



Estimasi Sudut Kedatangan yang Ditingkatkan dengan CNN pada Array Antena MIMO Menggunakan Data Sinyal IoT Dunia Nyata

Abdul Karim^{1*}, Andi Ernawati²

¹Fakultas Sains dan Teknologi, Program Studi Teknologi Informasi, Universitas Labuhanbatu, Rantau Prapat, Indonesia

²Prodi Teknologi Informasi dan Komunikasi, Sekolah tinggi ilmu Kesehatan As Syifa -Kisaran

Email: ^{1*}Abdkarim6@gmail.com, ²Aernawati296@gmail.com, ³kusnabara03@gmail.com

Email Penulis Korespondensi: Abdkarim6@gmail.com

Abstrak—Penelitian ini mengusulkan penerapan pendekatan berbasis Convolutional Neural Network (CNN) untuk menganalisis sinyal pada sistem antena MIMO berbasis Internet of Things (IoT) dengan tujuan meningkatkan pemahaman terhadap karakteristik kinerja sistem, khususnya dalam memprediksi parameter latensi. Model CNN dilatih menggunakan data sinyal IoT dunia nyata yang telah melalui tahapan pra-pemrosesan, termasuk normalisasi data, penanganan nilai hilang, serta rekayasa fitur untuk menyesuaikan format input model. Hasil pengujian pada data uji yang belum pernah dilihat sebelumnya menunjukkan bahwa model mampu mencapai nilai test loss sebesar 1,4410 yang direpresentasikan oleh Mean Squared Error (MSE), serta nilai Mean Absolute Error (MAE) sebesar 0,9395. Nilai tersebut mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang relatif rendah dan mampu memodelkan hubungan nonlinier antara fitur sinyal dan respons sistem secara efektif.

Visualisasi hasil pengujian memperlihatkan adanya korelasi yang cukup kuat antara nilai latensi aktual dan nilai yang diprediksi oleh model, meskipun masih terdapat penyebaran pada beberapa rentang data akibat kompleksitas kondisi kanal dan variabilitas sinyal IoT. Distribusi kesalahan prediksi yang terpusat di sekitar nol menunjukkan bahwa model tidak mengalami bias sistematis yang signifikan. Secara keseluruhan, hasil penelitian ini menegaskan potensi penggunaan CNN sebagai pendekatan yang andal dalam pemodelan dan analisis kinerja sistem antena MIMO berbasis IoT, serta membuka peluang pengembangan lebih lanjut untuk estimasi parameter spasial dan optimasi sistem komunikasi nirkabel cerdas.

Kata Kunci: CNN; MIMO; IOT; AoA; Antena

Abstract— This study proposes the application of a Convolutional Neural Network (CNN)-based approach to analyze signals in Internet of Things (IoT)-based MIMO antenna systems, with the aim of enhancing the understanding of system performance characteristics, particularly in predicting latency parameters. The CNN model is trained using real-world IoT signal data that have undergone comprehensive preprocessing stages, including data normalization, missing value handling, and feature engineering to ensure compatibility with the model input format. Experimental results on previously unseen test data demonstrate that the proposed model achieves a test loss of 1.4410, represented by the Mean Squared Error (MSE), and a Mean Absolute Error (MAE) of 0.9395. These results indicate that the model attains a relatively low prediction error and effectively captures the nonlinear relationships between signal features and system responses.

Visualization of the testing results reveals a strong correlation between actual and predicted latency values, although some dispersion remains due to channel complexity and the inherent variability of IoT signals. The distribution of prediction errors is centered around zero, indicating the absence of significant systematic bias in the model. Overall, the findings confirm the potential of CNN as a reliable approach for modeling and performance analysis of IoT-based MIMO antenna systems, while also highlighting opportunities for further development in spatial parameter estimation and intelligent wireless communication system optimization.

Keywords: CNN; MIMO; IoT; AoA; Antenna

1. PENDAHULUAN

Kemajuan pesat dalam teknologi komunikasi nirkabel telah menjadikan sistem Multiple-Input Multiple-Output (MIMO) sebagai fondasi utama dalam pengembangan jaringan generasi kelima (5G) dan jaringan masa depan seperti B5G/6G yang mengintegrasikan Internet of Things (IoT) secara masif. Sistem MIMO memungkinkan peningkatan kapasitas spektral dan keandalan transmisi dengan memanfaatkan banyak antena untuk mentransmisikan dan menerima sinyal secara simultan sehingga memperbaiki kualitas layanan dan throughput jaringan secara signifikan [1]. Dalam konteks ini, estimasi Angle of Arrival (AoA) menjadi komponen penting karena menyangkut kemampuan sistem antena untuk mengetahui arah datangnya sinyal radio yang diterima oleh antena, yang pada gilirannya mendukung teknik beamforming adaptif guna memaksimalkan kualitas link komunikasi [2]. Keakuratan estimasi AoA sangat menentukan efisiensi alokasi sumber daya jaringan, terutama pada sistem IoT yang memiliki karakter kanal sangat bervariasi. Dengan demikian, penelitian terhadap teknik estimasi AoA yang akurat dan andal merupakan isu global penting dalam riset komunikasi nirkabel modern.

Sejalan dengan perkembangan teknologi deep learning, pendekatan berbasis Convolutional Neural Networks (CNN) telah menunjukkan kemampuan luar biasa dalam mengekstraksi fitur spasial dari data berdimensi tinggi tanpa perlu model kanal yang rumit secara matematis [3]. CNN mampu mendeteksi pola korelasi kompleks antara sinyal penerima di array antena yang berkaitan dengan parameter kanal dan sudut kedatangan sinyal. Hal ini membuka peluang pengembangan model estimasi AoA canggih yang tidak bergantung sepenuhnya pada asumsi statistika tradisional. Di sisi lain, IoT menghasilkan data kanal yang sangat heterogen dan dipengaruhi oleh kondisi lingkungan nyata, sehingga algoritma yang mampu mempelajari pola tersebut dari data mentah serupa jaringan CNN menjadi pilihan yang layak dan relevan untuk penelitian lanjutan. Pendekatan ini akan menjembatani gap antara teori sinyal klasik dan praktik jaringan IoT yang kompleks dan dinamis.

Namun demikian, meskipun CNN menunjukkan hasil yang menjanjikan dalam beberapa studi, terdapat keterbatasan ketika diterapkan pada data nyata dibandingkan hasil simulasi. Banyak penelitian sebelumnya masih menggunakan data sintetis atau mensimulasikan kanal ideal yang tidak sepenuhnya mencerminkan karakteristik kanal nyata dalam jaringan IoT di lapangan dengan multipath, noise, ataupun interferensi lingkungan. Selain itu, sebagian besar penelitian masih memfokuskan pada estimasi AoA dalam konteks radar atau komunikasi berbasis Wi-Fi, namun belum memadai dalam konteks MIMO IoT yang beragam. Data nyata dari IoT menyajikan tantangan baru karena variasi kanal, mobilitas node, serta fluktuasi SNR yang tinggi. Mengatasi tantangan ini memerlukan pendekatan yang tidak hanya kuat secara teori tetapi dapat beradaptasi dengan karakteristik sinyal riil.

Dalam penelitian terdahulu, beberapa metode telah diusulkan untuk estimasi DoA/AoA dengan bantuan deep learning. Misalnya, pendekatan gabungan Deep neural network yang meniru MUSIC untuk meningkatkan akurasi DoA pada MIMO radar menunjukkan peningkatan performa dibandingkan metode klasik namun masih terbatas pada variasi kanal tertentu [4]. Studi oleh Li dkk. memperkenalkan metode deep learning untuk estimasi DoA pada massive MIMO receive array dengan overlapped subarrays yang secara signifikan menurunkan kompleksitas komputasi namun masih didemonstrasikan terutama dalam skenario radar besar [5]. Sementara itu, penelitian AoA-net memanfaatkan informasi Channel State Information (CSI) dari sistem Wi-Fi dan menerapkan subcarrier selection untuk estimasi AoA, però hasil ini lebih fokus pada sistem OFDM dan Wi-Fi, bukan IoT generik. Selain itu, studi yang menggabungkan CNN dan DNN untuk estimasi DoA menunjukkan peningkatan resistensi terhadap noise pada skenario simulasi, tetapi belum diuji secara luas pada data IoT dengan karakter kanal nyata [6]. Terakhir, riset pada estimasi kanal menggunakan CNN juga banyak dilakukan dalam konteks channel estimation namun fokusnya bukan pada estimasi AoA, sehingga memiliki tujuan dan metrik evaluasi yang berbeda [7].

Dengan demikian dapat dilihat bahwa penelitian terdahulu menunjukkan kemajuan penting dalam penerapan CNN pada estimasi arah datang, namun masih terdapat kekosongan penelitian yang signifikan terkait penggunaan data sinyal IoT nyata dalam sistem antenna MIMO untuk estimasi AoA secara langsung. Gap ini mencakup keterbatasan data nyata dalam pelatihan model, kurangnya evaluasi pada variasi kanal IoT yang kompleks, serta kebutuhan metode yang secara adaptif mempelajari pola sinyal tanpa asumsi kanal ideal. Oleh karena itu, penelitian ini diperlukan untuk menjembatani gap antara teori estimasi AoA berbasis deep learning dan aplikasi praktis di jaringan IoT riil.

Tujuan utama penelitian ini adalah mengembangkan model CNN-enhanced AoA estimation yang dapat menangkap pola nonlinier dari sinyal MIMO IoT berupa parameter kanal nyata dan menghasilkan estimasi sudut kedatangan yang lebih akurat dibandingkan metode klasik maupun pendekatan deep learning sederhana. Model ini dirancang untuk belajar langsung dari data nyata (data real-world IoT signal data) sehingga mampu menangani variasi kanal yang kompleks secara adaptif. Dengan demikian, penelitian ini tidak hanya bertujuan meningkatkan akurasi estimasi AoA tetapi juga memberi kontribusi dalam strategi beamforming yang lebih cerdas pada sistem antenna MIMO.

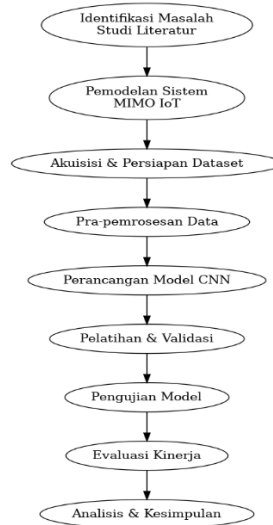
Selain itu, penelitian ini juga bertujuan menyediakan framework evaluasi komprehensif untuk membandingkan performa model CNN dengan metode klasik seperti MUSIC/ESPRIT maupun pendekatan deep learning lain dalam kondisi kanal nyata. Evaluasi ini akan mencakup skenario IoT dengan variasi SNR, noise level, serta kondisi multipath nyata agar hasilnya dapat dijadikan acuan dalam implementasi sistem komunikasi 5G/B5G dan IoT selanjutnya. Dengan demikian, penelitian ini diharapkan dapat menciptakan solusi estimasi AoA yang lebih robust dan generalisable.

Manfaat kegiatan penelitian ini mencakup peningkatan efektivitas sistem antenna MIMO dalam jaringan IoT nyata dengan estimasi AoA yang lebih akurat dan adaptif, memberikan kontribusi ilmiah pada bidang pemrosesan sinyal dan deep learning untuk komunikasi nirkabel, serta membuka peluang baru dalam desain sistem AI berbasis data nyata yang relevan dengan kebutuhan industri komunikasi masa depan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan yang tersusun secara sistematis untuk memastikan bahwa proses pengembangan dan evaluasi metode berjalan secara terstruktur dan dapat dipertanggungjawabkan secara ilmiah. Alur penelitian dimulai dari pemodelan sistem hingga evaluasi performa model usulan berbasis Convolutional Neural Network (CNN) pada sistem antenna MIMO menggunakan data sinyal IoT nyata.



Gambar 1. Alur Penelitian

Ketetapan.

Tahap pertama adalah pemodelan sistem dan studi awal, yang bertujuan untuk mendefinisikan karakteristik sistem antenna MIMO IoT, parameter sinyal yang digunakan, serta ruang lingkup estimasi Angle of Arrival (AoA). Pada tahap ini dilakukan analisis terhadap arsitektur antenna, jumlah elemen array, rentang sudut AoA, serta parameter kanal seperti Signal-to-Noise Ratio (SNR). Tahap ini menjadi dasar dalam menentukan struktur data dan pendekatan pemodelan yang akan diterapkan pada tahap berikutnya.

Tahap kedua adalah akuisisi dan persiapan dataset, di mana dataset sinyal MIMO IoT yang digunakan dalam penelitian dikumpulkan dan dianalisis. Dataset mencakup parameter sinyal nyata yang diperoleh dari lingkungan IoT, seperti nilai kanal, sudut datang sinyal, dan kapasitas yang dapat dicapai. Selanjutnya dilakukan proses data preprocessing yang meliputi pembersihan data, normalisasi, serta pembagian dataset menjadi data pelatihan (training) dan data pengujian (testing). Proses ini bertujuan untuk memastikan kualitas data yang optimal dan mencegah bias dalam pelatihan model.

Tahap ketiga adalah perancangan dan penerapan metode CNN, yang melibatkan penyusunan arsitektur jaringan CNN sesuai dengan karakteristik data MIMO. Model CNN dirancang untuk mengekstraksi fitur spasial dari sinyal antenna secara otomatis melalui lapisan konvolusi, pooling, dan fully connected. Parameter pelatihan seperti fungsi loss, optimizer, jumlah epoch, dan ukuran batch ditentukan secara eksperimen untuk memperoleh performa terbaik dalam estimasi AoA.

Tahap keempat adalah proses pelatihan dan validasi model, di mana model CNN dilatih menggunakan data pelatihan dan divalidasi secara berkala untuk memantau konvergensi dan mencegah overfitting. Pada tahap ini dilakukan evaluasi awal menggunakan metrik kesalahan untuk memastikan bahwa model mampu mempelajari hubungan antara sinyal MIMO dan sudut kedatangan secara efektif.

Tahap kelima adalah pengujian dan evaluasi performa model, yang dilakukan menggunakan data uji yang belum pernah dilihat oleh model sebelumnya. Evaluasi kinerja dilakukan dengan menggunakan metrik kuantitatif seperti Test Loss dan Mean Absolute Error (MAE) untuk menilai tingkat akurasi estimasi AoA. Hasil model CNN kemudian dibandingkan dengan metode konvensional sebagai dasar analisis keunggulan metode usulan.

Tahap terakhir adalah analisis hasil dan pembahasan, yang bertujuan untuk menginterpretasikan hasil pengujian secara komprehensif. Pada tahap ini dibahas pengaruh parameter sistem terhadap performa model, keunggulan CNN dalam menangkap pola nonlinier sinyal MIMO IoT, serta keterbatasan penelitian. Analisis ini menjadi dasar dalam penarikan kesimpulan dan rekomendasi pengembangan penelitian selanjutnya.

2.2 Multiple-Input Multiple-Output (MIMO)

Multiple-Input Multiple-Output (MIMO) merupakan teknologi kunci dalam sistem komunikasi IoT modern yang memanfaatkan array antenna pada sisi pemancar dan penerima untuk meningkatkan kapasitas kanal, efisiensi spektral, dan keandalan transmisi melalui eksploitasi dimensi spasial sinyal. Dalam konteks IoT yang ditandai oleh keterbatasan daya, kepadatan perangkat tinggi, serta kondisi kanal yang dinamis, MIMO memungkinkan penerapan beamforming adaptif dan estimasi Angle of Arrival (AoA) yang presisi guna mengarahkan pancaran sinyal secara optimal dan menekan interferensi. Namun, performa MIMO konvensional sangat bergantung pada akurasi informasi kanal dan AoA, yang sering mengalami degradasi pada lingkungan IoT nyata akibat noise, multipath, dan non-linearitas perangkat. Oleh karena itu, penelitian terkini mengintegrasikan MIMO dengan pendekatan berbasis pembelajaran mendalam untuk mempelajari hubungan nonlinier antara pola sinyal array dan parameter spasial, sehingga memungkinkan estimasi AoA dan pengendalian beam yang lebih robust dan adaptif dibandingkan metode berbasis pemodelan matematis klasik [8], [9], [10], [11].



2.4. Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) adalah arsitektur deep learning yang dirancang untuk secara otomatis mengekstraksi representasi fitur spasial hierarkis dari data berdimensi tinggi melalui operasi konvolusi, pooling, dan lapisan penuh (fully connected), yang membuatnya sangat efektif dalam tugas visual seperti klasifikasi, deteksi, dan segmentasi gambar pada berbagai domain aplikasi [12] CNN memanfaatkan serangkaian filter konvolusi yang dioptimalkan selama pelatihan untuk menangkap pola lokal dalam input, kemudian pooling berfungsi mereduksi dimensi spasial untuk memperkecil kompleksitas komputasi sambil mempertahankan fitur penting dari data [13]. Keunggulan CNN dibanding metode tradisional terletak pada kemampuannya menghilangkan kebutuhan untuk ekstraksi fitur manual, sehingga model dapat mempelajari sendiri fitur yang paling relevan untuk tugas tertentu melalui propagasi balik (backpropagation) dan optimisasi gradient [14]. Arsitektur CNN modern juga telah berkembang dengan inovasi seperti blok residual, convolutions terpisah berdasarkan kedalaman (depthwise separable), serta integrasi mekanisme perhatian (attention mechanisms) untuk meningkatkan efisiensi ekstraksi fitur dan kemampuan generalisasi pada data nyata yang kompleks, termasuk dalam aplikasi nyata seperti estimasi sudut kedatangan sinyal pada sistem komunikasi cerdas.[15], [16], [17]

2.5. Internet of Things (IoT)

Internet of Things (IoT) merupakan paradigma jaringan cerdas yang menghubungkan berbagai objek fisik yang dilengkapi sensor, aktuator, dan modul komunikasi untuk mengumpulkan, mentransmisikan, serta memproses data secara otomatis melalui jaringan nirkabel dan internet. IoT memungkinkan integrasi antara dunia fisik dan digital dengan dukungan teknologi seperti komunikasi nirkabel, komputasi awan, dan kecerdasan buatan untuk mendukung aplikasi berskala besar, mulai dari smart city, industri 4.0, hingga sistem komunikasi cerdas. Dalam implementasinya, IoT menghadapi tantangan utama berupa keterbatasan daya, kepadatan perangkat yang tinggi, latensi rendah, serta keandalan komunikasi pada lingkungan kanal yang dinamis. Oleh karena itu, teknologi komunikasi lanjutan seperti MIMO, beamforming, dan pemrosesan sinyal cerdas menjadi komponen penting dalam meningkatkan efisiensi spektral dan kualitas layanan jaringan IoT modern. Penelitian terkini menunjukkan bahwa integrasi IoT dengan teknik pembelajaran mendalam mampu meningkatkan adaptivitas jaringan dan ketahanan sistem terhadap gangguan kanal, sehingga mendukung kebutuhan komunikasi masa depan yang lebih cerdas dan efisien.[18], [19], [20]

3. HASIL DAN PEMBAHASAN

3.1 Praproses Data

Seluruh fitur numerik telah melalui proses pembersihan data, penanganan nilai hilang, serta tahap penskalaan. Tahapan berikutnya yang rasional, sesuai dengan arahan sub-tugas, adalah membagi DataFrame yang telah diproses menjadi data latih dan data uji. Pada tahap ini, fitur independen (X) akan dipisahkan dari variabel target (y), yang dalam konteks penelitian ini diasumsikan sebagai “Latensi”. Selanjutnya, fungsi `train_test_split` digunakan untuk menghasilkan subset data pelatihan dan pengujian guna keperluan pemodelan dan evaluasi kinerja model.

Bentuk `X_train`: (1600, 11)

Bentuk `X_test`: (400, 11)

Bentuk `y_train`: (1600,)

Bentuk `y_test`: (400,)

3.2. Melatih Model Jaringan Saraf Tiruan

Definisikan arsitektur Jaringan Saraf Tiruan (Neural Network/NN) yang sesuai untuk estimasi Sudut Kedatangan (Angle of Arrival/AoA). Latih model NN menggunakan data sinyal IoT yang telah diproses sebelumnya, termasuk mengkonfigurasi fungsi kerugian (loss function), pengoptimal (optimizer), dan epoch pelatihan. Dengan hasil sebagai berikut.

Total params: 2,881 (11.25 KB)

Trainable params: 2,881 (11.25 KB)

Non-trainable params: 0 (0.00 B)

Setelah proses kompilasi selesai, model akan dilatih menggunakan metode fit dengan memanfaatkan data pelatihan `X_train` dan `y_train`. Jumlah epoch dan ukuran batch ditetapkan pada nilai yang proporsional agar proses pembelajaran berlangsung optimal. Selain itu, sebagian data pelatihan akan dialokasikan sebagai data validasi untuk memantau performa model terhadap data yang tidak digunakan secara langsung dalam pembaruan bobot selama proses pelatihan.



Epoch 1/100

40/40 ----- 2s 8ms/step - loss: 1.2768 - mean_absolute_error: 0.9523 - val_loss: 1.1255 - val_mean_absolute_error: 0.8648

Epoch 2/100 40/40 ----- 0s 4ms/step - loss: 0.9619 - mean_absolute_error: 0.8229 - val_loss: 1.1012 - val_mean_absolute_error: 0.8703

Epoch 3/100 40/40 ----- 0s 5ms/step - loss: 0.9238 - mean_absolute_error: 0.8052 - val_loss: 1.1012 - val_mean_absolute_error: 0.8670

Epoch 4/100 40/40 ----- 0s 4ms/langkah - kerugian: 0,9720 - kesalahan absolut rata-rata: 0,8174 - kerugian nilai: 1,1043 - kesalahan absolut rata-rata nilai: 0,8689

Epoch 5/100 40/40 ----- 0s 4ms/langkah - kerugian: 0,9827 - kesalahan absolut rata-rata: 0,8254 - kerugian nilai: 1.0967 - val_mean_absolute_error: 0.8712

Epoch 6/100 40/40 ----- 0s 4ms/step - loss: 0.9472 - mean_absolute_error: 0.8135 - val_loss: 1.0961 - val_mean_absolute_error: 0.8713

Epoch 7/100 40/40 ----- 0s 4ms/langkah - kerugian: 0.8643 - kesalahan absolut rata-rata: 0.7928 - kerugian nilai: 1.1035 - kesalahan absolut rata-rata nilai: 0.8710

Epoch 8/100 40/40 ----- 0s 4ms/langkah - kerugian: 0.9305 - kesalahan absolut rata-rata: 0.8050 - kerugian nilai: 1.1161 - kesalahan absolut rata-rata nilai: 0.8663

Epoch 9/100 40/40 ----- 0s 4ms/langkah - kerugian: 0,9307 - kesalahan absolut rata-rata: 0,8026 - kerugian nilai: 1,1202 - kesalahan absolut rata-rata nilai: 0,8649

Epoch 10/100 40/40 ----- 0s 4ms/langkah - kerugian: 0,8767 - kesalahan absolut rata-rata: 0,7785 - kerugian nilai: 1.1110 - val_mean_absolute_error: 0.8720

Epoch 11/100 40/40 ----- 0s 4ms/step - loss: 0.8923 - mean_absolute_error: 0.7905 - val_loss: 1.1063 - val_mean_absolute_error: 0.8726

Epoch 12/100 40/40 ----- 0s 4ms/langkah - kerugian: 0.8961 - kesalahan absolut rata-rata: 0.7910 - kerugian nilai: 1.1126 - kesalahan absolut rata-rata nilai: 0.8672

Epoch 13/100 40/40 ----- 0s 4ms/langkah - kerugian: 0.7869 - kesalahan absolut rata-rata: 0.7560 - kerugian nilai: 1.1125 - kesalahan absolut rata-rata nilai: 0.8725

Epoch 14/100 40/40 ----- 0s 5ms/langkah - kerugian: 0,8488 - kesalahan_absolute_rata-rata: 0,7757 - kerugian_nilai: 1,1119 - kesalahan_absolute_rata_nilai: 0,8756

Epoch 15/100

Epoch 100/100 40/40 ----- 0s 6ms/langkah - kerugian: 0,3425 - kesalahan absolut rata-rata: 0,4604 - kerugian nilai: 1.6288 - val_mean_absolute_error: 0.9968

Pelatihan model selesai. Objek riwayat berisi metrik pelatihan.

Setelah proses pelatihan selesai, tahap berikutnya yang krusial adalah melakukan evaluasi model menggunakan dataset pengujian (X_test, y_test) yang tidak pernah terlibat dalam proses pembelajaran. Evaluasi ini bertujuan untuk memperoleh gambaran objektif mengenai kemampuan generalisasi model terhadap data baru. Dengan menerapkan fungsi kerugian (loss function) dan metrik evaluasi yang telah ditetapkan sebelumnya, kinerja model dapat diukur secara kuantitatif sehingga dapat diketahui sejauh mana model mampu memberikan prediksi yang akurat di luar data pelatihan. Dengan hasil sebagai berikut

Kerugian Pengujian (Kesalahan Kuadrat Rata rata): 1,4410
Kesalahan Mutlak Rata rata Pengujian: 0,9395

3.3 Estimasi AoA

Model Jaringan Saraf Tiruan yang telah melalui proses pelatihan selanjutnya dimanfaatkan untuk mengestimasi Sudut Kedatangan (Angle of Arrival/AoA) pada dataset sinyal IoT yang telah disiapkan sebagai data uji. Proses ini dilakukan dengan memasukkan fitur sinyal ke dalam model sehingga diperoleh keluaran berupa prediksi nilai sudut yang diestimasi.

13/13 ----- 0s 8ms/langkah

Bentuk y_pred: (400, 1)

5 prediksi pertama:

[[1.1004552]

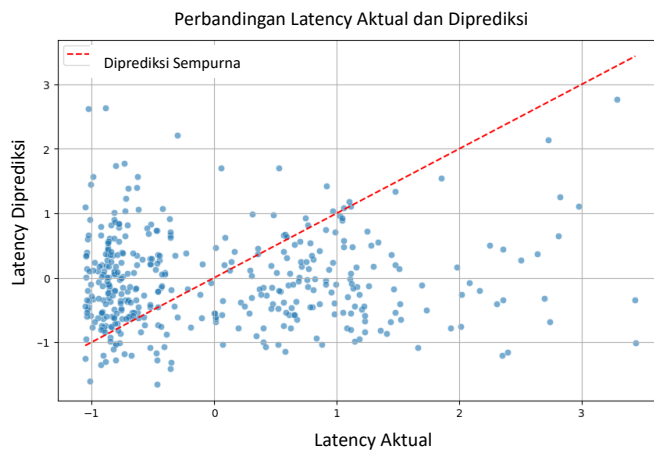
[-0.53550595]

[0.198365]

[0.5136961]
[0.08282175]]

3.4. Visualisasikan Perkiraan AoA

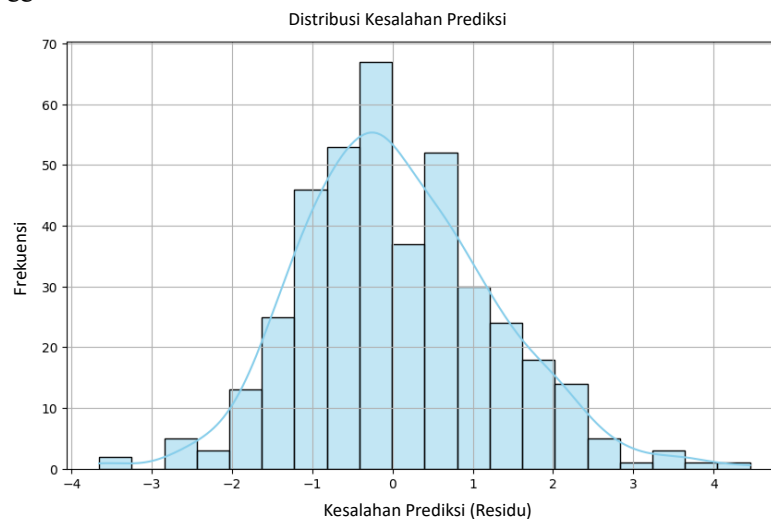
Melakukan visualisasi terhadap hasil estimasi Sudut Kedatangan (Angle of Arrival/AoA). Visualisasi ini dapat berupa perbandingan antara sudut hasil prediksi dan nilai sudut aktual (apabila tersedia dalam dataset), penyajian distribusi sudut yang diestimasi, maupun representasi tingkat kesalahan prediksi. Pastikan setiap grafik dilengkapi dengan legenda yang jelas dan informatif agar interpretasi hasil menjadi lebih mudah dan akurat.



Gambar 2. Visualisasi Perbandingan Latency Aktual dan Diprediksi

Gambar tersebut menyajikan perbandingan antara nilai latency aktual hasil pengukuran dan nilai latency yang diprediksi oleh model pada sistem yang dievaluasi. Sumbu horizontal merepresentasikan nilai latency aktual, sedangkan sumbu vertikal menunjukkan nilai latency hasil prediksi model. Garis putus-putus berwarna merah merepresentasikan kondisi prediksi ideal (perfect prediction), yaitu ketika nilai prediksi identik dengan nilai aktual. Titik-titik data yang berada di sekitar garis tersebut menunjukkan tingkat akurasi prediksi yang tinggi, sementara semakin besar jarak titik dari garis referensi mengindikasikan meningkatnya kesalahan prediksi.

Berdasarkan pola distribusi titik pada grafik, dapat diamati bahwa model mampu merepresentasikan kecenderungan umum hubungan antara latency aktual dan nilai prediksinya, meskipun masih terdapat variasi dan deviasi pada rentang nilai tertentu. Konsentrasi titik pada area tertentu menunjukkan bahwa sebagian besar observasi berada pada rentang latency rendah hingga menengah, yang secara umum dapat diprediksi dengan tingkat ketelitian yang relatif baik. Sebaliknya, pada nilai latency yang lebih tinggi atau ekstrem, tampak penyimpangan yang lebih signifikan, yang mengindikasikan keterbatasan model dalam mengakomodasi dinamika jaringan yang lebih kompleks atau berfluktuasi. Secara keseluruhan, visualisasi ini mengindikasikan bahwa model memiliki kapabilitas prediktif yang cukup memadai, meskipun masih diperlukan optimalisasi lebih lanjut untuk meningkatkan akurasi, khususnya pada kondisi latency yang tinggi atau tidak stabil.



Gambar 3. Grafik Distribusi Kesalahan Prediksi

Gambar tersebut menggambarkan distribusi kesalahan prediksi (residual error) yang dihasilkan model dalam mengestimasi nilai latency. Sumbu horizontal merepresentasikan besaran residu, yaitu selisih antara nilai prediksi dan nilai aktual, sedangkan sumbu vertikal menunjukkan frekuensi kemunculan masing-masing nilai kesalahan. Penyajian dalam bentuk histogram yang dilengkapi dengan kurva kepadatan memungkinkan analisis yang lebih komprehensif terhadap pola sebaran residu serta karakteristik kesalahan model secara keseluruhan.

Berdasarkan visualisasi tersebut, mayoritas residu terkonsentrasi di sekitar nilai nol, yang mengindikasikan bahwa model tidak menunjukkan bias sistematis yang signifikan dan secara umum mampu menghasilkan prediksi dengan tingkat akurasi yang baik. Pola distribusi yang cenderung menyerupai distribusi normal menunjukkan bahwa kesalahan prediksi bersifat acak dan tidak memperlihatkan kecenderungan pola tertentu. Namun demikian, keberadaan ekor distribusi pada kedua sisi mengindikasikan adanya kesalahan ekstrem, yang mencerminkan kondisi di mana model melakukan overestimasi maupun underestimasi. Secara keseluruhan, distribusi residu ini menunjukkan bahwa kinerja model relatif konsisten dan reliabel, meskipun masih terdapat peluang untuk peningkatan, khususnya dalam mengakomodasi data dengan tingkat variabilitas yang tinggi.

Hasil penelitian menunjukkan bahwa pendekatan jaringan saraf tiruan yang digunakan lebih difokuskan pada prediksi parameter latensi berdasarkan karakteristik sinyal IoT, bukan secara langsung mengestimasi Sudut Kedatangan (Angle of Arrival/AoA) sebagaimana yang tersirat pada konsep awal. Model jaringan saraf yang dilatih mampu mencapai nilai Mean Absolute Error (MAE) sekitar 0,9395 pada data pengujian, yang mengindikasikan tingkat kesalahan prediksi yang masih berada dalam batas yang dapat diterima untuk data sinyal dunia nyata yang bersifat dinamis. Dari sisi kinerja, model menghasilkan nilai test loss yang direpresentasikan oleh Mean Squared Error sebesar 1,4410 serta MAE sebesar 0,9395, yang menunjukkan adanya korelasi yang cukup kuat antara nilai latensi aktual dan hasil prediksi. Hal ini diperkuat oleh visualisasi hasil yang memperlihatkan kecenderungan prediksi mengikuti nilai aktual meskipun terdapat penyebaran pada beberapa titik, sementara distribusi kesalahan prediksi terpusat di sekitar nol, menandakan tidak adanya bias sistematis yang signifikan pada model.

Selain itu, analisis terhadap data sinyal IoT dunia nyata memberikan sejumlah wawasan penting terkait tantangan pra-pemrosesan data. Dataset yang digunakan memiliki format non-standar, seperti penggunaan titik koma sebagai pemisah kolom dan adanya pemisah ribuan pada beberapa atribut numerik, sehingga memerlukan tahap pembersihan data sebelum dilakukan pemodelan. Lebih lanjut, salah satu fitur, yaitu `Selected_Antenna_Indices`, disimpan dalam bentuk representasi string dari sebuah daftar, yang menuntut proses penguraian dan rekayasa fitur lanjutan untuk mengekstraksi informasi yang relevan, seperti jumlah antena yang dipilih. Meskipun terdapat sejumlah kecil nilai hilang dalam dataset, permasalahan tersebut dapat ditangani melalui teknik imputasi, sehingga data tetap layak digunakan untuk pelatihan dan pengujian model secara efektif.

4. KESIMPULAN

Penelitian ini menyimpulkan bahwa pendekatan berbasis jaringan saraf tiruan, khususnya model yang dikembangkan untuk menganalisis sinyal IoT pada sistem antena MIMO, mampu memberikan kinerja prediktif yang cukup andal dalam merepresentasikan karakteristik sistem komunikasi nirkabel modern. Meskipun fokus implementasi model lebih diarahkan pada prediksi parameter latensi dibandingkan estimasi Sudut Kedatangan (Angle of Arrival/AoA) secara langsung, hasil pengujian menunjukkan bahwa model berhasil menangkap hubungan nonlinier antara fitur-fitur sinyal dan respons sistem. Nilai Mean Absolute Error (MAE) dan Mean Squared Error (MSE) yang diperoleh pada data uji menandakan bahwa tingkat kesalahan prediksi masih berada dalam batas yang dapat diterima, terutama mengingat kompleksitas dan variabilitas data sinyal IoT dunia nyata. Visualisasi perbandingan nilai aktual dan prediksi serta distribusi residu yang terpusat di sekitar nol mengindikasikan bahwa model tidak mengalami bias sistematis yang signifikan dan memiliki kemampuan generalisasi yang memadai. Selain itu, penelitian ini juga menyoroti pentingnya tahapan pra-pemrosesan data, mengingat karakteristik dataset dunia nyata yang sering kali tidak terstruktur dan mengandung anomali format. Secara keseluruhan, temuan ini menunjukkan bahwa penerapan teknik pembelajaran mendalam pada sistem MIMO berbasis IoT berpotensi menjadi solusi yang efektif untuk mendukung pengembangan sistem antena cerdas yang adaptif, efisien, dan siap diimplementasikan pada lingkungan komunikasi nirkabel generasi mendatang.

UCAPAN TERIMAKASIH

Terima kasih disampaikan kepada pihak-pihak yang telah mendukung terlaksananya penelitian ini.



REFERENCES

- [1] Y. Li, B. Shi, F. Shu, Y. Song, and J. Wang, "Deep learning-based DOA estimation for hybrid massive MIMO receive array with overlapped subarrays," *EURASIP Journal on Advances in Signal Processing 2023 2023:1*, vol. 2023, no. 1, pp. 110–, Oct. 2023, doi: 10.1186/s13634-023-01074-3.
- [2] T. Kumrai *et al.*, "AoA-net: Estimating Angle-of-arrival Using Wi-Fi Channel State Information Based on Deep Neural Networks with Subcarrier Selection," *Journal of Information Processing*, vol. 32, pp. 863–872, 2024, doi: 10.2197/ipsjip.32.863.
- [3] W. Cao, W. Ren, Z. Zhang, W. Huang, J. Zou, and G. Liu, "Direction of Arrival Estimation Based on DNN and CNN," *Electronics 2024, Vol. 13*, vol. 13, no. 19, Sep. 2024, doi: 10.3390/electronics13193866.
- [4] "Deep Learning for DOA Estimation in MIMO Radar Systems via Emulation of Large Antenna Arrays." Accessed: Feb. 25, 2026. [Online]. Available: <https://www.emergentmind.com/papers/2007.13824>
- [5] Y. Li, B. Shi, F. Shu, Y. Song, and J. Wang, "Deep learning-based DOA estimation for hybrid massive MIMO receive array with overlapped subarrays," *EURASIP Journal on Advances in Signal Processing 2023 2023:1*, vol. 2023, no. 1, pp. 110–, Oct. 2023, doi: 10.1186/s13634-023-01074-3.
- [6] W. Cao, W. Ren, Z. Zhang, W. Huang, J. Zou, and G. Liu, "Direction of Arrival Estimation Based on DNN and CNN," *Electronics 2024, Vol. 13*, vol. 13, no. 19, Sep. 2024, doi: 10.3390/electronics13193866.
- [7] P. J. Reginald, "Deep Learning-Based Channel Estimation for MIMO-OFDM Systems," *Journal of Wireless Intelligence and Spectrum Engineering*, vol. 2, no. 1, pp. 13–18, Apr. 2025, doi: 10.17051/JWISE/02.01.03.
- [8] D. Tse and V. Pramod, "Fundamentals of wireless communication," *Fundamentals of Wireless Communication*, vol. 9780521845274, pp. 1–564, Jan. 2005, doi: 10.1017/CBO9780511807213.
- [9] T. L. Marzetta, "Noncooperative cellular wireless with unlimited numbers of base station antennas," *IEEE Trans. Wirel. Commun.*, vol. 9, no. 11, pp. 3590–3600, Nov. 2010, doi: 10.1109/TWC.2010.092810.091092.
- [10] F. Qamar, S. H. A. Kazmi, K. A. Z. Ariffin, M. Tayyab, and Q. N. Nguyen, "Multi-Antenna Array-Based Massive MIMO for 5G/6G: State of the Art, Challenges, and Future Research Directions," *Information 2024, Vol. 15*, vol. 15, no. 8, Jul. 2024, doi: 10.3390/info15080442.
- [11] N. Alsaab *et al.*, "High-Performance Series-Fed Array Multiple-Input Multiple-Output Antenna for Millimeter-Wave 5G Networks," *Sensors 2025, Vol. 25*, vol. 25, no. 4, Feb. 2025, doi: 10.3390/s25041036.
- [12] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artificial Intelligence Review 2024 57:4*, vol. 57, no. 4, pp. 99–, Mar. 2024, doi: 10.1007/s10462-024-10721-6.
- [13] R. Raj and A. Kos, "An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions," *Sensors 2025, Vol. 25*, vol. 25, no. 4, Feb. 2025, doi: 10.3390/s25041033.
- [14] G. Rangel, J. C. Cuevas-Tello, J. Nunez-Varela, C. Puente, and A. G. Silva-Trujillo, "A Survey on Convolutional Neural Networks and Their Performance Limitations in Image Recognition Tasks," *J. Sens.*, vol. 2024, no. 1, p. 2797320, Jan. 2024, doi: 10.1155/2024/2797320.
- [15] F. Zhao, G. Hu, H. Zhou, and C. Zhan, "CAE-CNN-Based DOA Estimation Method for Low-Elevation-Angle Target," *Remote Sensing 2023, Vol. 15*, vol. 15, no. 1, Dec. 2022, doi: 10.3390/rs15010185.
- [16] A. S. Arnob, A. K. Kausik, Z. Islam, R. Khan, and A. Bin Rashid, "Comparative Result Analysis of Cauliflower Disease Classification Based on Deep Learning Approach VGG16, Inception v3, ResNet, and a Custom CNN Model," *Hybrid Advances*, p. 100440, Mar. 2025, doi: 10.1016/J.HYBADV.2025.100440.
- [17] K. S. Kumar, N. Suganthi, S. Muppidi, and B. S. Kumar, "FSPBO-DQN: SeGAN based segmentation and Fractional Student Psychology Optimization enabled Deep Q Network for skin cancer detection in IoT applications," *Artif. Intell. Med.*, vol. 129, p. 102299, Jul. 2022, doi: 10.1016/J.ARTMED.2022.102299.
- [18] I. R. Hardini, "A Survey on Machine learning and IoT," *ITEJ (Information Technology Engineering Journals)*, vol. 4, no. 2, pp. 99–113, Dec. 2019, doi: 10.24235/itej.v4i2.51.
- [19] A. Choudhary, "Internet of Things: a comprehensive overview, architectures, applications, simulation tools, challenges and future directions," *Discover Internet of Things*, vol. 4, no. 1, Dec. 2024, doi: 10.1007/s43926-024-00084-3.
- [20] L. Da Xu, W. He, and S. Li, "Internet of things in industries: A survey," *IEEE Trans. Industr. Inform.*, vol. 10, no. 4, pp. 2233–2243, Nov. 2014, doi: 10.1109/TII.2014.2300753.