs S1
LOS Clear	209,53	210,12	113,23	45,90%
Multipath	301,3	315,49	123,84	58,90%
NLOS	1449	1451,67	205,81	85,80%
NLOS + Multipath	934,13	954,88	229,54	75,40%

Peningkatan terbesar dicapai pada lingkungan NLOS, dengan RMSE berkurang dari 1449 m menjadi 205,81 m atau mengalami reduksi sebesar 85,80%, diikuti kondisi NLOS + Multipath (75,40%), Multipath (58,90%), dan LOS Clear (45,90%). Hasil tersebut menunjukkan bahwa pendekatan LightGBM *Gating* lebih efektif dalam menangani kondisi propagasi kompleks, sehingga mampu mengurangi galat lokalisasi secara signifikan terutama pada lingkungan NLOS dan *multipath* dibandingkan metode koreksi residual konvensional.

3.7 Stabilitas Validasi Silang

Stabilitas dan kemampuan generalisasi model S4 (*LightGBM Gating* dengan fitur sinyal dan geospasial) dievaluasi menggunakan 10-fold *spatial block cross validation*. Setiap lipatan menggunakan sekitar 90% data sebagai data pelatihan

dan 10% sebagai data pengujian dengan pemisahan berbasis blok spasial untuk menghindari *spatial leakage*. Ringkasan hasil evaluasi pada setiap lipatan disajikan pada Tabel 4, yang meliputi Baseline RMSE, RMSE model, RER, dan *Retention Rate*.

Tabel 4. Metrik Evaluasi Model S4 pada Setiap Lipatan 10-Fold *Spatial Block Cross-Validation*

Lipatan	Baseline RMSE (m)	Model RMSE (m)	RER (%)	Retention Rate (%)
0	330,09	111,9	66,1	96,3
1	382,57	89,24	76,67	77
2	383,78	144,37	62,38	80,4
3	134,35	123,47	8,1	97,9
4	132	92,09	30,24	99,6
5	471,31	98,69	79,06	96,3
6	449,6	185,46	58,75	86,4
7	778,15	97,86	87,42	59,8
8	1448,2	146,24	89,9	38,2
9	338,43	108,64	67,9	77,8
Rata-rata	485,95	119,8	62,65	80,96
Std. Deviasi	430,91	28,99	26,22	19,11

Hasil evaluasi pada Tabel 4 menunjukkan bahwa model mampu mempertahankan kinerja konsisten pada seluruh lipatan meskipun tingkat kesulitan data bervariasi. Nilai Baseline RMSE berkisar antara 132,00 m hingga 1448,20 m, sedangkan RMSE model S4 tetap berada pada rentang 89,24–185,46 m dengan rata-rata 119,80 m dan standar deviasi 28,99 m. Sebaliknya, nilai RER menunjukkan variasi lebih besar yaitu 8,10–89,90% dengan rata-rata 62,65%. Variasi tersebut dipengaruhi oleh karakteristik masing-masing lipatan, dimana lipatan dengan Baseline RMSE rendah yang didominasi kondisi LOS Clear memiliki ruang perbaikan terbatas sehingga menghasilkan RER relatif kecil. Sebaliknya, lipatan dengan Baseline RMSE tinggi akibat dominasi kondisi NLOS dan *multipath* memberikan peluang koreksi lebih besar sehingga menghasilkan RER lebih tinggi.

Rata-rata *Retention Rate* sebesar 80,96% menunjukkan bahwa sebagian besar estimasi dapat dipertahankan atau dikoreksi oleh model. Retensi terendah terjadi pada lipatan 8 (38,2%) memiliki Baseline RMSE tertinggi (1448,20 m). Meskipun demikian, mekanisme *gating* tetap mampu menurunkan RMSE pada lipatan tersebut menjadi 146,24 m, menunjukkan bahwa model secara selektif menolak estimasi dengan potensi galat tinggi untuk menghindari koreksi yang tidak tepat. Secara keseluruhan, variasi antar lipatan tidak menunjukkan indikasi *overfitting* karena model S4 secara konsisten menghasilkan RMSE di bawah 200 m pada seluruh lipatan. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi spasial yang baik dan mampu mempertahankan akurasi pada wilayah yang tidak digunakan selama proses pelatihan.

3.8 Analisis Keterbatasan Model Berbasis Fitur Sinyal

Hasil evaluasi menunjukkan bahwa MLP (S2) maupun LightGBM parsial (S3) yang hanya memanfaatkan fitur sinyal seperti TDOA, AOA, korelasi, dan parameter elips, belum mampu meningkatkan akurasi awal sistem (baseline). Kedua model menghasilkan RER sangat kecil bahkan bernilai negatif pada beberapa skenario sehingga tidak memberikan perbaikan berarti terhadap estimasi awal.

Keterbatasan tersebut disebabkan oleh karakteristik galat pada lingkungan NLOS dan *multipath* yang bersifat nonlinier serta dipengaruhi oleh kondisi topografi dan propagasi sinyal. Informasi yang berasal dari fitur sinyal saja tidak cukup untuk membedakan galat akibat kondisi lingkungan dengan galat yang berasal dari proses pengukuran. Selain itu, pendekatan regresi residual menerapkan koreksi terhadap seluruh estimasi tanpa mempertimbangkan tingkat keandalannya sehingga koreksi juga diberikan pada estimasi yang telah akurat. Kondisi ini menyebabkan penambahan galat (*overcorrection*) dan membatasi kemampuan model dalam meningkatkan akurasi lokalisasi. Hasil tersebut menunjukkan bahwa integrasi fitur geospasial dan mekanisme *Quality Control* (QC) berbasis *LightGBM Gating* diperlukan agar proses koreksi residual hanya diterapkan pada estimasi yang benar-benar memerlukan perbaikan.

3.9 Analisis Efektivitas Mekanisme *Gating* dan Integrasi Fitur Geospasial

Keberhasilan model S4 dalam mencapai RER sebesar 77,22% merupakan hasil sinergi antara mekanisme *gating*, integrasi fitur geospasial, dan algoritma LightGBM sebagai *residual regressor*. Mekanisme *gating* memanfaatkan *QC Classifier* memiliki kinerja tinggi ($F1\text{-Score} = 0,9991$) untuk menentukan apakah estimasi awal sistem layak dipertahankan atau perlu dikoreksi. Dengan pendekatan ini, hanya estimasi yang diprediksi memiliki galat di atas 314 m akan diteruskan ke proses koreksi residual sehingga risiko *overcorrection* pada estimasi yang telah akurat dapat diminimalkan.

Selain mekanisme *gating*, integrasi fitur geospasial yang diekstraksi dari DEMNAS resolusi 8 m terutama parameter LOS dan karakteristik elevasi, memberikan informasi tambahan mengenai kondisi propagasi yang tidak dapat direpresentasikan oleh fitur sinyal saja. Analisis *feature importance* menunjukkan bahwa kontribusi fitur geospasial mencapai 49,8%, hampir setara dengan kontribusi fitur sinyal (50,2%) sehingga menegaskan bahwa informasi topografi dan visibilitas jalur propagasi memiliki peran yang sama pentingnya dalam proses koreksi residual. Selanjutnya, algoritma LightGBM mampu memodelkan hubungan nonlinier antara fitur sinyal dan geospasial secara efektif dan tetap stabil terhadap keberadaan *outlier*. Kombinasi ketiga komponen tersebut memungkinkan model menghasilkan peningkatan akurasi signifikan, terutama pada lingkungan propagasi kompleks.

3.10 Analisis *Feature Importance* terhadap Keandalan Estimasi

Untuk mengidentifikasi faktor yang paling berpengaruh terhadap keandalan estimasi, dilakukan analisis *feature importance* pada dua model yaitu *QC Classifier* (Sinyal + Spasial) dan *S4 Gating Classifier*. Nilai *feature importance* diperoleh dari akumulasi hasil 10-fold *spatial block cross-validation* dan dinormalisasi. Hasil analisis menunjukkan bahwa pada *QC Classifier*, fitur sinyal memberikan kontribusi sebesar 62,1%, sedangkan fitur geospasial berkontribusi 37,9%. Sebaliknya, pada *S4 Gating Classifier*, kontribusi kedua kelompok fitur menjadi hampir seimbang yaitu 50,2% untuk fitur sinyal dan 49,8% untuk fitur geospasial. Peningkatan kontribusi fitur geospasial menunjukkan bahwa informasi kondisi medan memiliki peran yang hampir sama pentingnya dengan informasi sinyal dalam menentukan apakah estimasi awal sistem layak dipertahankan atau perlu dikoreksi.

Tabel 5. Sepuluh Fitur dengan Nilai *Feature Importance* Tertinggi pada *QC Classifier* Sinyal dan Geospasial

Peringkat	Fitur	Importance	Kelompok	Keterangan
1	corr_peak_s1_s3	117,7	Sinyal	Korelasi puncak antara sensor 1 dan 3
2	aoa_conf_std	108,5	Sinyal	Standar deviasi konfidensi AOA
3	aoa_bearing_s3_cos	94,8	Sinyal	Cosinus sudut AOA sensor 3
4	aoa_bearing_s3_weighted_sin	88,9	Sinyal	Sinus AOA sensor 3 berbobot konfidensi
5	tdoa_ratio_12_23	83,3	Sinyal	Rasio TDOA antara pasangan sensor
6	los_clear_fraction	81,2	Geospasial	Fraksi jalur LOS bebas halangan
7	corr_peak_s2_s3	79,6	Sinyal	Korelasi puncak sensor 2 dan 3
8	tdoa_kurtosis	76,4	Sinyal	Kurtosis distribusi TDOA
9	elev_delta_m	72,1	Geospasial	Perbedaan elevasi antara sistem dan sumber
10	los_terrain_diff_m	68,3	Geospasial	Variasi elevasi sepanjang jalur LOS


Dari kelompok fitur sinyal, corr_peak_s1_s3 dan corr_peak_s2_s3 merupakan fitur dengan kontribusi tertinggi karena merepresentasikan kualitas korelasi sinyal antar sensor. Nilai korelasi rendah umumnya mengindikasikan terjadinya *multipath* atau gangguan propagasi yang berkorelasi dengan meningkatnya galat lokalisasi. Selain itu, aoa_conf_std mencerminkan tingkat ketidakpastian estimasi AOA, sedangkan fitur aoa_bearing_s3_cos, aoa_bearing_s3_weighted_sin, dan toda_ratio_12_23 berperan dalam mengidentifikasi inkonsistensi pengukuran arah datang dan perbedaan waktu kedatangan sinyal yang sering muncul pada kondisi NLOS.

Tabel 6. Sepuluh Fitur dengan Nilai *Feature Importance* Tertinggi pada Model *S4 Gating Classifier*

Peringkat	Fitur	Importance	Kelompok
1	los_clear_fraction	118,4	Geospasial
2	corr_peak_s1_s3	102,3	Sinyal
3	elev_delta_m	97,5	Geospasial
4	los_terrain_diff_m	88,1	Geospasial
5	aoa_conf_std	85,2	Sinyal
6	tdoa_ratio_12_23	79,8	Sinyal
7	abs_elev_delta_m	74,3	Geospasial
8	tri_sys_m	68,9	Geospasial
9	tdoa_kurtosis	65,4	Sinyal
10	aoa_bearing_s3_cos	61,7	Sinyal

Fitur geospasial yang paling dominan adalah los_clear_fraction, diikuti los_terrain_diff_m, elev_delta_m, abs_elev_delta_m, dan tri_sys_m. Dominasi fitur-fitur tersebut menunjukkan bahwa karakteristik LOS, perbedaan elevasi, dan kompleksitas topografi merupakan faktor utama yang memengaruhi keandalan estimasi. Pada *S4 Gating*

Classifier, *los_clear_fraction* menjadi fitur dengan kontribusi tertinggi dan menggeser *corr_peak_s1_s3* ke peringkat kedua. Hal tersebut menunjukkan bahwa keputusan *gating* lebih dipengaruhi oleh kondisi fisik jalur propagasi dibandingkan karakteristik sinyal semata. Kondisi tersebut mengonfirmasi bahwa integrasi fitur geospasial memungkinkan model mengidentifikasi estimasi dengan potensi galat tinggi secara lebih akurat sehingga menghasilkan proses koreksi residual yang lebih efektif.



Gambar 3. Perbandingan *Feature Importance* 15 Fitur Teratas pada *QC Classifier* dan *S4 Gating Classifier*

3.11 Analisis *Confusion Matrix* dan Pola Kesalahan Klasifikasi

Untuk mengevaluasi karakteristik kesalahan yang masih terjadi pada model S4, dilakukan analisis *confusion matrix* terhadap tiga tugas klasifikasi yaitu *Quality Control* (QC) estimasi awal sistem, deteksi kondisi NLOS, dan deteksi multipath. Analisis ini bertujuan untuk mengidentifikasi pola kesalahan klasifikasi dan mengevaluasi faktor-faktor yang masih membatasi kinerja model pada berbagai kondisi propagasi.

Tabel 7. *Confusion Matrix QC Classifier*

Kelas	Prediksi Good	Prediksi Bad
Aktual Good	13.146 (TP)	13 (FN)
Aktual Bad	10 (FP)	2.373 (TN)

Pada tugas *quality control*, model mengklasifikasikan estimasi awal sistem menjadi kategori *Good* (galat ≤ 314 m) dan *Bad* (galat > 314 m). Dari total 15.519 sampel, terdapat 13.146 sampel *Good* (84,71%) dan 2.373 sampel *Bad* (15,29%). Hasil *confusion matrix* pada Tabel 7 menunjukkan bahwa model mencapai akurasi sebesar 99,85% dengan hanya 13 *false negative* (FN) dan 10 *false positive* (FP). Dengan demikian, hanya 0,1% estimasi yang sebenarnya *Good* salah diklasifikasikan sebagai *Bad*, sedangkan hanya 0,4% estimasi *Bad* yang gagal terdeteksi. Hasil tersebut menunjukkan bahwa mekanisme *LightGBM Gating* mampu mempertahankan estimasi yang telah akurat sekaligus mengidentifikasi estimasi yang memerlukan proses koreksi sehingga risiko meneruskan estimasi tidak andal ke tahap lokalisasi akhir dapat diminimalkan.

Tabel 8. Distribusi Kesalahan Klasifikasi *Quality Control* Berdasarkan Lingkungan Propagasi

Lingkungan Propagasi	Jumlah Sampel	False Negative (Good $\rightarrow$ Bad)	False Positive (Good $\rightarrow$ Bad)	Interpretasi
LOS Clear	10.640	8	1	Sangat akurat
Multipath	2.950	4	3	Sedikit noise
NLOS	1.470	1	4	FP lebih banyak
NLOS + Multipath	459	0	2	Terbatas

Distribusi kesalahan berdasarkan lingkungan propagasi pada Tabel 8 menunjukkan bahwa performa model menurun seiring meningkatnya kompleksitas propagasi. Pada lingkungan LOS Clear (10.640 sampel), model hanya menghasilkan 8 FN dan 1 FP sehingga hampir seluruh sampel berhasil diklasifikasikan dengan benar. Jumlah kesalahan meningkat pada lingkungan *Multipath* (4 FN dan 3 FP) akibat karakteristik propagasi berada pada kondisi transisi antara LOS dan NLOS. Sementara itu, pada lingkungan NLOS (1 FN dan 4 FP) dan NLOS + *Multipath* (0 FN dan 2 FP), model cenderung menghasilkan lebih banyak *false positive* akibat adanya hambatan topografi yang ditunjukkan oleh nilai *los_clear_fraction* rendah dan *terrain ruggedness index* tinggi sehingga menyebabkan estimasi awal sistem dianggap masih layak dikoreksi. Meskipun demikian, secara keseluruhan jumlah *false positive* hanya 10 sampel atau sekitar 0,06%

dari 15.519 sampel, sehingga mekanisme *quality control* tetap bekerja secara konservatif dan efektif dalam mencegah estimasi tidak andal diteruskan ke proses lokalisasi akhir.

Tabel 9. *Confusion Matrix* Deteksi NLOS


Kelas	Prediksi LOS	Prediksi NLOS
Aktual LOS	1.369 (TN)	101 (FP)
Aktual NLOS	284 (FN)	13.765 (TP)

Selain melakukan *quality control* terhadap estimasi awal sistem, model S4 juga mampu mengidentifikasi kondisi propagasi NLOS secara implisit berdasarkan probabilitas estimasi "*Good*" ($prob_good < 0,5$). Berdasarkan *confusion matrix* pada Tabel 9, model berhasil mengidentifikasi 13.765 dari 14.049 sampel NLOS dengan recall sebesar 97,98% dan hanya 284 sampel yang masih diklasifikasikan sebagai LOS (*false negative*). Di sisi lain, dari 1.470 sampel LOS, hanya 101 sampel diprediksi sebagai NLOS (*false positive*). Sebagian besar kesalahan dipengaruhi oleh keterbatasan DEMNAS resolusi 8 m dalam merepresentasikan objek lokal dan kondisi topografi kompleks yaitu *terrain ruggedness index* tinggi dan *los_clear_fraction* rendah. Temuan tersebut menunjukkan bahwa integrasi fitur geospasial efektif merepresentasikan karakteristik NLOS, meskipun peningkatan resolusi data geospasial dan penambahan informasi lingkungan berpotensi meningkatkan kemampuan deteksi model.

Tabel 10. *Confusion Matrix* Deteksi Multipath

Kelas	Prediksi Multipath	Prediksi Non-Multipath
Aktual Multipath	2.140 (TP)	810 (FN)
Aktual Non-Multipath	1.703 (FP)	10.866 (TN)

Berbeda dengan deteksi NLOS, kemampuan model dalam mengidentifikasi kondisi *multipath* lebih terbatas. Berdasarkan *confusion matrix* pada Tabel 10, model berhasil mengidentifikasi 2.140 dari 2.950 sampel *multipath* dengan recall sebesar 72,54%, sedangkan 810 sampel masih diklasifikasikan sebagai *non-multipath* (*false negative*). Selain itu, terdapat 1.703 *false positive*, yaitu sampel *non-multipath* yang diprediksi sebagai *multipath*. Recall yang lebih rendah dibandingkan deteksi NLOS menunjukkan bahwa karakteristik *multipath* lebih sulit direpresentasikan menggunakan fitur geospasial dan parameter sinyal dasar karena pantulan dengan *delay* pendek menghasilkan pola sinyal menyerupai propagasi LOS. Oleh karena itu, peningkatan deteksi *multipath* memerlukan fitur propagasi yang lebih representatif seperti *delay spread* atau *channel impulse response* yang belum tersedia pada dataset penelitian ini.



Gambar 4. Diagram Radar Perbandingan Kinerja QC Classifier

Secara visual, grafik radar menunjukkan bahwa model S4 memiliki performa lebih baik dibandingkan model yang hanya menggunakan fitur sinyal pada seluruh metrik evaluasi yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *AUC-ROC*. Luas area radar model S4 yang mendekati nilai maksimum mengindikasikan peningkatan performa konsisten pada setiap metrik. Bukti tersebut memperkuat bahwa integrasi informasi geospasial seperti *los_clear_fraction*, *elev_delta_m* dan parameter topografi lainnya, memberikan kontribusi penting dalam meningkatkan keandalan mekanisme *LightGBM Gating* untuk mengklasifikasikan kualitas estimasi awal.

3.12 Evaluasi Robustness dan Generalisasi Spasial Model

Kemampuan model untuk menggeneralisasi pada wilayah yang tidak digunakan selama pelatihan (*unseen spatial blocks*) merupakan aspek penting dalam lokalisasi berbasis *machine learning*. Berdasarkan hasil *Spatial Block Cross Validation* (Tabel 4), model S4 menghasilkan performa lebih stabil dibandingkan baseline dengan koefisien variasi RMSE sebesar 24,2% ($119,80 \pm 28,99$ m), jauh lebih rendah dibandingkan baseline sebesar 88,7% ($485,95 \pm 430,91$ m). Hal ini

menunjukkan bahwa model mampu mereduksi variabilitas spasial error hingga 72,7% sehingga kualitas lokalisasi menjadi lebih seragam pada berbagai kondisi geografis.

Analisis korelasi Spearman antara peringkat RMSE baseline dan RMSE model menunjukkan hubungan tidak signifikan ($p = 0,38$; $p = 0,28$). Hal ini mengindikasikan bahwa performa model setelah koreksi tidak dipengaruhi oleh tingkat kesulitan awal setiap blok. Sebagai contoh, lipatan dengan baseline terburuk (RMSE 1448 m) berhasil dikoreksi menjadi sekitar 146 m, sedangkan lipatan dengan baseline terbaik (RMSE 132 m) menghasilkan RMSE 92 m. Hasil tersebut menunjukkan bahwa mekanisme *LightGBM Gating* mampu memberikan perbaikan lebih besar pada wilayah dengan propagasi sinyal lebih kompleks akibat efek multipath dan NLOS.

Tabel 11. Hasil Pengujian *Leave One Block Out* (LOBO) pada Lima Blok Spasial Terbesar

Blok ID	Karakteristik Medan	Baseline RMSE (m)	S4 RMSE (m)	RER (%)
B3	Perbukitan rendah	189,2	107,3	43,3
B7	Lembah sungai	446,5	121,8	72,7
B11	Pegunungan sedang	1023,4	148,2	85,5
B14	Dataran tinggi	312,7	112,4	64,1
B15	Karst berbukit	1876,2	167,9	91,1

Kemampuan generalisasi model selanjutnya divalidasi menggunakan skema *Leave One Block Out* (LOBO) pada lima blok spasial terbesar (Tabel 9). Rata-rata RER mencapai 71,3%, hanya sedikit lebih rendah dibandingkan 77,2% pada *Spatial Block Cross Validation* karena model tidak pernah dilatih menggunakan blok yang diuji. Meskipun demikian, seluruh blok tetap menghasilkan RMSE di bawah 170 m, termasuk blok B15 dengan karakteristik karst berbukit memiliki baseline RMSE 1876,2 m dan berhasil diturunkan menjadi 167,9 m (RER 91,1%). Hasil tersebut menunjukkan bahwa model mampu mempertahankan akurasi pada berbagai karakteristik geospasial mulai dari perbukitan, lembah sungai, pegunungan, hingga kawasan karst yang memiliki kondisi propagasi kompleks.

Robustness dan kemampuan generalisasi tersebut didukung oleh integrasi fitur geospasial DEMNAS 8 m terutama *los_clear_fraction*, *tri_sys_m*, dan *elev_delta_m*, dimana memungkinkan model menangkap pengaruh kondisi topografi terhadap kualitas estimasi posisi. Dengan demikian, model S4 tidak hanya meningkatkan akurasi rata-rata tetapi dapat juga menghasilkan performa stabil dan mampu digeneralisasikan pada wilayah baru selama informasi geospasial tersedia. Hal ini menunjukkan bahwa pendekatan *LightGBM Gating* berbasis fitur geospasial layak diterapkan sebagai mekanisme *quality control* pada sistem lokalisasi Hybrid TDOA-AOA di lingkungan operasional dengan karakteristik spasial beragam.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pendekatan *Quality Control LightGBM* diintegrasikan dengan fitur geospasial DEMNAS 8 m mampu meningkatkan akurasi lokalisasi Hybrid TDOA-AOA pada pita frekuensi FM 87,5 – 108 MHz di lingkungan dengan propagasi NLOS kompleks. Model yang diusulkan berhasil menurunkan RMSE sebesar 77,22%, dari 521,58 m menjadi 118,81 m, melampaui target penelitian sebesar 30%. Selain meningkatkan akurasi, model juga menunjukkan *robustness* tinggi dengan mereduksi koefisien variasi RMSE dari 88,7% menjadi 24,2%, serta mampu menurunkan *error* pada lingkungan NLOS ekstrem dari 1449 m menjadi 206 m (85,8%). Keberhasilan tersebut didukung oleh mekanisme *LightGBM Gating* yang mencapai *F1-Score* 0,9991 dalam menyaring estimasi yang tidak andal, serta integrasi fitur sinyal dan geospasial yang memberikan kontribusi hampir seimbang (50,2% dan 49,8%) terhadap keputusan model. Pengujian LOBO mengonfirmasi kemampuan generalisasi model pada wilayah yang tidak digunakan selama pelatihan dengan mempertahankan RMSE di bawah 170 m pada seluruh blok pengujian. Hasil ini menunjukkan bahwa pendekatan yang diusulkan mampu menghasilkan estimasi posisi lebih akurat, stabil, dan adaptif terhadap heterogenitas spasial sekaligus memberikan kontribusi berupa pendekatan *uncertainty aware quality control* untuk meningkatkan keandalan sistem lokalisasi Hybrid TDOA-AOA. Secara praktis, model ini dapat diterapkan sebagai lapisan validasi pada sistem monitoring spektrum frekuensi radio untuk meningkatkan akurasi lokalisasi di wilayah dengan karakteristik geografis beragam. Penelitian selanjutnya dapat difokuskan pada peningkatan kemampuan identifikasi kondisi *multipath* dan NLOS melalui teknik penyeimbangan kelas, pengembangan fitur geospasial yang lebih representatif, serta validasi model pada pita frekuensi dan wilayah operasional yang lebih beragam.

REFERENCES

- [1] J. Son, I. Keum, Y. Ahn, and B. Shim, "D-TLoc: Deep Learning-aided Hybrid TDoA/AoA-based Localization," in *2022 IEEE VTS Asia Pacific Wireless Communications Symposium (APWCS)*, Seoul, Korea, Republic of: IEEE, Aug. 2022, pp. 47–50. doi: 10.1109/APWCS55727.2022.9906489.
- [2] J. Kaur, O. R. Popoola, M. A. Imran, Q. H. Abbasi, and H. T. Abbas, "Deep Neural Network for Localization of Mobile Users using Raytracing," 2022.

- [3] X. Kang, D. Wang, Y. Shao, M. Ma, and T. Zhang, "An Efficient Hybrid Multi-Station TDOA and Single-Station AOA Localization Method," *IEEE Trans. Wireless Commun.*, vol. 22, no. 8, pp. 5657–5670, Aug. 2023, doi: 10.1109/TWC.2023.3235753.
- [4] S. Hu, L.-X. Guo, and Z. Liu, "A Novel Single-Site Hybrid AOA and TDOA Localization Algorithm for NLOS Scenarios," Jan. 07, 2025, doi: 10.36227/techrxiv.173626837.79923499/v1.
- [5] J. Kim, "Suppression of NLOS errors in TDOA-AOA hybrid localization," *Wireless Netw.*, vol. 29, no. 2, pp. 657–667, Feb. 2023, doi: 10.1007/s11276-022-03158-8.
- [6] N. Keleşoğlu, M. Halama, and A. Strzoda, "Enhancing LoRa-Based Outdoor Localization Accuracy Using Machine Learning," *IEEE Access*, vol. 13, pp. 129432–129450, 2025, doi: 10.1109/ACCESS.2025.3589032.
- [7] M. Kaczyński, Z. Piotrowski, and D. Pietrow, "A Survey of Machine Learning Techniques for Signal Source Localization and Emitter Tracking," *IEEE Access*, vol. 13, pp. 198390–198409, 2025, doi: 10.1109/ACCESS.2025.3629818.
- [8] N. Singh, S. Choe, R. Punmiya, and N. Kaur, "XGBLoc: XGBoost-Based Indoor Localization in Multi-Building Multi-Floor Environments," *Sensors*, vol. 22, no. 17, p. 6629, Sep. 2022, doi: 10.3390/s22176629.
- [9] M. N. De Sousa, R. Sant'Ana, R. P. Fernandes, J. C. Duarte, J. A. Apolinário, and R. S. Thomä, "Improving the performance of a radio-frequency localization system in adverse outdoor applications," *J Wireless Com Network*, vol. 2021, no. 1, p. 123, Dec. 2021, doi: 10.1186/s13638-021-02001-6.
- [10] X. Chen, Q. Xiang, L. Kong, H. Xu, and X. Liu, "Learning From FM Communications: Toward Accurate, Efficient, All-Terrain Vehicle Localization," *IEEE/ACM Trans. Networking*, vol. 31, no. 1, pp. 42–57, Feb. 2023, doi: 10.1109/TNET.2022.3187885.
- [11] F. Wang, X. Zhang, L. Liu, C. Chen, X. He, and Y. Zhou, "High-Precision Direction of Arrival Estimation Based on LightGBM," *Circuits Syst Signal Process*, vol. 43, no. 9, pp. 5834–5849, Sep. 2024, doi: 10.1007/s00034-024-02706-1.
- [12] X. Cui, Y. Li, J. Li, B. Jiang, S. Li, and J. Liu, "UWB Wireless Positioning Method Based on LightGBM," *Wireless Pers Commun*, vol. 137, no. 2, pp. 1141–1160, Jul. 2024, doi: 10.1007/s11277-024-11456-x.
- [13] Y. Chen, T. Xiang, X. Chen, and X. Zhang, "Map-assisted TDOA Localization Enhancement Based On CNN," Jan. 31, 2024, arXiv:2311.01291. doi: 10.48550/arXiv.2311.01291.
- [14] D. Pang, G. Wang, and K. C. Ho, "Hybrid AOA-TDOA Localization of a Moving Source by Single Receiver," *IEEE Trans. Commun.*, vol. 73, no. 6, pp. 4088–4104, Jun. 2025, doi: 10.1109/TCOMM.2024.3511932.
- [15] M. R. Shamsian, M. Sadeghi, and F. Behnia, "Joint TDOA and DOA Single Site Localization in NLOS Environment Using Virtual Stations," *IEEE Trans. Instrum. Meas.*, vol. 73, pp. 1–10, 2024, doi: 10.1109/TIM.2023.3334343.
- [16] X. Yang, Z. Wu, and D. Mo, "NLOS/LOS identification with LightGBM ensemble," *PLoS One*, vol. 21, no. 7, p. e0353288, Jul. 2026, doi: 10.1371/journal.pone.0353288.
- [17] S. Rabanser *et al.*, "Selective Prediction via Training Dynamics," Jul. 06, 2025, doi: 10.48550/arXiv.2205.13532.
- [18] A. Pugnana, L. Perini, J. Davis, and S. Ruggieri, "Deep Neural Network Benchmarks for Selective Classification," 2024.
- [19] L. Feng, M. O. Ahmed, H. Hajimirsadeghi, and A. Abdi, "Towards Better Selective Classification," Mar. 01, 2023, doi: 10.48550/arXiv.2206.09034.
- [20] I. D. Mienye and Y. Sun, "A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects," *IEEE Access*, vol. 10, pp. 99129–99149, 2022, doi: 10.1109/ACCESS.2022.3207287.
- [21] W. Gao, Z. Li, Q. Chen, W. Jiang, and Y. Feng, "Modelling and prediction of GNSS time series using GBDT, LSTM and SVM machine learning approaches," *J Geod.*, vol. 96, no. 10, p. 71, Oct. 2022, doi: 10.1007/s00190-022-01662-5.
- [22] H.-T. Thai, "Machine learning for structural engineering: A state-of-the-art review," *Structures*, vol. 38, pp. 448–491, Apr. 2022, doi: 10.1016/j.istruc.2022.02.003.
- [23] M. Vasudevan and M. Yuksel, "Machine Learning for Radio Propagation Modeling: A Comprehensive Survey," *IEEE Open J. Commun. Soc.*, vol. 5, pp. 5123–5153, 2024, doi: 10.1109/OJCOMS.2024.3446457.
- [24] B. Feng, M. Zheng, W. Liang, and L. Zhang, "A Recent Survey on Radio Map Estimation Methods for Wireless Networks," *Electronics*, vol. 14, no. 8, p. 1564, Apr. 2025, doi: 10.3390/electronics14081564.
- [25] C. Li *et al.*, "Toward Intelligent Radio Maps: Evaluation Metrics, Construction Schemes, and Future Trends," *IEEE Internet Things J.*, vol. 13, no. 12, pp. 25542–25562, Jun. 2026, doi: 10.1109/JIOT.2026.3679645.
- [26] D. B. Susetyo, "Vertical Accuracy Assessment of Various Open-Source DEM Data: DEMNAS, SRTM-1, and ASTER GDEM," *Geodesy and cartography*, vol. 49, no. 4, pp. 209–215, Dec. 2023, doi: 10.3846/gac.2023.18168.