



PEMODELAN DAN EVALUASI PREDIKSI RSRP MENGUNAKAN ARTIFICIAL NEURAL NETWORK UNTUK OPTIMASI KUALITAS LAYANAN JARINGAN KOMUNIKASI NIRKABEL

Mhd Ikhwan Rifki¹, M. Khalil Gibran², Abdul Halim Hasugian³, Muhammad Dani Solihin⁴

^{1,2,3}Universitas Islam Negeri Sumatera Utara, ⁴Universitas Negeri Medan

^{1,2,3}Jln. Lapangan Golf, Desa Durian Jangak, Kabupaten Deli Serdang,
203521

⁴Jln. William Iskandar Ps. V, Kenangan Baru, Kec. Percut Sei Tuan,
Kabupaten Deli Serdang, Sumatera Utara, 20221

e-mail : rifki.mhdikhwan@uinsu.ac.id¹

ABSTRAK

Penelitian ini bertujuan untuk memprediksi nilai Reference Signal Received Power (RSRP) pada jaringan LTE menggunakan metode regresi berbasis Multilayer Perceptron (MLP). Model dirancang dengan enam variabel input, dua hidden layer, dan satu output untuk menghasilkan estimasi RSRP berdasarkan data pengukuran yang mencakup parameter RSRQ, SNR, RSSI, RSRP terukur dengan identitas longitude dan latitude. Data yang digunakan telah melalui proses pembersihan dan validasi. Evaluasi performa model dilakukan menggunakan metrik Mean Squared Error (MSE) dan Mean Absolute Error (MAE). Hasil pengujian menunjukkan bahwa model mencapai nilai MSE sebesar 6,64 dBm dan MAE sebesar 4.1922 dBm, dengan kesalahan relatif masing-masing 0.73% dan 5.13%. Distribusi kesalahan prediksi dianalisis menggunakan histogram yang berada pada interval ± 5 dBm, yang menunjukkan bahwa dominasi nilai prediksi berada dekat dengan nilai aktual. Hasil ini menunjukkan bahwa model MLP mampu memberikan estimasi RSRP yang cukup akurat dan dapat digunakan untuk mendukung perencanaan serta optimasi kualitas jaringan komunikasi.

Kata kunci : MLP, Prediksi RSRP, MSE, MAE, LTE

ABSTRACT

This research seeks to forecast the value of Reference Signal Received Power (RSRP) in LTE networks by using a regression method that depends on a Multilayer Perceptron (MLP). The model takes six input variables, has two hidden layers, and produces one output to estimate RSRP using measurement data that includes RSRQ, SNR, RSSI, and measured RSRP, as well as location details like longitude and latitude. The data used has gone through a cleaning and validation process. Model performance evaluation is performed using Mean Squared Error (MSE) and Mean Absolute Error (MAE) metrics. The test results showed that the model achieved an MSE value of 6.64 dBm and MAE of 4.1922 dBm, with relative errors of 0.73% and 5.13%, respectively. The distribution of the prediction error was analyzed using a histogram that falls within the ± 5 dBm interval, which shows that the predominance of the predicted values is close to the actual values. These results show that the MLP model is capable of providing reasonably accurate RSRP estimation and can be used to support communication network quality planning and optimization.

Keywords: MLP, RSRP Prediction, MSE, MAE, LTE

1. PENDAHULUAN

Kualitas jaringan komunikasi nirkabel mengilustrasikan kemampuan suatu jaringan komunikasi dalam memfasilitasi pertukaran informasi antar pengguna jaringan komunikasi

dengan level kesalahan yang minim. Kemampuan jaringan juga ditentukan melalui kemampuan bertahan jaringan komunikasi terhadap besaran gangguan yang diterima saat pengiriman informasi berlangsung. Gangguan kualitas jaringan nirkabel



dapat terjadi pada beberapa aspek diantaranya *obstacles* pada lingkungan propagasi yang dapat memberikan dampak pada penurunan level besaran sinyal terima yang diperoleh perangkat komunikasi. Hal ini juga dapat disebabkan oleh faktor mobilitas pengguna yang memiliki pola *random* sehingga memungkinkan munculnya peningkatan jarak yang signifikan antara pengguna dengan *transmitter*.

Level besaran daya terima dalam jaringan Long Term Evolution (LTE) perangkat komunikasi yang digunakan pengguna dapat disebut dengan istilah Reference Signal Received Power (RSRP). RSRP memiliki peranan yang sangat penting, besaran level nilai RSRP dapat digunakan sebagai referensi gambaran desain, manajemen jaringan, khususnya pada *coverage* wilayah kepadatan trafik lalu lintas transaksi informasi, hingga deskripsi lingkungan yang kompleks dalam aspek geografis. Sehingga hal ini dapat mempengaruhi kualitas jaringan komunikasi dalam hal kecepatan transmisi data, layanan, hingga aspek kemampuan konektivitas perangkat pada jaringan komunikasi.

Salah satu upaya optimasi jaringan komunikasi, dapat dilakukan dengan mengukur besaran level RSRP yang diterima kemudian melakukan komparasi terhadap kesesuaian nilai RSRP yang seharusnya diterima oleh perangkat komunikasi yang digunakan oleh pengguna. Proses pengukuran RSRP pada suatu lingkungan wilayah, dapat dilakukan dengan menggunakan metode *drivetest*, dimana pengguna dapat mengukur level besaran RSRP saat melintasi suatu wilayah yang masuk dalam *coverage transmitter*. Pengukuran RSRP memiliki fluktuasi nilai, hal ini disebabkan posisi pengguna pada satu lokasi menentukan besaran level nilai RSRP yang diterima.

Berdasarkan jalur propagasi pancarannya, nilai RSRP yang bervariasi dapat dipengaruhi oleh kondisi Line of Sight (LoS) dan Non-Line of Sight (N-LoS). LoS mendeskripsikan kondisi bebas hambatan antara *transmitter* dengan perangkat komunikasi pengguna. Kondisi bebas ini mendeskripsikan tidak adanya aspek *obstacles* yang berada antar *transmitter* dengan perangkat komunikasi. *Obstacles* dapat diasumsikan dengan hambatan oleh objek seperti, gedung, pepohonan dan berbagi objek lainnya yang dapat menghalangi propagasi sinyal. Sementara itu, N-LoS mengilustrasikan kondisi lingkungan propagasi tidak langsung karena keberadaan *obstacles* yang berasal dari objek pada jalur propagasi sinyal. Hal ini menyebabkan munculnya fenomena *multipath* yang menyebabkan sinyal yang berjalan dari *transmitter* menuju perangkat pengguna

mengalami pantulan (*reflection*), pembiasan (*refraction*), difraksi (*diffraction*) dan penyebaran (*scattering*) (Putra; et al., 2021). Sehingga dampaknya terbentuknya beberapa jalur propagasi gelombang yang akan dilalui oleh sinyal yang berjalan menuju perangkat komunikasi pengguna.

Hasil pengukuran RSRP dengan pada suatu lokasi *coverage* memiliki hambatan dan tantangan. Hambatan dapat terdiri dari kondisi, vegetasi, kontur geografis serta variasi jumlah kepadatan pengguna pada suatu wilayah akan menghasilkan visualisasi data yang bervariasi dan berfluktuatif. Kondisi tersebut memberikan hasil ketidakpastian yang berdampak pada sulitnya mendeskripsikan sebaran peta kualitas jaringan komunikasi melalui visualisasi RSRP secara *realtime* dan akurat. Selain itu, pendekatan konvensional dengan menggunakan model lingkungan propagasi secara deterministik, dinilai tidak cukup mendeskripsikan kompleksitas kondisi lingkungan secara detail, sehingga memberikan ilustrasi estimasi RSRP yang kurang presisi. Namun demikian, model propagasi masih dianggap sebagai pendekatan realistik yang dapat digunakan dalam mewakili besaran nilai RSRP yang diterima oleh perangkat komunikasi pengguna.

Salah satu upaya lainnya yang dapat dilakukan dalam mengatasi masalah tersebut adalah dengan menggunakan analisis prediksi kualitas jaringan komunikasi. Implementasi pendekatan prediktif cerdas, mendukung aspek fleksibilitas secara adaptif terhadap data terukur hasil pengukuran. Salah satu pendekatan yang dapat diterapkan dalam model prediksi adalah dengan menggunakan Artificial Neural Network (ANN). ANN dapat diadopsi sebagai model pembelajaran mesin, karena memiliki kemampuan dalam membaca dan memahami pola data yang bersifat *non-linier*. Sejalan dengan itu, implementasi ANN juga dapat digunakan dalam mempelajari korelasi yang bersifat kompleks antar variabel yang dibutuhkan, serta memberikan hasil prediksi yang optimal dengan tingkat akurasi yang ditinggi.

Berdasarkan hasil penelitian yang dilakukan oleh (Valdovinos-bardají & Campos, 2022) pendekatan *machine learning* dengan beberapa parameter yang digunakan dalam penelitian, meliputi, Channel Quality Indicator (CQI), Reference Signal Received Quality (RSRQ) and number of Physical Resource Blocks (PRB) yang menjadi inputan pada model Fully Connected Neural Network (FCNN) dengan 2 (dua) hidden layers (L =2) dan 1 (satu) output. Hasil penelitian diperoleh model *machine learning* yang diimplementasikan dalam melakukan proses prediksi memperoleh visualisasi akurasi yang tinggi.

Selanjutnya penelitian yang dilakukan oleh



(Campos et al., 2020) menggunakan metrik Channel Quality Indicator (CQI), Reference Signal Received Power (RSRP) dan Reference Signal Received Quality (RSRQ) sebagai parameter prediksi pada konteks LAA untuk User Equipment (UE) dalam menghadapi tingkat interferensi (gangguan) yang berbeda. Kinerja algoritma yang dievaluasi menunjukkan tingkat akurasi yang baik, meskipun diterapkan untuk kebutuhan prediksi pada kondisi kanal komunikasi yang sebenarnya serta pergerakan pengguna yang bersifat *random*.

Selanjutnya penelitian yang dilakukan oleh (Fauzi et al., 2022) mendeskripsikan pengujian terhadap model *machine learning* untuk memprediksi level kuat sinyal terima pada jaringan komunikasi seluler. Model *machine learning* untuk kebutuhan prediksi RSRP diimplementasikan sebanyak enam model, diantaranya Linear Regression (LR), Artificial Neural Network (ANN), Support Vector Machine (SVM), Regression Trees (RT), Ensembles of Trees (ET), dan Gaussian Process Regression (GPR), dengan total metode yang diterapkan sebanyak lebih dari 20 model. Hasil penelitian menunjukkan bahwa, seluruh model *machine learning* dapat digunakan dalam memprediksi RSRP. Namun diantaranya seluruh model yang diterapkan, metode yang memiliki kemampuan dalam hal kecepatan prediksi dan efisiensi model yang paling praktis dalam memprediksi RSRP adalah ET dan Random Forest (RF). Kedua metode tersebut dinilai memiliki kemampuan dalam memprediksi RSRP pada multi-band frekuensi pada lingkungan dengan kondisi yang bervariasi.

Selain itu penelitian yang dilakukan oleh (Wu et al., 2021) mengusulkan metode penyesuaian pembelajaran untuk memprediksi cakupan wilayah dan beberapa variabel lainnya, termasuk fitur dasar yang dibangun berdasarkan data terukur, serta fitur kombinasi lainnya serta memanfaatkan fitur *generator Gradient Enhanced Decision Tree (GBDT)* yang dirancang untuk kebutuhan penyediaan fitur yang tinggi sebagai bagian dari input model jaringan syaraf. Sehingga hasil penelitian mengilustrasikan proses *pre-processing* data dapat meningkatkan akurasi prediksi RSRP pada model *deepl learning* yang diimplementasikan dalam penelitian.

Sementara itu, penelitian yang dilakukan oleh (Tarhuni et al., 2023) mendeskripsikan prediksi nilai RSRP dengan menggunakan *drone* untuk mengoleksi data ukur yang dibutuhkan dalam proses prediksi. Pemanfaatan *drone* digunakan untuk mempermudah jangkauan pengukuran RSRP pada lokasi yang sulit. Model ANN yang digunakan merupakan MLP-NN yang

dimanfaatkan dalam memprediksi RSRP dan mengklasifikasikan lokasi titik pengukuran pada permukaan tanah dengan klasifikasi buruk, cukup, baik, dan sangat baik. Metode yang diusulkan memiliki tingkat akurasi sebesar 97% dalam memprediksi cakupan sinyal di permukaan tanah. Disamping itu, evaluasi yang dilakukan dalam beberapa skenario pengujian, menghasilkan level eror kurang dari 3% untuk 68 derajat. Selain itu, pengukuran diluar ruangan dengan memanfaatkan MSE memiliki level eror kurang dari 6%. Selain itu, evaluasi MSE untuk satu zona pengukuran dengan menggunakan model ANN diperoleh level eror sebesar 10%.

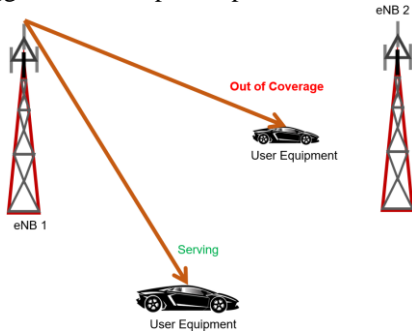
Berdasarkan deskripsi korelasi penelitian yang relevan, maka penelitian yang dilakukan berorientasi pada implementasi model Artificial Neural Network (ANN) dalam memprediksi RSRP sebagai salah satu indikator kualitas jaringan komunikasi nirkabel. Implementasi ANN dengan model MLP-NN digunakan dalam mendeskripsikan pemetaan RSRP berdasarkan lokasi dengan memanfaatkan fitur *longitude* dan *latitude* posisi perangkat komunikasi yang digunakan oleh pengguna. Pemetaan RSRP divisualisasikan dengan menggunakan *heatmap* pada setiap titik kordinat pengguna sesuai dengan histori pergerakannya. Evaluasi model ANN yang dilakukan dengan memanfaatkan Mean Squared Error (MSE) dan Mean Absolute Percentage Error (MAPE) untuk mengevaluasi kapabilitas kinerja dari model ANN yang diaplikasikan. Penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem prediksi kualitas jaringan komunikasi nirkabel berdasarkan data hasil pengukuran pada lokasi yang sebenarnya.

2. METODE PENELITIAN

Jaringan komunikasi nirkabel memiliki keunggulan dalam hal fleksibilitas bagi pengguna yang senantiasa melakukan mobilitas yang bersifat *random* selama proses komunikasi berlangsung. Mobilitas pengguna memungkinkan pengguna dapat bergerak menjauhi eNB. Sehingga menyebabkan daya sinyal yang pancarkan oleh eNB selaku *transmitter* mengalami penurunan level seiring mobilitas user yang bergerak menjauhi eNB yang memberikan pelayanan terhadap pengguna. Sehingga seiring dengan bertambahnya jarak antara pengguna dengan eNB, maka akan semakin kecil daya sinyal terima yang akan diperoleh pengguna. Penurunan daya sinyal terima bukan hanya disebabkan oleh bertambahnya jarak, namun terdapat beberapa faktor lain terutama kondisi lingkungan, kepadatan pengguna dalam satu *cell* jaringan komunikasi nirkabel. Ilustrasi mobilitas



pengguna, dideskripsikan pada Gambar 1.

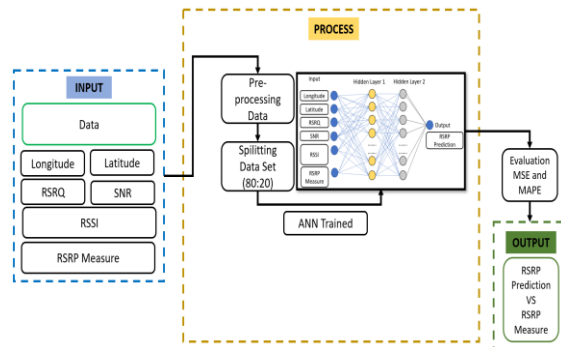


Gambar 1. Ilustrasi Mobilitas Pengguna

Sehingga berdasarkan ilustrasi Gambar 1, beberapa ruang lingkup penelitian yang dilakukan dapat dijabarkan sebagai berikut :

1. Wilayah pengukuran
Cakupan distribusi data terukur meliputi nilai sinyal pada jaringan nirkabel pada teknologi Long Term Evolution (LTE) tidak mencakup jenis jaringan komunikasi lainnya.
2. Parameter
Model prediksi hanya menggunakan parameter dari hasil data terukur yang meliputi nilai *longitude*, *latitude*, RSRQ, SNR dan RSSI, RSRP hasil pengukuran.
3. Model Prediksi ANN
Model prediksi ANN yang diterapkan, adalah model Multilayer Perceptron (MLP-NN). Sehingga analisis pada model prediksi hanya akan mengevaluasi kinerja dan memvisualisasikan perbandingan antara hasil data RSRP yang diprediksi dengan RSRP terukur.
4. Sumber Data
Data data yang diperoleh pada penelitian merupakan data RSRP ya dan tersedia pada *platform kaggle*.
5. Evaluasi model
Hasil evaluasi model akan diuji dengan menggunakan metrik Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE). Hasil evaluasi akan memvisualisasikan hasil perbandingan RSRP data utama dengan RSRP hasil prediksi model ANN, persentase hasil akurasi dan eror MSE dalam satuan persen.

Diagram alur penelitian implementasi model dan evaluasi prediksi RSRP menggunakan *Artificial Neural Network* dapat diilustrasikan pada Gambar 2.



Gambar 2. Diagram Alur Penelitian

Uraian diagram alur penelitian, proses pelaksanaan penelitian dilakukan melalui tiga tahapan utama, diantaranya :

2.1. Input

Inputan skenario model prediksi menggunakan sebaran data yang terdiri dari beberapa variabel diantaranya *longitude*, *latitude*, RSRQ, SNR, RSSI dan RSRP sebagai data utama. *Longitude* dan *latitude* mengilustrasikan parameter yang termasuk ke dalam sistem koordinat geografis untuk memberikan deskripsikan posisi atau letak suatu objek pada permukaan bumi. Parameter *longitude* dan *latitude* dimanfaatkan untuk menjelaskan titik dan lokasi dimana perangkat komunikasi yang digunakan oleh pengguna. Sehingga parameter ini dapat dijadikan sebagai landasan untuk menentukan histori posisi pengguna yang senantiasa bergerak. Beberapa komponen lainnya dapat diuraikan sebagai berikut :

2.1.1. RSSI (References Signal Strenght Indicator)

RSSI mendeskripsikan formulasi jarak yang secara umum sangat dipengaruhi oleh lingkungan sekitar. Sehingga tidak ada ketentuan yang mengatur formulasi dalam menentukan pola perhitungan yang secara spesifik. Namun dibalik kompleksitas komputasi RSSI, model yang paling umum digunakan adalah merepresentasikannya adalah dengan pendekatan jarak dan kondisi lingkungan sekitar. Persamaan RSSI dapat direpresentasikan pada Persamaan (1) dan Persamaan (2) (Shi et al., 2020)

$$\rho = \alpha - 10 \beta \text{ Log } (d)$$

Dimana

$$d = 10 \exp (\rho - \alpha) / (10 * \beta)$$

d mendeskripsikan jarak antara perangkat komunikasi pengguna dengan beberapa *transmitter*. ρ mengilustrasikan nilai RSSI pada posisi pengguna saat ini. Sementara α merupakan nilai RSSI pada jarak referensi (misalnya 1 m). sedangkan β merupakan nilai eksponen *path-loss*. Dalam proses pengukuran nilai RSSI, perlu dilakukan



penyesuaian terhadap nilai ekponen *path-loss* yang digunakan. Untuk nilai *path-loss* dalam ruangan, levelnya berkisaran antara 1,6-1,8. Sedangkan diluar ruangan, misalnya wilayah perkotaan nilai dapat mencapai 3-4 atau dapat mencapai level 3,5-6 untuk lingkungan propagasi LTE.

2.1.2. RSRP (Reference Signal Received Power)

RSRP mendeskripsikan rerata level kuat sinyal referensi yang diterima oleh pengguna melalui perangkat komunikasi yang berasal dari eNB. Semakin dekat jarak antara eNB dengan pengguna, maka akan kualitas sinyal RSRP akan semakin baik, penurunan kualitas level sinyal RSRP juga berlaku sebaliknya. Komputasi penentuan level RSRP dalam satuan dBm, dapat ditentukan melalui Persamaan (3) (Putra; et al., 2021) (Rolich et al., 2024)

$$RSRP (dBm) = RSSI (dBm) - 10 \log(12 \cdot N)$$

Berdasarkan Persamaan (3), maka nilai RSSI memiliki level yang lebih besar jika dikomparasi dengan level nilai RSRP. RSSI memiliki kompleksitas nilai, dikarena mengandung berbagai komponen pelemahan pada lingkungan yang berasal dari nilai ekponen *path-loss*, yang mencakup *shadowing*, dan bahkan komponen *multipath*.

2.1.3. RSRQ (References Signal Receiver Quality)

RSRQ merupakan rasio perbandingan antara RSRP dan RSSI serta dianggap sebagai parameter utama yang dapat memberikan indikasi kualitas sinyal yang diterima pada jaringan komunikasi LTE. Selain itu, RSRQ juga dapat memberikan deskripsi dampak interferensi antar *transmitter* yang saling berdekatan. Formulasi untuk menentukan nilai RSRQ dapat dinotasikan Pada Persamaan (4) (Putra; et al., 2021) (Behjati et al., 2022)

$$RSRQ = N \cdot \frac{RSRP}{RSSI}$$

2.1.4. SNR (Signal Noise Ratio)

SNR merupakan ratio antara perbandingan level daya sinyal yang diterima pengguna melalui perangkat komunikasi dengan terhadap daya yang berasal dari *noise*. Formulasi yang dibutuhkan dalam menentukan nilai SNR dalam satuan dB dapat dilakukan dengan menggunakan Persamaan (7)

$$SNR = 10 \log_{10} \frac{P_{Signal}}{P_{Noise}}$$

P_{Signal} merupakan level nilai rata-rata daya sinyal, sedangkan P_{noise} memberikan ilustrasi nilai rata-rata *noise* yang diterima.

2.2. Proses

2.2.1. Pre-Processing Data

Sebelum data diproses pada tahapan pelatihan data, perlu dilakukan proses *pre-processing* data. Beberapa tahapan *pre-processing* data dapat dideskripsikan sebagai berikut :

1. Pembersihan data

Pembersihan data dilakukan untuk memastikan data yang dihimpun memiliki kelengkapan nilai variabel. Pemeriksaan data meliputi *missing value*, duplikasi, serta nilai yang terindikasi masuk kategori anomali.

2. Seleksi Fitur

Fitur akan digunakan sebagai inputan pada model ANN yang dipilih berdasarkan keterkaitan dengan nilai RSRP yang menjadi target prediksi output, dalam hal ini RSRQ, RSSI, SNR, *longitude*, *latitude*, serta RSRP terukur.

3. Normalisasi data

Dalam proses normalisasi data, proses transformasi numerik dilakukan dengan menggunakan formulasi *min/max*. Setiap nilai pada fitur akan diklasifikasikan dalam rentang skala [0,1] secara proporsional. Hal ini dilakukan untuk mencegah dominasi nilai salah satu atau beberapa fitur akibat dari skala data numerik dengan jumlah yang besar. Transformasi numerik pada nilai fitur menggunakan persamaan *min/max*, dapat dilakukan melalui Persamaan (8) (Alazab et al., 2024)

$$X'_n = \frac{X_n - \min(X_n)}{\max(X_n) - \min(X_n)}$$

X_n merupakan data asli yang tidak dinormalisasi, sedangkan X'_n merupakan data hasil proses normalisasi dengan menggunakan persamaan *min/max*. Selain itu, hal ini dilakukan untuk mempercepat mekanisme proses konvergensi pada pelatihan model serta memberikan kestabilan numerik pada algoritma yang diimplementasikan.

4. Pemisahan data latih dan data uji (*Train-Test Split*)

Data Set akan dibagi kedalam dua kategori, yaitu data latih (*training set*) dan data uji (*testing set*) dengan rasio 80:20. Data latih diimplementasikan



sebagai proses pembelajaran model MLP-NN, sedangkan data uji akan diimplementasikan untuk proses evaluasi kinerja model dalam memprediksi data lainnya.

2.1.5. Arsitektur Model MLP-NN

Airtificial Neural Network (ANN) menjadi algoritma yang umum digunakan sebagai model pembelajaran data (Vipin et al., 2023). Hasil komputasi modelnya dapat mendeskripsikan pola atau model data yang sering dimanfaatkan dalam memprediksi nilai keluaran serangkaian data. Formulasi dasar dalam komputasi neuron pada satu *layer* pada MLP dapat dilihat melalui Persamaan (9) (Alazab et al., 2024) (Wang et al., 2024)

$$Sum_j = \sum_{i=1}^n w_{ij} \cdot I_i + b_j$$


Sum_j mengindikasikan sejumlah total sinyal yang masuk ke *neuron j*. Variabel w_{ij} mengilustrasikan bobot pada input ke- i ke neuron ke j , sedangkan I_i merujuk pada ilustrasi input ke- i . Sementara itu, b_j mendeskripsikan bias dari neuron ke- j , dengan n merupakan jumlah neuron atau input yang merujuk pada *layer* sebelumnya. Untuk menentukan output *layer* sebagai luaran hasil prediksi, dapat menggunakan skema regresi. Skema regresi dalam memprediksi nilai RSRP dapat dikomputasi dengan mengimplementasi Persamaan (10) (Alazab et al., 2024) (Mohammadi et al., 2024) (Ali et al., 2019)

$$\hat{y} = \sum_{j=1}^n w_j \cdot a_j + b$$

Opsi lainnya dapat menggunakan *function sigmoid* melalui Persamaan (11) (Alazab et al., 2024)

$$\hat{y} = func(sum_j)$$

\hat{y} merupakan nilai RSRP hasil prediksi dengan menggunakan model MLP. Variabel n mendeskripsikan jumlah neuron pada *hidden layer* akhir. Sementara itu, w_j mendeskripsikan hubungan neuron ke- j pada *hidden layer* ke output *layer*. a_j nilai aktivasi dari *neuron j* pada *hidden layer* terakhir, sementara b merupakan bias pada output *layer*. Ilustrasi arsitektur MLP-NN dapat diperlihatkan pada Gambar 3.



Gambar 3. Arsitektir Model MLP-NN

Berdasarkan Gambar 3 deskripsi model arsitektur MLP memiliki *hidden layer* 1 dengan 64 neuron, hidden layer 2 memiliki jumlah neuron sebanyak 32. Sementara itu, output *layer* memiliki 1 neuron. Penurunan jumlah neuron pada *hidden layer* pertama dan kedua dilakukan untuk menghindari faktor *overfitting*. Selain itu, hal ini dilakukan untuk meminimalisir kompleksitas pada model prediksi yang dibangun, serta tetap menjaga hasil prediksi agar tetap efektif dalam menangkap dan memahami pola.

2.3. Output

2.3.1. MAE (Mean Absolute Error)

MAE diimplementasikan dalam memvisualisasikan rerata nilai kesalahan absolut antara nilai aktual dan nilai hasil prediksi. Deskripsi formulasi MAE dapat direpresentasikan pada Persamaan (12) (Jos et al., 2024) (Jos et al., 2023).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

2.3.2. MSE (Mean Squared Error)

MSE diimplementasikan untuk menghitung rerata dari fungsi kuadrat antara nilai aktual hasil pengukuran dengan nilai hasil prediksi. Komputasi MSE untuk menghitung rerata selisih kuadrat RSRP dapat dilakukan melalui Persamaan (13) (Chen et al., 2024) (Calasan et al., 2024)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Dimana n merupakan jumlah data uji, sedangkan y_i mendeskripsikan nilai aktual RSRP hasil pengukuran pada titik ke i . Sementara itu, variabel \hat{y}_i nilai prediksi RSRP ANN pada lokasi ke i .



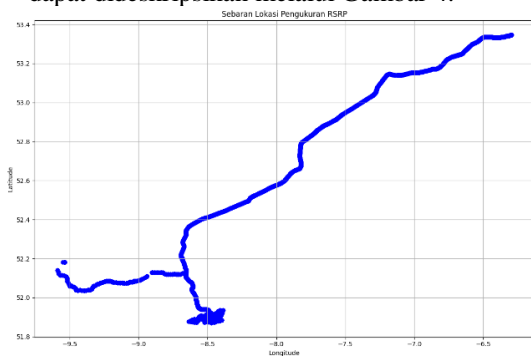
3. HASIL DAN PEMBAHASAN

Dalam memprediksi nilai RSRP dengan menggunakan model MLP-NN, dibutuhkan beberapa variabel yang memiliki nilai yang berpengaruh pada level nilai RSRP pada jaringan komunikasi LTE. Seluruh variabel yang dihimpun diperoleh dari sebaran data hasil pengukuran. Jumlah data yang terukur memiliki jumlah sebanyak 33270 data. Sampel sebaran data, berupa kelengkapan variabel dan level nilainya dapat dilihat pada Tabel 1.

Tabel 1. Sampel Sebaran Data Variabel

No	Long	Lat	RSRQ	SNR	RSSI	Measured RSRP (dBm)
1	9.491.517	52.061.743	-2	5	-81	-83
2	849.995	51.893.425	-12	6	-73	-90
3	8.428.397	51.910.644	-2	5	-81	-79
4	8.473.018	51.909.566	-7	17	-61	-79
5	8.481.721	51.897.335	-17	-6	-80	-97


Sebaran data pada titik pengukuran dimulai dari lokasi *longitude* -9,491517 dan *latitude* 52,06174, dengan titik akhir pengukuran berada pada lokasi dengan *longitude* -8.512298 dan *latitude* 51.891609. Sebaran pengukuran data bukan mendeskripsikan seluruh panjang lintasan pengukuran, melainkan mendeskripsikan pergerakan pengguna yang bersifat *random*. Visualisasi sebaran lokasi pengukuran RSRP, dapat dideskripsikan melalui Gambar 4.



Gambar 4. Visualisasi Sebaran Lokasi Pengukuran RSRP


Sebaran data RSRP yang terukur memiliki

pola yang non-linier, hal ini sangat bergantung pada kondisi dan lingkungan pada titik pengguna berada. Hal ini menjadi penyebab utama RSRP yang terukur memiliki pola yang fluktuatif, akibat fenomena *path-loss* pada setiap titik yang mewakili aspek kompleksitas kondisi lingkungan. Visualisasi level nilai RSRP dapat dilihat pada Gambar 5.




Gambar 5. Visualisasi RSRP Terukur

Nilai inputan MLP-NN merupakan *longitude*, *latitude*, RSRQ, SNR, RSSI dan RSRP terukur. Variabel inputan akan diproses melalui model prediksi MLP-NN dengan struktur 6 inputan, 64 neuron pada *hidden layer* pertama, 32 Neuron *hidden layer* kedua dan satu neuron input. Pada prosesnya dilanjutkan dengan melakukan normalisasi data pada setiap nilai variabel input. Proses dilanjutkan dengan melakukan pembagian data uji dan data latih, yang menjadi dasar pelatihan model dalam melakukan proses prediksi pada nilai RSRP pada jaringan komunikasi LTE. Hasil proses prediksi dengan menggunakan model MLP-NN dapat dilihat pada Gambar 6. Sementara itu, hasil perbandingan antara RSRP terukur dengan RSRP hasil prediksi dapat divisualisasikan melalui tampilan grafik Gambar 7.



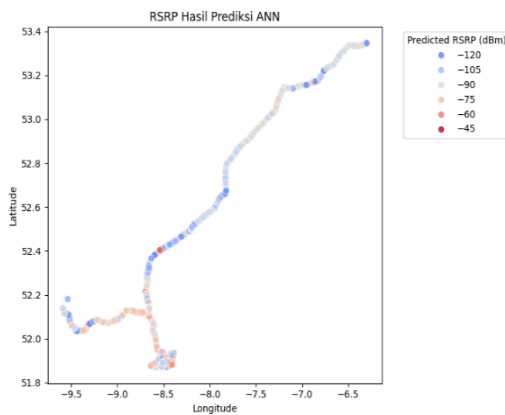
Gambar 6. Visualisasi RSRP Hasil Prediksi




Gambar 7. Visualisasi Perbandingan RSRP Terukur dengan RSRP Hasil Prediksi



Sehingga jika RSRP terukur dengan RSRP hasil prediksi divisualisasikan berdasarkan jalur pergerakan pengguna, maka dapat diperoleh hasil bahwa pemetaan nilai RSRP terukur memiliki nilai yang lebih tinggi dibandingkan dengan RSRP hasil prediksi. Hal ini ditandai dengan sebaran level RSRP terukur pada peta yang didominasi oleh besaran RSRP yang diwakili oleh interval nilai sebesar -75 hingga -100 dBm. Sedangkan RSRP hasil prediksi model didominasi oleh interval -90 hingga -120 dBm. Visualisasi pemetaan level besaran RSRP terukur dengan RSRP hasil prediksi dapat diuraikan pada Gambar 8 dan Gambar 9.



Gambar 8. Visualisasi Mapping RSRP Hasil Pengukuran



Gambar 9. Visualisasi Mapping RSRP Hasil Prediksi

Hasil evaluasi performa model prediksi RSRP menggunakan MLP-NN, dikomputasi

dengan menggunakan dua metrik evaluasi yaitu, MAE dan MSE. Hasil komputasi dengan menggunakan MSE diperoleh sebesar 41,7166 dBm², hal ini setara dengan $\sqrt{41,7166 \text{ dBm}} \approx 6,46 \text{ dBm}$. Nilai ini menunjukkan rerata kuadrat selisih antara nilai RSRP aktual dengan nilai RSRP hasil prediksi model hasil prediksi memiliki galat sebesar 6,46 dBm. Sementara itu, nilai komputasi MAE yang diperoleh sebesar 4,1922 dBm, nilai tersebut merujuk pada rerata deviasi secara absolut. Dalam interpretasi lainnya proporsional besaran sinyal juga dinyatakan dalam bentuk persentase terhadap nilai RSRP terukur. Hasil komputasi MSE memiliki besaran persentase error pada level 0,73% sedangkan MAE memiliki level persentase error sebesar 5,13%. Dengan besaran persentase error yang relative rendah, maka hal ini mendeskripsikan performa model yang baik dalam mendeskripsikan kondisi sinyal RSRP pada lokasi pengukuran dengan deviasi prediktif yang masuk dalam kategori kecil terhadap sinyal yang diterima secara aktual. Secara detail, sampel sebaran data hasil komputasi MAE dan MSE dapat dilihat pada Tabel 2. Sementara itu, visualisasi nilai hasil komputasi MSE dan MAE dapat dilihat pada Gambar 10.

Tabel 2. Sampel Sebaran Data Hasil Komputasi Persentase Error MAE dan MSE

No	Long	Lat	Measur red RSRP (dBm)	Estim asi RSRP (dBm)	Error MSE (%)	Ero r MAE (%)
1	-9.491517	52.061743	-83	-80.70	0.068	2.39
2	-8.49995	51.893425	-90	-90.20	0.00033	0.17
3	-8.428397	51.910644	-79	-70.10	0.95	8.90
4	-8.473018	51.909566	-79	-79.02	0.0000057	0.021
5	-8.481721	51.897335	-97	-97.96	0.011	0.96

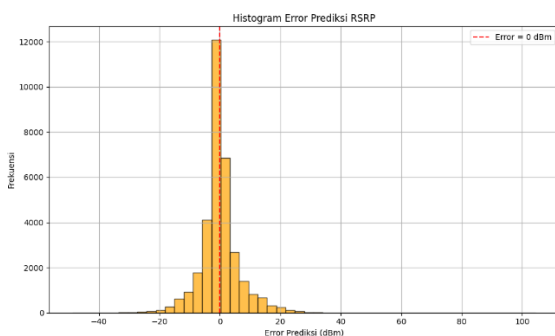
Mean Squared Error (MSE): 41.7166 dBm²
 Mean Absolute Error (MAE): 4.1922 dBm
 Mean Squared Error (MSE) dalam persen: 0.73 %
 Mean Absolute Error (MAE) dalam persen: 5.13 %

Gambar 10. Visualisasi Nilai Hasil Komputasi MSE dan MAE

Berdasarkan Gambar 11. Sumbu horizontal mengilustrasikan selisih antara nilai RSRP terukur secara aktual dan level RSRP yang dihasilkan oleh model prediksi. Sedangkan sumbu vertikal mendeskripsikan frekuensi error yang terjadi pada interval nilai tertentu. Grafik histogram menyatakan



dominasi bagian error terbesar terkonsentrasi pada titik disekitar level 0 dBm, dimana puncak tersebut ditandai dengan garis merah sebagai referensi nol error. Error menyebar secara relatif dan simetris pada sisi kiri dan kanan mendekati bentuk ideal dari distribusi normal (*gaussian*). Selain itu, puncak histogram tertinggi berada pada rentang error antara -5 dBm hingga 5 dBm. Hal ini merujuk pada performa model yang memiliki deviasi yang relatif kecil terhadap terhadap data aktual hasil pengukuran. Secara detail, visualisasi distribusi error prediksi RSRP yang dinyatakan dalam satuan dBm, dapat dideskripsikan pada Gambar 11.



Gambar 11. Histogram Error Prediksi RSRP

4. KESIMPULAN

Kompleksitas lingkungan propagasi memiliki dampak signifikan terhadap besaran variasi Reference Signal Received Power (RSRP) yang diterima oleh pengguna. Sebagai salah satu komponen penentu kualitas jaringan, RSRP perlu dievaluasi dan diukur besaran untuk memetakan daya *coverage* jaringan komunikasi LTE. Selain memperoleh nilai aktual pengukuran pada lokasi pengukuran, pengembangan model prediksi ANN dapat dilakukan dalam mendeskripsikan sebaran data RSRP pada lingkungan propagasi. Sehingga penelitian yang dilakukan berorientasi pada pengembangan dan evaluasi model prediksi RSRP dengan menggunakan MLP-NN yang disusun dengan menggunakan skema 6 input yang terdiri dari *longitude*, *latitude*, RSSI, RSRQ, SNR dan RSRP terukur (nilai aktual pengukuran). Skema model prediksi menerapkan 2 *hidden layer*, dan 1 *output layer*. Output *layer* akan menghasilkan estimasi nilai RSRP sebagai output regresi. Hasil komputasi model dievaluasi dengan menggunakan matrik MAE dan MSE yang merujuk pada evaluasi galat atau deviasi yang dihasilkan oleh model prediksi. Galat pada MAE dalam perbandingan RSRP terukur dengan hasil prediksi menghasilkan besaran 4,1922 dBm, sedangkan pada MSE memiliki nilai galat sebesar 6,64

dBm.

Intepretasi skema evaluasi lainnya, dapat dikomputasi dalam bentuk rerata persentase error melalui evaluasi MAE dengan rerata persentase error menyentuh level 5,13%, sedangkan rerata persentase error MSE berada pada level 0,73%. Rerata persentase error pada metrik evaluasi yang diterapkan memiliki level yang relatif kecil, hal ini menandakan bahwa model yang digunakan dalam penelitian memiliki performa yang baik baik dan dianggap layak untuk digunakan. Selain itu, hasil penelitian juga mendeskripsikan histogram error prediksi RSRP sebagai interpretasi variasi dalam pengujian model prediksi. Visualisasi histogram error menunjukkan dominasi kuantitas error yang muncul terfokus pada rentang nilai ± 5 dBm dengan sebaran error mayoritas berada pada titik referensi 0 dBm. Hal ini mendeskripsikan bahwa model prediksi yang diimplementasikan memiliki performa generalisasi yang baik dan hasil prediksi yang mendekati nilai aktual dari lokasi pengukuran RSRP.

5. REFERENSI

Alazab, M., Abu, R., Castillo, P. A., Abu-salih, B., & Martín, A. (2024). An effective networks intrusion detection approach based on hybrid Harris Hawks and multi-layer perceptron. *Egyptian Informatics Journal*, 25(December 2023), 100423. <https://doi.org/10.1016/j.eij.2023.100423>

Ali, M., Altobi, S., Bevan, G., Wallace, P., Harrison, D., & Ramachandran, K. P. (2019). Engineering Science and Technology , an International Journal Fault diagnosis of a centrifugal pump using MLP-GABP and SVM with CWT. *Engineering Science and Technology, an International Journal*, 22(3), 854–861. <https://doi.org/10.1016/j.jestch.2019.01.005>

Behjati, M., Zulkifley, M. A., Alobaidy, H. A. H., Nordin, R., & Abdullah, N. F. (2022). *Reliable Aerial Mobile Communications with RSRP & RSRQ Prediction Models for the Internet of Drones : A Machine Learning Approach*.

Calasan, M., Radonji, I., & Panti, L. (2024). *Voltage root mean square error calculation for solar cell parameter estimation : A novel g -function approach*. 10(September). <https://doi.org/10.1016/j.heliyon.2024.e37887>

Campos, P., Hernández-solana, Á., & Valdovinos-bardajá, A. (2020). *Analysis of hidden node problem in LTE networks deployed in unlicensed spectrum*. 177(March). <https://doi.org/10.1016/j.comnet.2020.107280>

Chen, K., Weng, Y., Hosseini, A. A., Dening, T.,



- Zuo, G., & Zhang, Y. (2024). A comparative study of GNN and MLP based machine learning for the diagnosis of Alzheimer ' s Disease involving data synthesis. *Neural Networks*, 169(May 2023), 442–452. <https://doi.org/10.1016/j.neunet.2023.10.040>
- Fauzi, M. F. A., Nordin, R., Abdullah, N. F., & Alobaidy, H. A. H. (2022). Mobile Network Coverage Prediction Based on Supervised Machine Learning Algorithms. *IEEE Access*, 10, 55782–55793. <https://doi.org/10.1109/ACCESS.2022.3176619>
- Jos, P., García, E., Men, L. A., Prado, D., & S, A. B. (2024). *Predicting the critical superconducting temperature using the random forest , MLP neural network , M5 model tree and multivariate linear regression*. 86(June 2023), 144–156. <https://doi.org/10.1016/j.aej.2023.11.034>
- Jos, P., García, E., S, B. M. P., & Paredes, S. (2023). *Modelling energy performance of residential dwellings by using the MARS technique , SVM-based approach , MLP neural network and M5 model tree*. 341(April). <https://doi.org/10.1016/j.apenergy.2023.121074>
- Mohammadi, M., Jamshidi, S., Rezvanian, A., & Gheisari, M. (2024). Measurement : Sensors Advanced fusion of MTM-LSTM and MLP models for time series forecasting: An application for forecasting the solar radiation. *Measurement: Sensors*, 33(May), 101179. <https://doi.org/10.1016/j.measen.2024.101179>
- Putra, G. M., Budiman, E., Malewa, Y., Cahyadi, D., Taruk, E., & Hairah, U. (2021). *4G LTE Experience : Reference Signal Received Power , Noise Ratio and Quality*. 139–144.
- Rolich, A., Turcanu, I., Vinel, A., & Baiocchi, A. (2024). Understanding the impact of persistence and propagation on the Age of Information of broadcast traffic in 5G NR-V2X sidelink communications. *Computer Networks*, 248(January), 110503. <https://doi.org/10.1016/j.comnet.2024.110503>
- Shi, Y., Shi, W., Liu, X., & Xiao, X. (2020). *An RSSI Classification and Tracing Algorithm to Improve Trilateration-Based Positioning*. <https://doi.org/https://doi.org/10.3390/s20154244>
- Tarhuni, N., Saadi, I. Al, Asif, H. M., & Mesbah, M. (2023). *Machine-Learning-Based Ground-Level Mobile Network Coverage Prediction Using UAV Measurements*.
- Valdovinos-bardají, A., & Campos, P. (2022). *Detection in Unlicensed LTE Networks*. 208(April 2021). <https://doi.org/10.1016/j.comnet.2022.108862>
- Vipin, V., Trivedi, K., & Koley, S. (2023). Results in Physics Optimization of parameters of the OWC wave energy converter device using MLP and XGBoost models. *Results in Physics*, 55(June), 107163. <https://doi.org/10.1016/j.rinp.2023.107163>
- Wang, M., Feng, Y. T., Guan, S., & Qu, T. (2024). Multi-layer perceptron-based data-driven multiscale modelling of granular materials with a novel Frobenius norm-based internal variable. *Journal of Rock Mechanics and Geotechnical Engineering*, 16(6), 2198–2218. <https://doi.org/10.1016/j.jrmge.2024.02.003>
- Wu, S., Ma, B., Zhang, J., Zheng, S., Shao, W., & Zheng, W. (2021). Intelligent Propagation Model Method for RSRP Prediction Based on Machine Learning. *2021 7th International Conference on Computer and Communications (ICCC)*, 2287–2291. <https://doi.org/10.1109/ICCC54389.2021.9674686>