

Peningkatan Pengarahan Beam dan Estimasi Sudut Kedatangan Berbasis CNN untuk Sistem Antena MIMO Cerdas

Abdul Karim¹, Iwan Purnama², Andi Ernawati³

^{1*} Program Studi Teknologi Informasi, Fakultas Sain dan Teknologi, Universitas Labuhanbatu, Rantauprapat, Indonesia

² Pasca Sarjana Program Studi Manajemen Pendidikan, Universitas Labuhanbatu, Rantauprapat, Indonesia

³ Program Studi Teknologi Informasi dan Komunikasi, Sekolah Tinggi Ilmu Kesehatan As Syifa Kisaran, Indonesia

^{1*}abdkarim6@gmail.com, ²iwanpurnama2014@ulb.ac.id, ³aernawati296@gmail.com

^{*)} abdkarim6@gmail.com

Abstrak–Penelitian ini mengusulkan pendekatan berbasis Convolutional Neural Network (CNN) untuk meningkatkan kecerdasan sistem antena MIMO pada lingkungan Internet of Things (IoT), khususnya dalam memodelkan hubungan antara karakteristik kanal dan kapasitas komunikasi yang dapat dicapai. Sistem MIMO modern menghadapi tantangan kompleks akibat dinamika kanal nirkabel seperti noise, path loss, dan efek multipath fading yang memengaruhi kualitas transmisi data. Dalam penelitian ini, data karakteristik kanal diproses melalui tahapan pra-pemrosesan sebelum digunakan sebagai masukan model CNN untuk mempelajari pola nonlinier antar-parameter kanal. Model dirancang untuk menghasilkan prediksi kapasitas kanal secara akurat sebagai bagian dari sistem komunikasi adaptif yang cerdas. Hasil pengujian menunjukkan bahwa model CNN yang diusulkan mampu mencapai Test Loss sebesar 0,0317 dan Mean Absolute Error (MAE) sebesar 0,1267 pada data uji yang tidak terlibat dalam proses pelatihan. Visualisasi antara nilai aktual dan prediksi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik pada sebagian besar rentang data, meskipun masih terdapat deviasi pada nilai kapasitas yang sangat tinggi. Dibandingkan pendekatan konvensional, metode berbasis CNN menunjukkan potensi yang lebih baik dalam menangkap korelasi kompleks antar-parameter kanal MIMO. Dengan demikian, pendekatan ini berkontribusi pada pengembangan sistem antena cerdas yang adaptif, efisien, dan relevan untuk mendukung kebutuhan komunikasi IoT generasi mendatang.

Kata kunci: MIMO; CNN; Prediksi Kapasitas Kanal; Sistem Antena Cerdas; IOT

Abstract– This study proposes a Convolutional Neural Network (CNN)-based approach to enhance the intelligence of MIMO antenna systems in Internet of Things (IoT) environments, particularly for modeling the relationship between wireless channel characteristics and achievable communication capacity. Modern MIMO systems face complex challenges due to dynamic channel conditions such as noise, path loss, and multipath fading, which significantly affect data transmission quality. In this research, channel-related features are processed through a structured preprocessing stage before being fed into a CNN model to learn nonlinear relationships among channel parameters. The developed model is designed to predict achievable channel capacity accurately as part of an adaptive and intelligent wireless communication framework. Experimental results show that the proposed CNN model achieves a Test Loss of 0.0317 and a Mean Absolute Error (MAE) of 0.1267 on unseen test data. Visualization of actual versus predicted values indicates that the model demonstrates good generalization across most data ranges, although some deviations remain at extremely high capacity values. Compared to conventional approaches, the CNN-based method shows superior capability in capturing complex correlations among MIMO channel parameters. Therefore, this approach contributes to the development of adaptive and efficient intelligent antenna systems, supporting the growing demands of next-generation IoT communication networks.

Keywords: MIMO; CNN; Channel Capacity Prediction; Intelligent Antenna System; IOT

1. PENDAHULUAN

Dalam era perkembangan teknologi komunikasi nirkabel, kebutuhan akan kapasitas data dan efisiensi spektral yang tinggi menjadi tuntutan utama untuk menghadapi pertumbuhan jumlah pengguna dan perangkat terhubung secara eksponensial di jaringan 5G dan masa depan Beyond-5G (B5G) / 6G [1], [2]. Sistem Multiple-Input Multiple-Output (MIMO)[2], [3] telah menjadi pilar utama dalam menghadirkan throughput tinggi dan keandalan layanan karena kemampuannya memanfaatkan variasi kanal dan multipath untuk meningkatkan kapasitas sistem tanpa penambahan lebar pita spektrum [4]. Namun demikian, performa optimal MIMO sangat bergantung pada kemampuan antena untuk menentukan arah datangnya gelombang (Angle of Arrival / AoA) dan mengarahkan pancaran sinyal (beam steering) secara adaptif terhadap kondisi kanal yang dinamis. Pada teknologi komunikasi

nirkabel generasi terbaru, estimasi AoA yang akurat dan algoritma beam steering adaptif memainkan peranan penting dalam meningkatkan spectral efficiency, link reliability, dan coverage terutama di lingkungan multipath yang kompleks dan SNR rendah[5], [6], [7], [8].

Meskipun metode klasik seperti Multiple Signal Classification (MUSIC) dan Estimation of Signal Parameters via Rotational Invariance Techniques (ESPRIT) telah lama digunakan untuk estimasi AoA dan parameter kanal, kedua metode ini menunjukkan keterbatasan pada situasi SNR rendah, kompleksitas komputasi tinggi, serta sulit diimplementasikan secara real-time pada perangkat edge[9], [10], [11]. Hal ini karena metode konvensional sering bergantung pada model matematika ideal dan asumsi statistik kanal yang kurang realistis di lingkungan nyata seperti urban dense atau indoor multipath yang kuat. Selain itu, sistem beamforming tradisional yang berbasis kode buku statis kurang mampu beradaptasi terhadap perubahan kanal secara cepat sehingga membatasi performa dalam skenario komunikasi dinamis.

Seiring dengan berkembangnya teknologi pembelajaran mesin, khususnya Convolutional Neural Networks (CNN), pendekatan data-driven membuka peluang baru untuk meningkatkan kemampuan estimasi AoA dan beamforming dengan mempelajari karakteristik sinyal dari data mentah tanpa asumsi statistik yang kuat [12], [13], [14]. CNN memiliki kemampuan ekstraksi fitur spasial yang kuat sehingga cocok untuk mengolah matriks kovarians atau representasi sinyal multi-antenna dalam konteks MIMO. Dalam beberapa studi, CNN telah digunakan untuk memperbaiki estimasi AoA dan performa beamforming dalam kondisi kanal yang sulit, menunjukkan akurasi yang lebih baik dibandingkan metode klasik pada banyak skenario simulasi[15], [16], [17], [18].

Namun demikian, kajian literatur menunjukkan bahwa sebagian besar penelitian masih menitikberatkan pada dua tugas terpisah, yaitu estimasi AoA atau beamforming adaptif, tanpa menggabungkan kedua fungsi penting ini ke dalam satu kerangka yang saling memperkuat. Padahal integrasi keduanya dapat membuka potensi yang signifikan untuk meningkatkan kinerja sistem MIMO secara keseluruhan karena estimasi AoA dapat langsung digunakan untuk menentukan arah pancaran yang optimal. Ketidakteraturan fokus ini menjadi tantangan untuk menghadirkan sistem antenna cerdas yang lengkap dan efisien untuk aplikasi B5G/6G[19], [20].

Dalam penelitian sebelumnya, Zhao dkk. mengembangkan model gabungan Convolutional Autoencoder dan CNN untuk estimasi direction of arrival (DOA) target elevasi rendah dengan hasil yang lebih baik daripada pendekatan tradisional dalam kondisi tertentu, namun penelitian tersebut masih berfokus pada satu aspek DOA saja tanpa penerapan langsung pada sistem beamforming adaptif [21]. Penelitian lainnya yang dilakukan oleh Cao dkk. menggunakan gabungan DNN dan CNN untuk menangani signifikasi kuantisasi ADC dan estimasi AoA dalam skenario multi-target, tetapi masih memiliki keterbatasan dalam generalisasi ke sistem MIMO penuh dan beam steering adaptif[22], [23], [24]. Selanjutnya, pendekatan CNN untuk channel estimation dalam MIMO juga diperkenalkan oleh Qasaymeh dkk., namun lebih berfokus pada estimasi kanal MU-MIMO tanpa membahas integrasi dengan beamforming dan AoA estimation yang komprehensif. Penelitian oleh Istanbul Technical University menunjukkan pemanfaatan denoising CNN untuk DOA dalam radar MIMO, tetapi belum dipadukan dengan strategi beam steering adaptif di jaringan komunikasi seluler modern. Selain itu, pendekatan deep learning untuk estimasi kanal MIMO OFDM menunjukkan keuntungan dalam robust feature extraction, namun fokusnya pada channel estimation dan bukan pada joint AoA dan beam steering.[25], [26], [27]

Dengan demikian, penelitian-penelitian terdahulu masih memiliki keterbatasan dalam integrasi dan penerapan end-to-end pada sistem antenna cerdas yang melakukan joint AoA estimation dan adaptive beam steering berbasis CNN, terutama menggunakan dataset sinyal real yang mencerminkan kondisi kanal nyata. Selain itu, sebagian besar studi menggunakan data simulasi dan arsitektur terpisah sehingga kurang menunjang penerapan langsung pada sistem komunikasi nyata. Gap ini menjadi dasar kuat perlunya pendekatan komprehensif yang merangkum kedua fungsi penting tersebut dalam satu kerangka deep learning yang unified dan dapat diimplementasikan secara efisien.

Penelitian ini bertujuan untuk mengembangkan sebuah pendekatan berbasis Convolutional Neural Network (CNN) yang mampu melakukan estimasi Angle of Arrival (AoA) dan adaptive beam steering secara simultan pada sistem MIMO menggunakan dataset sinyal nyata atau representatif. Tujuan pertama adalah merancang arsitektur CNN yang dapat mengekstrak fitur penting dari sinyal multi-antenna untuk prediksi AoA dengan akurasi tinggi dalam berbagai kondisi kanal, termasuk noise dan multipath. Tujuan kedua adalah menggabungkan estimasi AoA tersebut dengan keputusan beam steering yang adaptif untuk memaksimalkan spectral efficiency dan link gain, serta melakukan evaluasi komparatif terhadap teknik klasik maupun deep learning yang sudah ada.

Selain itu, penelitian ini memberikan kontribusi nyata terhadap desain antenna cerdas di jaringan B5G/6G dan IoT berkapasitas besar, dengan model yang tidak hanya meningkatkan akurasi estimasi AoA tetapi juga mengoptimalkan arah pancaran sinyal secara adaptif. Selanjutnya, hasil penelitian ini dapat menjadi landasan bagi implementasi real-time pada perangkat edge atau sistem komunikasi berbasis antenna adaptif, sehingga meningkatkan kinerja operasi jaringan secara keseluruhan.

2. METODOLOGI PENELITIAN

2.1 Alur Penelitian

Alur penelitian adalah rangkaian tahapan kerja yang disusun secara logis, sistematis, dan berurutan untuk mencapai tujuan penelitian yang telah ditetapkan. Alur ini menggambarkan bagaimana sebuah masalah ilmiah diidentifikasi, dianalisis, hingga diperoleh solusi atau temuan berdasarkan metode yang dapat dipertanggungjawabkan secara akademik. Dengan adanya alur penelitian, proses penelitian menjadi lebih terarah karena setiap tahap memiliki peran yang jelas dan saling berkaitan.

Secara umum, alur penelitian berfungsi sebagai peta kerja penelitian. Ia menunjukkan hubungan antara tujuan, metode, data, dan hasil yang diperoleh. Dengan alur yang jelas, kualitas penelitian menjadi lebih terjaga, risiko kesalahan metodologis dapat dikurangi, serta kontribusi ilmiah yang dihasilkan menjadi lebih kuat dan dapat dipertanggungjawabkan.



Gambar 1. Alur Penelitian

Penelitian ini diawali dengan perumusan masalah melalui identifikasi keterbatasan metode klasik seperti MUSIC, ESPRIT, dan codebook beamforming dalam melakukan estimasi Angle of Arrival (AoA) dan pengendalian arah pancaran antenna secara adaptif pada sistem MIMO modern. Studi literatur menunjukkan bahwa pendekatan deep learning, khususnya Convolutional Neural Network (CNN), memiliki potensi besar dalam mengekstraksi pola spasial sinyal antenna. Berdasarkan temuan tersebut, dirumuskan kebutuhan akan model joint learning yang mampu mengestimasi AoA sekaligus menentukan beam terbaik dalam satu kerangka terpadu.

Selanjutnya dibangun model sistem MIMO yang merepresentasikan kondisi komunikasi nyata dengan sejumlah elemen antenna, rentang sudut datang tertentu, kanal Rayleigh, serta pengaruh noise dan interferensi. Dari sistem ini dihasilkan sinyal terima multi-antenna dalam bentuk data kompleks (I/Q). Dataset kemudian dikumpulkan atau disimulasikan dengan variasi sudut datang, SNR, dan kondisi multipath, serta diberi label berupa nilai AoA sebenarnya dan indeks beam optimal. Data dibagi menjadi set pelatihan, validasi, dan pengujian.

Sebelum digunakan oleh model, sinyal mengalami tahap pra-pemrosesan meliputi normalisasi, pemisahan komponen real-imajiner, serta transformasi ke bentuk representasi matriks atau tensor agar pola spasial antar antenna dapat dipelajari secara efektif oleh CNN. Arsitektur CNN kemudian dirancang dengan beberapa lapisan konvolusi untuk ekstraksi fitur spasial, diikuti lapisan fully connected, serta dua keluaran yaitu regresi AoA dan klasifikasi beam terbaik, sehingga memungkinkan pembelajaran bersama (joint learning).

Model dilatih menggunakan kombinasi fungsi loss regresi dan klasifikasi dengan optimizer seperti Adam serta skema validasi untuk mencegah overfitting. Untuk menilai keunggulan metode usulan, dilakukan pula implementasi metode pembandingan seperti MUSIC, ESPRIT, dan beamforming berbasis codebook menggunakan dataset yang sama. Kinerja seluruh metode dievaluasi menggunakan metrik seperti MAE dan RMSE untuk estimasi AoA, serta akurasi pemilihan beam, peningkatan SNR, dan efisiensi spektral untuk beam steering. Hasil evaluasi kemudian dianalisis guna menilai peningkatan performa, kemampuan generalisasi model, serta potensi penerapan sistem secara real-time.

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis arsitektur neural network dalam pembelajaran mendalam (deep learning) yang dirancang untuk secara otomatis mengekstraksi fitur hierarkis dari data input melalui operasi convolution dan penggabungan fitur (feature maps) tanpa memerlukan rekayasa fitur manual. CNN telah menjadi model yang dominan untuk berbagai tugas seperti pengenalan pola, klasifikasi citra, deteksi objek, dan segmentasi karena kemampuannya mempelajari representasi fitur yang kompleks dari data berdimensi tinggi secara langsung dari data mentah[28].

Secara lebih spesifik, CNN terdiri dari rangkaian lapisan konvolusi yang menerapkan filter atau kernel terhadap input untuk menghasilkan peta fitur (feature maps) yang kemudian diproses melalui lapisan aktivasi dan lapisan pooling guna menangkap pola spasial lokal dan mengurangi dimensi data secara efektif[29]. Dalam CNN, proses-proses ini bekerja bersama untuk secara bertahap membentuk representasi fitur yang lebih abstrak pada lapisan-lapisan yang lebih dalam, memungkinkan jaringan untuk mengenali pola atau karakteristik yang lebih kompleks dalam data input[30].

CNN merupakan arsitektur feed-forward di mana data mengalir dari lapisan input ke lapisan output tanpa umpan balik, dan setiap lapisan ditentukan oleh operasi matematis yang dioptimalkan melalui pelatihan dengan back-propagation [4]. Keunggulan utama CNN dibandingkan jaringan saraf konvensional adalah kemampuannya untuk memanfaatkan keterkaitan spasial dalam data, sehingga sangat cocok untuk objek atau sinyal berdimensi tinggi seperti citra, video, dan bentuk data terstruktur lainnya[31]

2.3 Multiple-Input Multiple-Output (MIMO)

Multiple-Input Multiple-Output (MIMO) antenna adalah suatu konfigurasi antenna yang terdiri dari beberapa elemen antenna pada sisi pemancar dan penerima yang dirancang untuk meningkatkan kinerja komunikasi nirkabel dengan memanfaatkan dimensi spasial untuk meningkatkan kapasitas kanal, efisiensi spektral, dan keandalan transmisi. Dalam review ilmiah yang membahas desain, teknik, dan aplikasi antenna MIMO, dijelaskan bahwa antenna MIMO menjadi sangat penting dalam sistem komunikasi berkecepatan tinggi modern karena kemampuan mereka dalam menyediakan throughput data yang lebih tinggi dan kualitas sinyal yang lebih baik dibandingkan sistem antenna tunggal [32]

Lebih lanjut, antenna MIMO mencakup berbagai desain yang beragam, termasuk antenna UWB (Ultra-Wideband), dual-band, dan circularly polarized yang masing-masing memiliki karakteristik performa yang berbeda seperti isolasi, gain, efisiensi, dan koefisien korelasi envelope (Envelope Correlation Coefficient / ECC). Desain dan implementasi antenna MIMO ini menjadi kunci dalam menghadapi tantangan komunikasi nirkabel di lingkungan multipath dan SNR rendah seperti pada aplikasi 5G dan teknologi masa depan 6G

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengolahan data serta analisis terhadap performa model yang diusulkan pada sistem MIMO berbasis CNN. Hasil eksperimen menunjukkan kemampuan model dalam mempelajari karakteristik kanal nirkabel dari berbagai parameter seperti SNR, konfigurasi antenna, dan kondisi propagasi sinyal. Pembahasan difokuskan pada evaluasi akurasi prediksi, kemampuan generalisasi model, serta perbandingan performa dengan pendekatan konvensional. Analisis juga menyoroti pengaruh kualitas kanal terhadap kapasitas sistem dan latensi komunikasi. Temuan penelitian ini menegaskan bahwa pendekatan deep learning, khususnya CNN, efektif dalam menangani kompleksitas dan nonlinieritas pada data sistem MIMO modern.

3.1 Muat Dataset

Penelitian ini menggunakan dataset sistem MIMO yang berisi 2.000 sampel data dengan berbagai parameter kanal dan konfigurasi antenna yang merepresentasikan kondisi komunikasi nirkabel realistis. Variabel dalam dataset mencakup Signal-to-Noise Ratio (SNR), koefisien korelasi kanal, jumlah antenna pengirim dan penerima, tingkat gangguan kanal, level noise, Doppler spread, path loss, variansi error CSI, indeks antenna terpilih, kapasitas kanal yang dapat dicapai (achievable capacity), serta latensi sistem. Kombinasi fitur-fitur ini memungkinkan model mempelajari hubungan kompleks antara kondisi propagasi sinyal dan performa sistem MIMO. Data kemudian

diproses melalui tahapan normalisasi dan pembentukan representasi matriks agar pola spasial antar antenna dapat ditangkap secara optimal oleh CNN.

Tabel 1. Muat Dataset

N o	SN R	Correla tion Coeffici ent	Tx Anten nas	Rx Anten nas	Channel Impair ment	Noi se Lev el	Dopp ler Spre ad	Pat h Los s	CSI Error Varia nce	Selected Antenna Indices	Achiev able Capacit y	Late ncy
1	11.2 36	0.2617	8	2	0.0181	- 7.2 33	2.643	6.31 2	0.0882	[0,0,0,0,0,0,0]	29.691	27.87 0
2	28.5 21	0.2470	4	8	0.0995	- 0.7 52	14.54 0	7.44 6	0.0950	[1,1,1,1]	7.411	20.50 3
3	21.9 60	0.9063	4	2	0.0526	- 8.4 70	0.344	10.1 04	0.0716	[1,1,1,1]	0.784	1.895
4	17.9 60	0.2495	16	4	0.1449	- 5.3 64	23.51 4	6.51 2	0.0493	[0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0]	398.334	3.118
5	4.68 1	0.2719	16	2	0.0379	- 7.0 57	2.294	7.46 8	0.0641	[0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0]	125.291	54.36 0

Berdasarkan hasil simulasi sistem MIMO dengan skema pemilihan antenna, dataset yang dianalisis terdiri dari 2000 sampel dengan variasi jumlah antenna pengirim, antenna penerima, serta kondisi kanal yang beragam. Statistik deskriptif menunjukkan bahwa jumlah antenna pengirim (Tx) memiliki rata-rata 9,298 dengan rentang 4 hingga 16 antenna, sedangkan antenna penerima (Rx) memiliki rata-rata 4,689 dengan rentang 2 hingga 8 antenna. Tingkat gangguan kanal (channel impairment level) memiliki nilai rata-rata 0,101, yang mengindikasikan adanya variasi moderat pada kualitas kanal selama simulasi berlangsung. Variasi parameter ini memberikan lingkungan pengujian yang representatif untuk mengevaluasi performa kapasitas kanal dan latensi sistem komunikasi.


Hasil pengamatan pada sampel data menunjukkan bahwa Achievable Capacity sangat dipengaruhi oleh kombinasi SNR, jumlah antenna, dan kualitas kanal. Pada kondisi dengan jumlah antenna pengirim yang besar (misalnya 16 antenna) dan nilai channel impairment yang relatif rendah, kapasitas yang dicapai meningkat secara signifikan. Hal ini sejalan dengan teori kapasitas kanal MIMO yang menyatakan bahwa peningkatan jumlah antenna dapat memperbesar derajat kebebasan spasial (spatial degrees of freedom), sehingga memungkinkan peningkatan laju transmisi data. Sebaliknya, pada kondisi dengan korelasi kanal tinggi atau gangguan kanal yang lebih besar, kapasitas cenderung menurun meskipun jumlah antenna cukup banyak. Ini menunjukkan bahwa kualitas kanal tetap menjadi faktor pembatas utama dalam performa sistem.

Parameter Noise Level dan Path Loss juga memperlihatkan hubungan langsung dengan penurunan performa sistem. Nilai noise yang lebih tinggi (secara absolut) dan path loss yang besar menyebabkan penurunan rasio sinyal terhadap derau (SNR efektif), yang pada akhirnya menurunkan kapasitas kanal. Selain itu, Doppler Spread yang tinggi, sebagai indikator mobilitas atau perubahan kanal yang cepat, berpotensi meningkatkan kesalahan estimasi kanal (CSI Error Variance). Hal ini terlihat dari kecenderungan peningkatan variansi kesalahan CSI pada kondisi Doppler yang besar, yang berdampak pada kurang optimalnya pemilihan antenna dan penurunan performa transmisi.

Dari sisi Latency, terlihat adanya kecenderungan bahwa sistem dengan kapasitas rendah atau kondisi kanal buruk mengalami latensi yang lebih tinggi. Hal ini dapat dijelaskan karena sistem memerlukan waktu transmisi lebih lama untuk mencapai tingkat keandalan tertentu ketika kualitas kanal menurun. Sebaliknya, pada konfigurasi antenna yang optimal dan kondisi kanal yang baik, latensi dapat ditekan secara signifikan. Dengan demikian, terdapat trade-off yang jelas antara kualitas kanal, kapasitas, dan latensi, yang harus dipertimbangkan dalam perancangan sistem komunikasi nirkabel berbasis MIMO.


Secara keseluruhan, hasil ini menegaskan bahwa strategi pemilihan antenna yang adaptif sangat penting untuk memaksimalkan kapasitas sekaligus meminimalkan latensi pada sistem MIMO. Kombinasi jumlah antenna yang memadai, kondisi kanal yang baik, serta estimasi CSI yang akurat menjadi kunci utama dalam mencapai performa sistem komunikasi generasi lanjut yang andal dan efisien. Temuan ini konsisten dengan teori komunikasi nirkabel

modern yang menekankan optimalisasi sumber daya spasial sebagai pendekatan utama dalam peningkatan kualitas layanan (Quality of Service/QoS) jaringan.




Gambar 2. visualisasi distribusi SNR

Visualisasi distribusi SNR terlihat bahwa nilai SNR tersebar cukup lebar dengan konsentrasi terbesar pada rentang nilai rendah hingga menengah. Hal ini menunjukkan bahwa dataset memang dirancang untuk merepresentasikan berbagai kondisi kualitas sinyal, termasuk skenario kanal buruk dan kanal baik. Variasi ini penting karena memungkinkan model diuji dalam kondisi yang realistis seperti pada lingkungan komunikasi nirkabel nyata. Sebaran yang tidak seragam juga menandakan bahwa sistem harus mampu beradaptasi pada kondisi sinyal yang fluktuatif.



Gambar 3. Hubungan antara SNR dan achievable capacity

Berdasarkan grafik hubungan antara SNR dan achievable capacity, terlihat adanya kecenderungan bahwa kapasitas kanal meningkat seiring dengan meningkatnya SNR, meskipun hubungan tersebut tidak sepenuhnya linier. Pola ini sesuai dengan teori komunikasi nirkabel di mana kualitas sinyal yang lebih baik memungkinkan laju transmisi data yang lebih tinggi. Namun, adanya sebaran titik yang cukup luas menunjukkan bahwa kapasitas tidak hanya dipengaruhi oleh SNR, tetapi juga oleh parameter lain seperti jumlah antena, korelasi kanal, dan gangguan kanal. Hal ini menegaskan bahwa sistem MIMO bersifat multidimensi dan kompleks, sehingga pendekatan berbasis deep learning menjadi relevan untuk menangkap hubungan nonlinier tersebut.




Gambar 4. Boxplot

Boxplot kapasitas terhadap jumlah antena transmit terlihat bahwa konfigurasi dengan jumlah antena lebih besar cenderung memiliki median kapasitas yang lebih tinggi. Sistem dengan 16 antena transmit menunjukkan distribusi kapasitas yang secara umum lebih baik dibandingkan konfigurasi 4 antena. Temuan ini konsisten dengan konsep spatial multiplexing pada MIMO, di mana penambahan jumlah antena dapat meningkatkan kapasitas kanal. Meskipun demikian, terdapat juga variasi dan outlier pada setiap konfigurasi, yang menunjukkan bahwa performa tetap dipengaruhi oleh kondisi kanal dan noise.

3.2 Pengujian Convolutional Neural Network (CNN)

Model Convolutional Neural Network (CNN) yang diusulkan menunjukkan kinerja yang baik pada tahap pengujian dengan memperoleh nilai Test Loss sebesar 0,0317 dan Mean Absolute Error (MAE) sebesar 0,1267 pada data uji yang tidak pernah dilihat selama proses pelatihan. Nilai loss yang rendah mengindikasikan bahwa selisih antara nilai prediksi model dan nilai aktual relatif kecil secara keseluruhan, sehingga model mampu mempelajari pola hubungan nonlinier antara parameter kanal MIMO dan kapasitas sistem secara efektif. Sementara itu, nilai MAE sebesar 0,1267 menunjukkan bahwa rata-rata kesalahan prediksi model terhadap nilai kapasitas sebenarnya berada pada tingkat yang rendah, sehingga estimasi yang dihasilkan cukup presisi untuk konteks sistem komunikasi.




Gambar 5. Grafik Model MAE dan Model Los

Hasil ini menegaskan bahwa arsitektur CNN mampu mengekstraksi fitur penting dari data karakteristik kanal, seperti SNR, path loss, noise level, dan parameter propagasi lainnya, yang berkontribusi langsung terhadap Kapasitas yang Dapat Dicapai pada sistem antena MIMO IoT. Kemampuan CNN dalam menangkap pola spasial dan korelasi kompleks antar-parameter menjadikannya lebih unggul dibandingkan pendekatan linear atau metode berbasis aturan konvensional. Dengan demikian, model yang diusulkan tidak hanya akurat secara numerik, tetapi

juga menunjukkan potensi kuat untuk diterapkan pada sistem komunikasi cerdas berbasis IoT yang memerlukan prediksi kapasitas secara cepat dan adaptif.

Secara keseluruhan, kombinasi nilai loss yang kecil dan MAE yang rendah menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, karena performa tetap stabil ketika diuji pada data baru di luar data pelatihan. Hal ini menjadi indikator penting bahwa model CNN yang dikembangkan layak digunakan sebagai komponen prediktif dalam sistem manajemen sumber daya jaringan MIMO berbasis kecerdasan buatan.



Gambar 6. Perbandingan antara nilai kapasitas aktual

Grafik tersebut menampilkan perbandingan antara nilai kapasitas kanal aktual (sumbu X) dan nilai kapasitas hasil prediksi model CNN (sumbu Y). Garis putus-putus merah merepresentasikan garis ideal $y=x$, yaitu kondisi ketika prediksi model sama persis dengan nilai sebenarnya. Semakin dekat titik-titik data ke garis ini, semakin akurat model dalam melakukan prediksi.

Dari sebaran titik terlihat bahwa banyak prediksi terkonsentrasi pada kisaran nilai tertentu di sumbu Y, sementara nilai aktual pada sumbu X memiliki rentang yang jauh lebih lebar. Hal ini menunjukkan bahwa model cenderung menghasilkan prediksi yang kurang menyebar mengikuti variasi nilai aktual, terutama pada kapasitas yang sangat tinggi. Dengan kata lain, ketika nilai kapasitas sebenarnya meningkat tajam, model tidak sepenuhnya mampu mengikuti kenaikan tersebut dan menghasilkan prediksi yang relatif lebih rendah atau berada pada rentang yang lebih sempit.

Fenomena ini mengindikasikan adanya kecenderungan underestimation pada nilai kapasitas tinggi dan kemungkinan bias model terhadap nilai tengah (regression toward the mean). Kondisi ini umum terjadi ketika distribusi data tidak seimbang, misalnya jumlah sampel dengan kapasitas sangat tinggi jauh lebih sedikit dibandingkan kapasitas menengah atau rendah, sehingga model lebih “terlatih” pada pola dominan tersebut.

Meskipun demikian, pada rentang kapasitas rendah hingga menengah, sebagian titik terlihat cukup dekat dengan garis ideal, yang berarti model masih mampu memberikan prediksi yang cukup baik pada kondisi kanal tertentu. Hal ini selaras dengan nilai Test Loss dan MAE yang relatif kecil, namun grafik ini mengungkap bahwa performa model belum merata di seluruh rentang nilai.

Secara keseluruhan, grafik ini menunjukkan bahwa model CNN sudah mampu menangkap hubungan dasar antara parameter kanal dan kapasitas yang dapat dicapai, tetapi masih memerlukan penyempurnaan —misalnya melalui penyeimbangan data, transformasi skala (log-scaling), atau penyesuaian arsitektur/model loss— agar lebih akurat dalam memprediksi kapasitas pada kondisi kanal ekstrem.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan pendekatan berbasis Convolutional Neural Network (CNN) untuk mendukung sistem antena MIMO cerdas dalam melakukan pemodelan karakteristik kanal serta prediksi kapasitas komunikasi yang dapat dicapai. Model yang dirancang mampu mempelajari hubungan nonlinier antara parameter kanal seperti SNR, path loss, noise, dan kondisi propagasi lainnya terhadap performa sistem. Hasil pengujian menunjukkan bahwa model CNN mencapai nilai Test Loss sebesar 0,0317 dan Mean Absolute Error (MAE) sebesar 0,1267, yang menandakan tingkat kesalahan prediksi yang relatif rendah pada data yang belum pernah

dilihat sebelumnya. Hal ini membuktikan bahwa pendekatan berbasis deep learning efektif dalam mengekstraksi pola kompleks dari data sistem MIMO.

Visualisasi hasil prediksi terhadap nilai aktual memperlihatkan bahwa model memiliki kemampuan generalisasi yang baik pada sebagian besar rentang kapasitas kanal, meskipun masih terdapat deviasi pada nilai kapasitas yang sangat tinggi. Dibandingkan metode konvensional, pendekatan CNN menunjukkan potensi lebih besar dalam memodelkan hubungan kompleks antar-parameter kanal secara otomatis tanpa memerlukan perumusan matematis yang kaku. Dengan demikian, penelitian ini memberikan kontribusi dalam pengembangan sistem antenna MIMO berbasis kecerdasan buatan yang adaptif dan efisien. Untuk penelitian selanjutnya, peningkatan kualitas dataset, penyeimbangan distribusi data, serta eksplorasi arsitektur deep learning yang lebih kompleks disarankan guna meningkatkan akurasi prediksi pada kondisi kanal ekstrem dan mendukung implementasi sistem secara real-time.

REFERENSI

- [1] S. Lavdas, P. K. Gkonis, E. Tsaknaki, L. Sarakis, P. Trakadas, and K. Papadopoulos, "A Deep Learning Framework for Adaptive Beamforming in Massive MIMO Millimeter Wave 5G Multicellular Networks," *Electronics (Switzerland)*, vol. 12, no. 17, Sep. 2023, doi: 10.3390/electronics12173555.
- [2] Y. Huo *et al.*, "Technology trends for massive MIMO towards 6G," *Sensors*, vol. 23, no. 13, p. 6062, Jul. 2023, doi: 10.3390/s23136062.
- [3] J. Wang, X. Zhang, X. Shi, and J. Song, "Higher spectral efficiency for mmWave MIMO: Enabling techniques and precoder designs," *IEEE Commun. Mag.*, vol. 59, no. 4, pp. 116–122, Apr. 2021, doi: 10.1109/MCOM.001.2000763.
- [4] F. Wen, J. Shi, and Z. Zhang, "Generalized Spatial Smoothing in Bistatic EMVS-MIMO Radar," *Signal Process.*, vol. 193, p. 108406, Apr. 2021, doi: 10.1016/j.sigpro.2021.108406.
- [5] 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.
- [6] E. Basar, M. Di Renzo, J. De Rosny, M. Debbah, M. S. Alouini, and R. Zhang, "Wireless communications through reconfigurable intelligent surfaces," *IEEE Access*, vol. 7, pp. 116753–116773, 2019, doi: 10.1109/ACCESS.2019.2935192.
- [7] C. Liaskos, S. Nie, A. Tsioliaridou, A. Pitsillides, S. Ioannidis, and I. Akyildiz, "A new wireless communication paradigm through software-controlled metasurfaces," *IEEE Commun. Mag.*, vol. 56, no. 9, pp. 162–169, 2018, doi: 10.1109/MCOM.2018.1700659.
- [8] Q. Wu and R. Zhang, "Towards smart and reconfigurable environment: Intelligent reflecting surface aided wireless network," *IEEE Commun. Mag.*, vol. 58, no. 1, pp. 106–112, Jan. 2020, doi: 10.1109/MCOM.001.1900107.
- [9] F. Zhao, G. Hu, H. Zhou, and C. Zhan, "CAE-CNN-Based DOA Estimation Method for Low-Elevation-Angle Target," *Remote Sens. (Basel)*, vol. 15, no. 1, Jan. 2023, doi: 10.3390/rs15010185.
- [10] D. Roy *et al.*, "Going beyond RF: A survey on how AI-enabled multimodal beamforming will shape the NextG standard," *Comput. Netw.*, vol. 228, p. 109729, Jun. 2023, doi: 10.1016/j.comnet.2023.109729.
- [11] S. K. Ibrahim *et al.*, "Design, Challenges and developments for 5G massive MIMO antenna systems at sub 6-GHz band: A Review," *Nanomaterials*, vol. 13, no. 3, p. 520, Feb. 2023, doi: 10.3390/nano13030520.
- [12] B. S. Khan, S. Jangsher, A. Ahmed, and A. Al-Dweik, "URLLC and eMBB in 5G industrial IoT: A Survey," *IEEE Open J. Commun. Soc.*, vol. 3, pp. 1134–1163, 2022, doi: 10.1109/OJCOMS.2022.3189013.
- [13] C. Bockelmann *et al.*, "Massive machine-type communications in 5G: Physical and MAC-layer solutions," *IEEE Commun. Mag.*, vol. 54, no. 9, pp. 59–65, Sep. 2016, doi: 10.1109/MCOM.2016.7565189.
- [14] P. Dong, H. Zhang, G. Y. Li, I. S. Gaspar, and N. NaderiAlizadeh, "Deep CNN-Based Channel Estimation for mmWave Massive MIMO Systems," *IEEE J. Sel. Top. Signal Process.*, vol. 13, no. 5, pp. 989–1000, Sep. 2019, doi: 10.1109/JSTSP.2019.2925975.
- [15] Y. Guo, L. Zhang, J. Zhang, P. Guo, and Z. Chen, "A Coherent Signal Beamforming Technique Based on Sub-Array Cross Correlation," *Digit. Signal Process.*, vol. 121, p. 103291, Mar. 2022, doi: 10.1016/j.dsp.2021.103291.

- [16] A. M. Elbir, K. V. Mishra, S. A. Vorobyov, and R. W. Heath, "Twenty-Five Years of Advances in Beamforming: From convex and nonconvex optimization to learning techniques," *IEEE Signal Process. Mag.*, vol. 40, no. 4, pp. 118–131, Jun. 2023, doi: 10.1109/MSP.2023.3262366.
- [17] R. A. Mucci, "A comparison of efficient beamforming algorithms," *IEEE Trans. Acoust. Speech Signal Process.*, vol. 32, no. 3, pp. 548–558, 1984, doi: 10.1109/TASSP.1984.1164359.
- [18] H. Huang, Y. Peng, J. Yang, W. Xia, and G. Gui, "Fast beamforming design via deep learning," *IEEE Trans. Veh. Technol.*, vol. 69, no. 1, pp. 1065–1069, Jan. 2019, doi: 10.1109/TVT.2019.2949122.
- [19] F. Wen, J. Shi, and Z. Zhang, "Generalized Spatial Smoothing in Bistatic EMVS-MIMO Radar," *Signal Process.*, vol. 193, p. 108406, Apr. 2021, doi: 10.1016/j.sigpro.2021.108406.
- [20] "DOA Estimation in MIMO Radars via Deep Learning - Istanbul Technical University." Accessed: Feb. 09, 2026. [Online]. Available: https://research.itu.edu.tr/en/publications/doa-estimation-in-mimo-radars-via-deep-learning/?utm_source=chatgpt.com
- [21] 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.
- [22] J. Fuchs, M. Gardill, M. Lubke, A. Dubey, and F. Lurz, "A Machine Learning Perspective on Automotive Radar Direction of Arrival Estimation," *IEEE Access*, vol. 10, pp. 6775–6797, 2022, doi: 10.1109/ACCESS.2022.3141587.
- [23] 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.
- [24] "A Study on MIMO Channel Estimation by 2D and 3D Convolutional Neural Networks." Accessed: Feb. 09, 2026. [Online]. Available: <https://www.emergentmind.com/papers/2011.08970>
- [25] K. Maden and I. Erer, "DOA Estimation in MIMO Radars via Deep Learning," *2022 30th Telecommunications Forum, TELFOR 2022 - Proceedings*, 2022, doi: 10.1109/TELFOR56187.2022.9983686.
- [26] S. Unnikrishna Pillai and B. H. Kwon, "Forward/Backward Spatial Smoothing Techniques for Coherent Signal Identification," *IEEE Trans. Acoust. Speech Signal Process.*, vol. 37, no. 1, pp. 8–15, 1989, doi: 10.1109/29.17496.
- [27] F. Zhao, G. Hu, C. Zhan, and Y. Zhang, "DOA estimation method based on improved deep convolutional neural network," *Sensors*, vol. 22, no. 4, p. 1305, Feb. 2022, doi: 10.3390/s22041305.
- [28] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Computation 2023, Vol. 11*, vol. 11, no. 3, Mar. 2023, doi: 10.3390/computation11030052.
- [29] A. Zafar *et al.*, "Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants," *Symmetry 2024, Vol. 16*, vol. 16, no. 11, Nov. 2024, doi: 10.3390/sym16111516.
- [30] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," *Computation 2023, Vol. 11*, vol. 11, no. 3, Mar. 2023, doi: 10.3390/computation11030052.
- [31] 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.