

Analisis Prediksi Hotspot Berbasis Convolutional Neural Network (CNN) Untuk Virtual Small Cell (VSC)

Raga Ersya Sabila
Telkom University Purwokerto
Fakultas Elektro dan Telekomunikasi
Purwokerto, Indonesia
ragaersa@student.telkomuniversity.ac.id

Achmad Rizal Danisya, S.T.,M.T
Telkom University Purwokerto
Fakultas Elektro dan Telekomunikasi
Purwokerto, Indonesia
achmadd@telkomuniversity.ac.id

Mas Aly Afandi, S.ST., M. T
Telkom University Purwokerto
Fakultas Elektro dan Telekomunikasi
Purwokerto, Indonesia
alyafandi@telkomuniversity.ac.id

Abstrak — Pengelolaan trafik pada area dengan kepadatan pengguna tinggi menjadi salah satu tantangan dalam jaringan 5G. Salah satu pendekatan yang digunakan untuk mengatasi hal ini adalah penerapan *Virtual Small Cell* (VSC), yang memungkinkan pembentukan cell virtual secara dinamis tanpa infrastruktur fisik tambahan. Dalam penelitian ini, VSC dikombinasikan dengan teknik beamforming untuk mengarahkan sinyal ke area-area potensial (*hotspot*) secara lebih efisien. Kanal adaptif diterapkan guna menyesuaikan parameter transmisi terhadap kondisi kanal yang berubah secara real-time. Untuk memaksimalkan efektivitas strategi ini digunakan metode prediksi pergerakan pengguna berdasarkan data heatmap jaringan. *Convolutional Neural Network* (CNN) dipilih karena kemampuannya dalam mengekstraksi pola spasial dan temporal dari data trafik, sehingga mampu memetakan dan memprediksi distribusi pengguna secara akurat. Hasil eksperimen menunjukkan bahwa model CNN-GRU yang dilatih hingga 500 epoch mampu menghasilkan prediksi SINR, RSSI, dan efisiensi bandwidth dengan deviasi kecil terhadap data aktual. Rata-rata selisih masing-masing parameter adalah 3,6 dB untuk SINR, 0,16 dBm untuk RSSI, dan 1,08 bps/Hz untuk efisiensi bandwidth. Temuan ini menunjukkan bahwa CNN dapat digunakan secara efektif dalam sistem prediksi kanal untuk mendukung penerapan beamforming adaptif pada VSC.

Kata kunci— Virtual Small Cell, Hotspot Prediction, 5G, Beamforming, Convolutional Neural Network (CNN)

I. PENDAHULUAN

Perkembangan jaringan 5G meningkatkan kecepatan transfer data dan kapasitas jaringan untuk memenuhi kebutuhan pengguna yang tinggi, namun juga menghadirkan tantangan kompleks, terutama dalam manajemen lalu lintas di area padat atau hotspot. Virtual Small Cell (VSC) menjadi solusi dengan membentuk cell virtual adaptif sehingga kapasitas dapat dialokasikan dinamis sesuai kebutuhan[1].

Beamforming mendukung efisiensi VSC dengan mengarahkan sinyal presisi ke perangkat di hotspot, meningkatkan kualitas sinyal, dan mengurangi interferensi[2]. Pengelompokan kanal berdasarkan karakteristiknya memungkinkan beam diarahkan lebih tepat, sehingga efisiensi spektrum meningkat dan konsumsi energi berkurang[3].

Kanal adaptif memberikan fleksibilitas penyesuaian frekuensi dan daya secara otomatis untuk merespons perubahan kondisi lingkungan, mengurangi interferensi, dan meningkatkan kualitas sinyal. Prediksi karakteristik kanal menjadi penting, dan Convolutional Neural Network (CNN) efektif untuk tugas ini karena kemampuannya mengidentifikasi pola spasial dan temporal pada data kanal[3].

Penelitian ini mengembangkan model VSC dengan beamforming, clustering kanal, dan prediksi UE berbasis CNN untuk meningkatkan throughput, menurunkan latensi, pada jaringan 5G di area hotspot.

II. KAJIAN TEORI

A. Kajian Pustaka

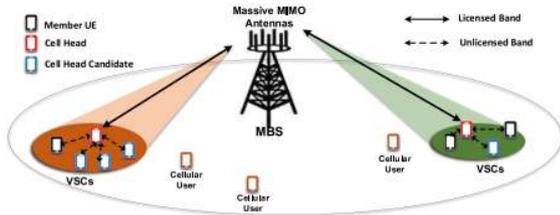
Berbagai studi terkait menunjukkan potensi metode pembelajaran mesin untuk mendukung efisiensi VSC pada jaringan 5G. Penelitian pertama menggunakan LSTM untuk prediksi hotspot guna mendukung beamforming adaptif, namun belum mengeksplorasi keunggulan CNN dalam ekstraksi fitur spasial[1]. Studi kedua menerapkan Graph Convolution Network (GCN) untuk pengolahan data spasial, tetapi tidak mengintegrasikan CNN dalam prediksi atau clustering kanal hotspot[4]. Penelitian ketiga mengusulkan Reinforcement Convolutional Transfer Learning (RC-TL) untuk prediksi lintasan pengguna, namun belum diarahkan pada prediksi kanal hotspot VSC berskala spasial-temporal kecil[5]. Studi keempat membuktikan kemampuan CNN memodelkan data spasial-temporal pada data iklim, namun belum diaplikasikan di jaringan VSC[6]. Selain itu, pendekatan hibrid CNN terbukti meningkatkan akurasi klasifikasi data hiperspektral, tetapi belum dioptimalkan untuk prediksi hotspot VSC dengan teknik clustering[7].

B. Virtual Small Cell

Virtual Small Cell (VSC) pada jaringan 5G memungkinkan pembentukan cell virtual secara dinamis di area dengan permintaan tinggi atau hotspot tanpa infrastruktur fisik tambahan, sehingga kapasitas jaringan dapat difokuskan pada area dengan kebutuhan data besar untuk mengoptimalkan pengalaman pengguna dan mengurangi biaya operasional. Dengan memanfaatkan perangkat pengguna sebagai node tambahan untuk mendistribusikan sinyal, VSC mengurangi kebutuhan

infrastruktur, meningkatkan efisiensi operasional, dan memungkinkan penyesuaian kapasitas jaringan secara fleksibel sesuai kebutuhan tanpa perubahan signifikan pada konfigurasi jaringan[1].

$$SINR_{(dB)} = \frac{P_{i,j} \cdot G_{i,j}}{N_0 + \sum_{k \neq i} P_{k,j} \cdot G_{k,j}} \quad (1)$$



GAMBAR 1
ARSITEKTUR VIRTUAL SMALL CELL [1]

Gambar 1 menunjukkan arsitektur *Virtual Small Cell* (VSC) pada jaringan seluler yang memanfaatkan Massive MIMO serta spektrum berlisensi dan tidak berlisensi. *Macro Base Station* (MBS) dengan antena *Massive MIMO* melayani berbagai perangkat pengguna (UE), sementara VSC dibentuk secara virtual melalui kelompok UE yang dikoordinasikan oleh satu perangkat sebagai *Cell Head* (merah) untuk mengelola komunikasi lokal dan menjadi perantara dengan MBS. Terdapat pula *Cell Head Candidate* (biru) sebagai calon pengganti jika diperlukan, sedangkan anggota UE lainnya ditandai dengan warna hitam.

C. *Beamforming*

Beamforming adalah teknik pemrosesan sinyal dalam komunikasi nirkabel yang mengarahkan gelombang radio ke penerima tertentu untuk memperkuat sinyal dan mengurangi interferensi, dengan memfokuskan pancaran (“beam”) sesuai lokasi perangkat penerima[2]. Pada jaringan 5G, terutama di frekuensi gelombang milimeter, *beamforming* meningkatkan kualitas sinyal, jangkauan, dan kapasitas jaringan dengan mengatur fase dan amplitudo sinyal dari setiap elemen antena array sehingga terjadi interferensi konstruktif di arah target dan destruktif di arah lain, sesuai persamaan dasar *beamforming*[9].

$$y(t) = \sum_{n=1}^N \omega_n \cdot xn(t) \quad (2)$$

D. *K-Means Clustering*

K-Means Clustering adalah salah satu algoritma *unsupervised learning* paling populer dalam ilmu data dan pembelajaran mesin yang digunakan untuk membagi sekumpulan data ke dalam sejumlah kelompok (kluster) berdasarkan kemiripan antar data. Konsep dasar dari *K-Means* adalah mencari titik-titik pusat kluster (*centroid*) sedemikian rupa sehingga jarak rata-rata antar anggota kluster ke pusatnya diminimalkan[14].

$$J = \sum_{i=1}^K \sum_{j \in c_i} ||x_j - \mu_i|| \quad (3)$$

ujuan optimasi adalah mencari pembagian kluster dan posisi *centroid* μ_i sedemikian rupa sehingga nilai fungsi x_j minimum.

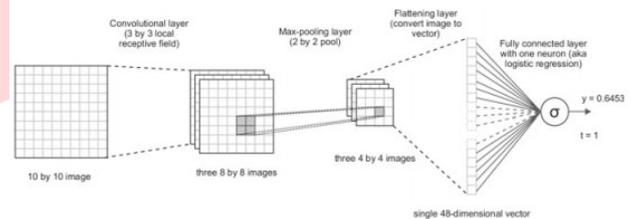
E. *Deep learning*

Deep learning merupakan cabang dari machine learning yang berfokus pada penggunaan jaringan neural

yang mendalam (*deep neural networks*) untuk mengekstrak pola kompleks dari data melalui lapisan-lapisan pemrosesan yang hierarkis. Metode ini telah membuktikan efektivitasnya dalam berbagai aplikasi, seperti pengenalan gambar, pengenalan suara, pemrosesan bahasa alami, dan lain-lain, karena kemampuannya untuk menghasilkan model dengan akurasi yang tinggi pada data yang beragam dan kompleks[15].

F. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah jenis *deep neural network* yang dirancang untuk memproses data visual dan spasial dengan memanfaatkan lapisan konvolusi untuk menangkap fitur lokal seperti tepi, tekstur, dan objek[18]. Arsitekturnya umumnya terdiri dari lapisan konvolusi untuk ekstraksi fitur, pooling untuk reduksi dimensi dan beban komputasi, serta fully connected di bagian akhir untuk menghasilkan klasifikasi atau prediksi[19].

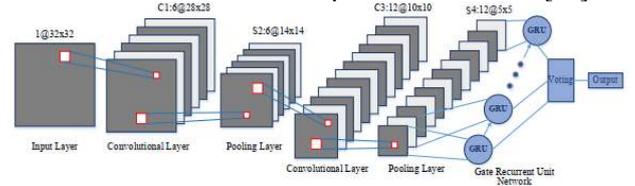


GAMBAR 2
ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK [19]

Gambar tersebut menunjukkan arsitektur dasar dari jaringan saraf konvolusional atau *Convolutional Neural Network* (CNN) yang digunakan untuk pengenalan pola pada data gambar. Proses dimulai dari sebuah citra input berukuran 10×10 piksel, yang kemudian diproses melalui lapisan konvolusi. Pada lapisan ini, diterapkan tiga buah filter berukuran 3×3 untuk mengekstraksi fitur lokal dari gambar, menghasilkan tiga citra fitur (*feature maps*) berukuran 8×8. Setelah itu, hasilnya diproses oleh lapisan max-pooling dengan ukuran 2×2, yang berfungsi untuk mereduksi dimensi spasial dengan tetap mempertahankan fitur yang paling menonjol. Output dari pooling layer ini berupa tiga gambar berukuran 4×4 piksel [19].

G. *Gated Recurrent Unit*

Gated Recurrent Unit (GRU) adalah varian RNN yang mengatasi masalah vanishing gradient pada data sekuensial dengan struktur lebih sederhana dari LSTM namun tetap mampu mempertahankan informasi jangka panjang. Model hybrid CNN-GRU menggabungkan keunggulan CNN dalam ekstraksi fitur spasial dan GRU dalam menangkap hubungan temporal, di mana CNN bertindak sebagai ekstraktor fitur awal dan GRU memproses urutan fitur untuk memodelkan dinamika temporal secara efektif [22].



GAMBAR 3
ARSITEKTUR HYBRID CNN-GRU [22]

Gambar tersebut memperlihatkan arsitektur hybrid CNN-GRU untuk memproses data spasial sekaligus

menangkap hubungan temporal. Input berupa citra grayscale 32×32 diproses oleh lapisan konvolusi pertama (C1, 6 filter) menghasilkan enam feature map 28×28 , kemudian diperkecil oleh pooling pertama (S2) menjadi 14×14 . Lapisan konvolusi kedua (C3, 12 filter) menghasilkan feature map 10×10 yang kembali diperkecil oleh pooling kedua (S4) menjadi 5×5 . Setiap peta fitur ini kemudian diubah menjadi rangkaian fitur dan diumpungkan ke GRU untuk memproses informasi sekuensial secara efisien dengan mempertahankan informasi relevan dan mengabaikan yang tidak penting.

H. Probability Density Function

Probability Density Function (PDF) adalah fungsi matematika yang menggambarkan kemungkinan relatif dari suatu variabel acak kontinu mengambil nilai tertentu dalam suatu rentang. Tidak seperti variabel diskrit yang menggunakan *Probability Mass Function* (PMF), PDF digunakan untuk variabel kontinu di mana probabilitas untuk satu nilai spesifik adalah nol, dan probabilitas didefinisikan sebagai area di bawah kurva PDF dalam rentang tertentu [24].

$$f_x(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (4)$$

I. Cumulative Distribution Function

Cumulative Distribution Function (CDF), atau dalam bahasa Indonesia disebut Fungsi Distribusi Kumulatif, adalah suatu fungsi matematika yang menggambarkan probabilitas kumulatif dari sebuah variabel acak. Artinya, CDF memberikan nilai probabilitas bahwa suatu variabel acak XX akan memiliki nilai yang kurang dari atau sama dengan suatu angka tertentu x . Secara matematis, CDF didefinisikan sebagai [25]:

$$F_x(x) = P(\leq x) \quad (5)$$

fungsi ini berlaku baik untuk variabel acak kontinu maupun diskrit, meskipun bentuk dan sifat matematisnya berbeda tergantung jenis variabelnya. CDF merepresentasikan akumulasi probabilitas dari kiri ke kanan sepanjang garis bilangan real. Jika kita mengamati grafik CDF, maka pada nilai xx yang sangat kecil (mendekati minus tak hingga), nilainya akan mendekati nol karena hampir tidak ada kemungkinan bahwa XX lebih kecil dari nilai tersebut [25].

J. Signal Interference Noise Ratio

Signal-to-Interference-plus-Noise Ratio (SINR) adalah metrik yang digunakan dalam sistem komunikasi nirkabel untuk mengukur kualitas sinyal yang diterima. SINR menunjukkan perbandingan antara kekuatan sinyal yang diinginkan dengan jumlah gangguan (interference) dari sinyal lain serta derau (noise) dari lingkungan atau perangkat keras [26].

$$SINR = \frac{p_s}{\sum_{i=1}^N p_i + N_0} \quad (6)$$

Fungsi ini digunakan untuk mengukur kualitas penerimaan sinyal dalam suatu sistem komunikasi nirkabel, di mana semakin tinggi nilai SINR, semakin baik kualitas sinyal yang diterima, dan semakin kecil kemungkinan terjadinya kesalahan transmisi data.

K. Received Signal Strength Indicator

Received Signal Strength Indicator (RSSI) adalah ukuran kekuatan sinyal radio yang diterima oleh suatu perangkat penerima, biasanya dinyatakan dalam satuan

desibel-milliwatts (dBm). RSSI tidak mengukur kualitas sinyal secara keseluruhan, tetapi hanya mengukur kuantitas energi sinyal yang diterima, sehingga sering digunakan sebagai indikator kekuatan konektivitas dalam sistem komunikasi nirkabel seperti Wi-Fi, ZigBee, Bluetooth, atau jaringan seluler [27].

$$RSSI(d) = Pt + Gt + Gr - 10\log_{10}(d) - L \quad (7)$$

Persamaan ini menggambarkan bahwa semakin jauh jarak penerima dari pemancar, maka RSSI akan semakin kecil (lebih negatif).

L. Bandwidth Efficiency

Bandwidth Efficiency atau *spectral efficiency* adalah ukuran efisiensi penggunaan spektrum frekuensi dalam sistem komunikasi digital. *Bandwidth efficiency* menunjukkan jumlah data (bit) yang bisa dikirim per detik dalam satu satuan bandwidth (Hz), umumnya dinyatakan dalam satuan bps/Hz (bits per second per Hertz). Semakin tinggi efisiensi bandwidth, maka semakin banyak data yang dapat dikirim melalui kanal komunikasi dengan lebar pita tertentu, tanpa memperbesar alokasi spektrum frekuensi [28].

$$n = \frac{R_b}{B} \quad (8)$$

Secara konsep, nilai n menggambarkan kemampuan suatu sistem komunikasi memanfaatkan lebar pita yang tersedia.

III. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk memprediksi dan melakukan clustering kanal hotspot dalam jaringan virtual small cell menggunakan Convolutional Neural Network (CNN). Pendekatan ini bertujuan untuk mengidentifikasi area hotspot pada kanal jaringan berdasarkan pola penggunaan spektrum dan perilaku pengguna, sehingga dapat meningkatkan efisiensi alokasi kanal pada area padat pengguna.

A. Alat Yang Digunakan

Penelitian ini menggunakan perangkat keras (hardware) dan perangkat lunak (software) yang mendukung pengolahan data dan implementasi *Convolutional Neural Network* (CNN) untuk melakukan clustering pada kanal hotspot di *Virtual Small Cell* (VSC).

TABEL 1
PERANGKAT KERAS YANG DIGUNAKAN UNTUK MELAKUKAN PENELITIAN

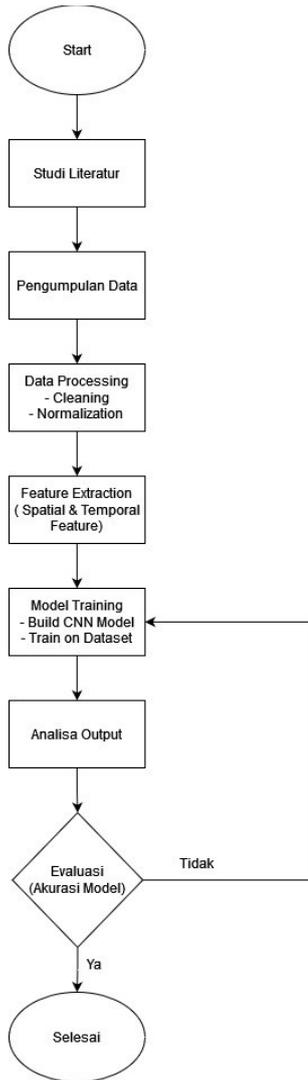
Perangkat	Lenovo Ideapad 330-14AST
Processor	AMD A4-9125 RADEON R3, 4 COMPUTE CORES 2C+2G 2.30 GHz
RAM	8 GB
OS	Windows 10 Home Single Language
System Type	64-bit operating system, x64-based processor

Model simulasi yang dirancang dan diimplementasikan dalam penelitian ini menggunakan program *Python* untuk membuat arsitektur CNN-nya dan *software* MATLAB R2023b. Digunakan untuk mensimulasikan hasil penelitian serta uji coba data penelitian. Adapun *Python* untuk pengolahan dataset dan pengembangan model yang akan digunakan dalam penelitian.

B. Alur Penelitian

Penelitian ini mencakup berbagai langkah-langkah yang perlu dilakukan untuk mencapai hasil yang

diharapkan. Berikut adalah tahapan yang dilakukan, disertai dengan flowchart berikut berikut.

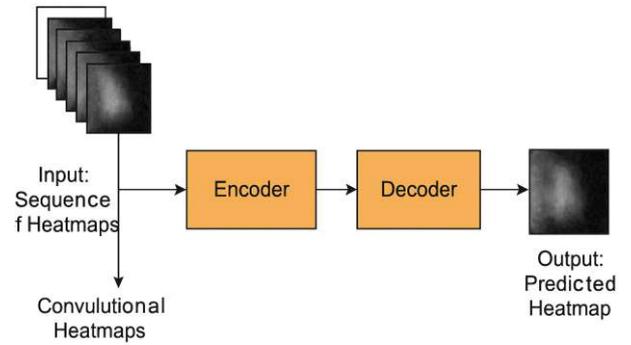


GAMBAR 4 (FLOWCHART ALUR PENELITIAN)

Flowchart pada Gambar 4 menggambarkan alur penelitian yang dimulai dari persiapan data dan perangkat penelitian, pengambilan serta pemuatan dataset penggunaan kanal komunikasi small cell, dilanjutkan dengan pembersihan data dan normalisasi fitur. Selanjutnya dilakukan ekstraksi fitur spasial dan temporal untuk analisis hotspot, lalu dibangun dan dilatih model CNN guna mengenali pola penggunaan kanal. Hasil ekstraksi CNN digunakan untuk proses clustering hotspot virtual dengan metode seperti K-means, dan tahap akhir adalah evaluasi hasil clustering untuk mengukur akurasi dan kesesuaian dengan tujuan penelitian.

C. Arsitektur Model

Berikut adalah diagram model untuk algoritma prediksi hotspot menggunakan CNN-GRU.



GAMBAR 5 (DIAGRAM MODEL CNN-GRU)

Diagram menunjukkan arsitektur CNN untuk memprediksi gambar heatmap berikutnya dari urutan heatmap grayscale sebelumnya. Model terdiri dari encoder dengan lapisan konvolusi, BatchNorm, ReLU, dan dua pooling untuk mengekstraksi fitur spasial penting sambil mengurangi dimensi, serta decoder yang menggunakan konvolusi dan upsampling untuk mengembalikan ukuran gambar. Fungsi aktivasi sigmoid di akhir menghasilkan satu heatmap dengan nilai piksel 0–1 sebagai prediksi frame selanjutnya, yang dapat diulang secara autoregresif untuk memproyeksikan beberapa frame ke depan.

D. Simulasi Beamforming

Dalam rangka mengevaluasi dampak prediksi distribusi pengguna terhadap efektivitas pengelolaan jaringan, penelitian ini melakukan simulasi beamforming sebagai tahap lanjutan setelah proses prediksi hotspot menggunakan model CNN-GRU, berikut topologi beamforming pada penelitian ini.

TABEL 2 PARAMETER INPUT

Tipe Antena	Planar Array 16x16
Koordinat Base Station (BS)	1175, 1175 (Di tengah)
Tinggi BS (heightBS)	35 Meter
Radius Maksimal Cluster	300 Meter
Tinggi UE (hUE)	1,5 meter
Frekuensi Carrier	3,6 GHz
Noise Figure	7 dB

TABEL 3 PARAMETER INPUT

SINR(dB)	Rasio sinyal terhadap interferensi dan noise
RSSI(dBm)	Kuat sinyal yang diterima oleh UE
BANDWIDTH EFFECIENCY(bps/Hz)	Efisiensi spektrum yang didapat tiap UE

IV. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan mensimulasikan sistem jaringan seluler yang mengimplementasikan Virtual Small Cell (VSC) dalam area perkotaan padat. Trafik pengguna pada area ini sangat dinamis dan menunjukkan pola spasial tertentu tergantung waktu. Dataset yang digunakan berupa peta distribusi trafik (traffic heatmap) yang menunjukkan tingkat kepadatan pengguna (User Equipment/UE) di area 2D berukuran 100x100 satuan, dibagi menjadi 10x10 grid. Setiap grid menyimpan informasi jumlah UE aktif pada satu waktu tertentu. CNN digunakan untuk mempelajari pola distribusi trafik pada data historis dan memprediksi kondisi trafik di masa mendatang. Prediksi ini menjadi dasar pengambilan keputusan sistem jaringan untuk menyalakan atau mematikan VSC secara otomatis di lokasi-lokasi yang diprediksi sebagai hotspot. Proses simulasi dan evaluasi dilakukan untuk membandingkan performa prediksi dengan kondisi aktual, serta mengukur efektivitas penerapan CNN dalam mendukung manajemen jaringan berbasis VSC.

A. Hasil Percobaan

Pada bagian ini dibahas hasil dari serangkaian percobaan yang dilakukan untuk mengevaluasi performa model prediksi hotspot berbasis arsitektur CNN-GRU. Model dilatih menggunakan dataset heatmap distribusi pengguna jaringan dalam grid berukuran 10x10 yang disiapkan dalam bentuk sekuens time-series. Tujuan utama dari eksperimen ini adalah untuk melihat kemampuan model dalam memprediksi pola sebaran pengguna di masa depan, yang menjadi dasar dalam pengambilan keputusan penempatan *Virtual Small Cell* (VSC) secara dinamis.

B. Hasil dan Analisis SINR

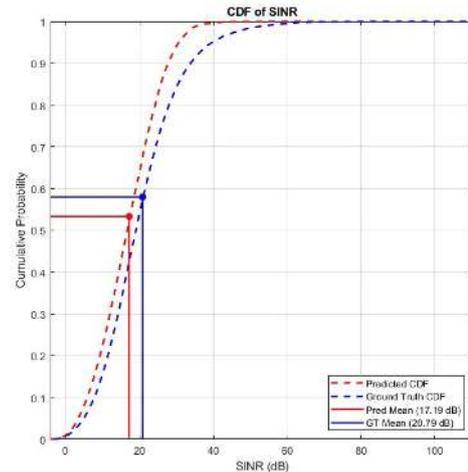
Dalam pengukuran ini, nilai SINR dianalisis per jam dengan menghitung rata-rata nilai SINR dari seluruh titik pengguna yang tercover oleh arah beam. Selisih antara nilai rata-rata SINR hasil prediksi dan ground truth digunakan sebagai indikator.

TABEL 4
TABEL NILAI MEAN SINR PREDIKSI DAN GROUND TRUTH

Jam	Mean SINR Prediksi (dB)	Mean SINR Ground Truth (dB)	Selisih (dB)
1	18.14	20.13	1.99
2	17.59	20.26	2.67
3	17.97	20.61	2.64
4	17.37	21.45	4.08
5	17.18	21.26	4.08
6	17.77	20.98	3.21
7	17.55	20.80	3.25
8	16.23	20.72	4.49
9	17.57	21.34	3.77
10	17.44	20.96	3.52
11	16.81	21.48	4.67
12	16.63	21.46	4.83
13	16.56	21.12	4.56
14	16.09	19.58	3.49
15	17.91	20.39	2.48
16	16.70	19.96	3.26
17	16.47	20.36	3.89
18	16.55	20.71	4.16

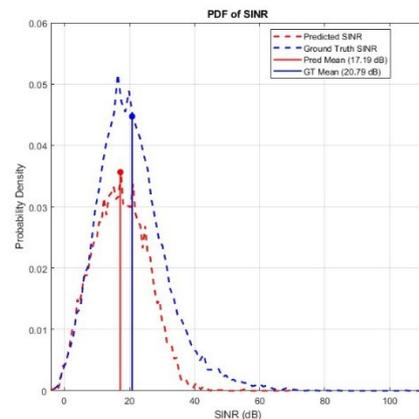
19	16.86	20.90	4.04
20	18.24	21.13	2.89
21	17.32	20.93	3.61
22	17.52	21.64	4.12
23	17.23	20.57	3.34
24	16.90	20.25	3.35

Selisih Minimum terjadi pada Jam ke-1, **20.13 - 18.14 = 1.99 dB** dan Selisih Maksimum terjadi pada Jam ke-12, **21.46 - 16.63 = 4.83 dB**.



GAMBAR 5
GRAFIK CDF SINR 24 JAM

Grafik CDF menunjukkan kurva prediksi dengan kemiringan lebih rendah dibanding ground truth, mengindikasikan kecenderungan model menghasilkan SINR lebih rendah. Hal ini sejalan dengan rata-rata prediksi 17,19 dB yang lebih kecil dari ground truth 20,79 dB.



GAMBAR 6
GRAFIK PDF SINR 24 JAM

Grafik PDF memperlihatkan distribusi probabilitas SINR, di mana prediksi memiliki puncak lebih lebar dan condong ke kiri dibanding ground truth, menandakan prediksi lebih menyebar dan kurang optimal. Meski bentuk distribusinya serupa, terdapat selisih rata-rata 3,6 dB (GT: 20,79 dB; Prediksi: 17,19 dB) yang menunjukkan gap performa cukup signifikan.

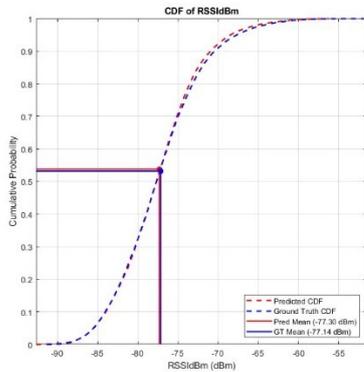
C. Hasil dan Analisis RSSI

Dalam pengukuran ini, nilai RSSI dianalisis per jam dengan menghitung rata-rata nilai RSSI dari seluruh titik pengguna yang tercover oleh arah beam. Selisih antara nilai rata-rata RSSI hasil prediksi dan ground truth digunakan sebagai indikator.

TABEL 5
TABEL NILAI MEAN RSSI PREDIKSI DAN GROUND TRUTH

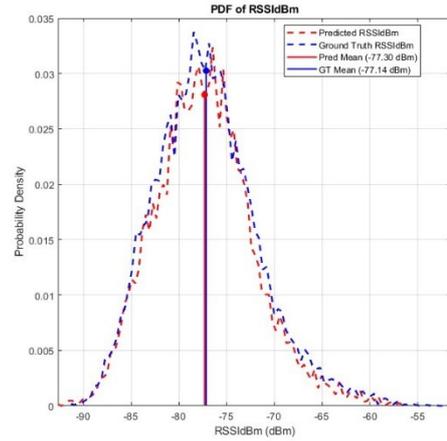
Jam	Mean RSSI Prediksi (dBm)	Mean RSSI Ground Truth (dBm)	Selisih (dBm)
1	-77.20	-77.05	0.15
2	-77.31	-77.33	0.02
3	-77.27	-77.55	0.28
4	-76.93	-76.99	0.06
5	-77.54	-76.74	0.80
6	-77.02	-77.50	0.48
7	-76.99	-76.90	0.09
8	-77.21	-77.35	0.14
9	-77.41	-77.18	0.23
10	-77.44	-77.03	0.41
11	-77.13	-77.10	0.03
12	-77.64	-76.68	0.96
13	-77.41	-76.80	0.61
14	-77.63	-76.98	0.65
15	-77.33	-77.08	0.25
16	-77.46	-77.66	0.20
17	-77.33	-77.27	0.06
18	-77.24	-77.53	0.29
19	-77.19	-77.31	0.12
20	-77.13	-77.22	0.09
21	-77.49	-77.08	0.41
22	-77.40	-76.68	0.72
23	-77.13	-77.12	0.01
24	-77.49	-77.16	0.33

Selisih Minimum: **0.01 dBm** (Jam ke-23) dan Selisih Maksimum: **0.96 dBm** (Jam ke-12), Secara keseluruhan, perbedaan nilai RSSI antara prediksi dan ground truth bersifat kecil, menunjukkan bahwa model cukup handal dalam memetakan kekuatan sinyal.



GAMBAR 7
GRAFIK CDF RSSI 24 JAM

Grafik CDF RSSI menunjukkan kurva prediksi dan ground truth yang hampir seluruhnya tumpang tindih, dengan rata-rata masing-masing $-77,30$ dBm dan $-77,14$ dBm (selisih $0,16$ dBm), menandakan tingkat ketepatan prediksi yang sangat tinggi tanpa pergeseran signifikan pada distribusi.



GAMBAR 8
GRAFIK PDF RSSI 24 JAM

Grafik PDF RSSI menunjukkan distribusi prediksi dan ground truth yang hampir identik berbentuk normal simetris dengan puncak sekitar -77 dBm. Prediksi sedikit lebih lebar namun perbedaannya minim, menandakan model mampu merepresentasikan penyebaran nilai RSSI secara akurat tanpa bias signifikan.

D. Hasil dan Analisis Bandwidth Efficiency

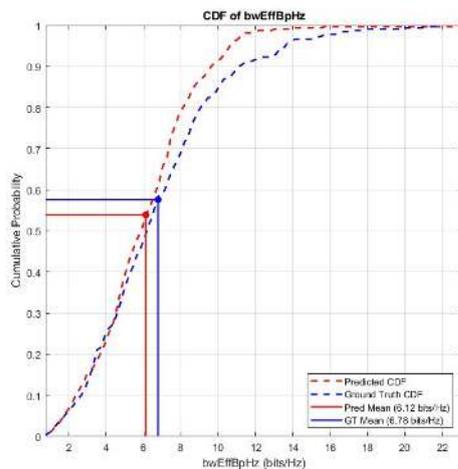
Dalam pengukuran ini, nilai *Bandwidth Efficiency* dianalisis per jam dengan menghitung rata-rata nilai *Bandwidth Efficiency* dari seluruh titik pengguna yang tercover oleh arah beam. Selisih antara nilai rata-rata *Bandwidth Efficiency* hasil prediksi dan ground truth digunakan sebagai indikator.

TABEL 6
TABEL NILAI MEAN BANDWIDTH EFFICIENCY PREDIKSI DAN GROUND TRUTH

Jam	Mean Bandwidth Efficiency Prediksi (bps/Hz)	Mean Bandwidth Efficiency Ground Truth (bps/Hz)	Selisih (bps/Hz)
1	6.12	6.78	0.66
2	5.94	6.80	0.86
3	6.07	6.94	0.87
4	5.87	7.18	1.31
5	5.81	7.13	1.32
6	6.00	7.04	1.04
7	5.93	6.99	1.06
8	5.52	6.95	1.43
9	5.94	7.16	1.22
10	5.89	7.03	1.14
11	5.71	7.20	1.49
12	5.63	7.19	1.56
13	5.62	7.08	1.46
14	5.46	6.61	1.15
15	6.05	6.85	0.80
16	5.65	6.71	1.06
17	5.59	6.83	1.24
18	5.61	6.95	1.34
19	5.72	7.00	1.28
20	6.14	7.08	0.94
21	5.85	7.02	1.17
22	5.92	7.24	1.32
23	5.83	6.94	1.11

24	5.72	6.80	1.08
----	------	------	------

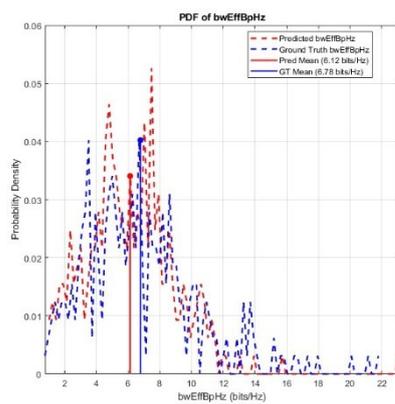
Selisih Minimum: **0.66 bps/Hz** (Jam ke-1) dan Selisih Maksimum: **1.56 bps/Hz** (Jam ke-12).



GAMBAR 9

GRAFIK CDF BANDWIDTH EFFICIENCY 24 JAM

Grafik CDF menunjukkan kurva prediksi berada di kiri kurva ground truth, menandakan kecenderungan model memprediksi efisiensi bandwidth lebih rendah. Rata-rata prediksi 6,12 bps/Hz lebih kecil 0,66 bps/Hz dari ground truth 6,78 bps/Hz, dan median prediksi juga tercatat lebih rendah.



GAMBAR 10

GRAFIK PDF BANDWIDTH EFFICIENCY 24 JAM

Grafik PDF menunjukkan distribusi prediksi lebih sempit dan tinggi dengan puncak sekitar 6,2 bps/Hz, sedangkan ground truth lebih lebar dengan puncak 6,8 bps/Hz. Hal ini menandakan model mengunderestimate efisiensi bandwidth dan kurang merepresentasikan variasi kondisi jaringan meski tren umum distribusi tetap tertangkap.

V. KESIMPULAN

Penelitian ini mengusulkan dan mengevaluasi sistem prediksi pola sebaran hotspot pengguna dalam jaringan seluler menggunakan pendekatan deep learning berbasis CNN-GRU, dengan tujuan mendukung alokasi beamforming adaptif pada skenario Virtual Small Cell (VSC). Dataset berupa data spasial pengguna yang dipetakan ke dalam grid 10×10 digunakan sebagai input untuk memodelkan distribusi trafik dalam horizon waktu ke depan.

Evaluasi beamforming dilakukan dengan cara membandingkan hasil SINR, RSSI, dan efisiensi bandwidth (Bandwidth Efficiency) dari arah beam hasil prediksi terhadap arah beam dari ground truth. Hasil analisis CDF dan PDF menunjukkan bahwa model prediksi mampu mempertahankan pola distribusi sinyal yang menyerupai data aktual, terutama dalam aspek spasial. Namun, terdapat kecenderungan sistematis model untuk melakukan underestimation terhadap nilai SINR dan efisiensi spektrum, dengan selisih rata-rata SINR sekitar 3.6 dB dan efisiensi bandwidth sekitar 1.16 bps/Hz dari ground truth.

Distribusi RSSI menunjukkan hasil yang lebih stabil, dengan selisih rata-rata hanya 0.16 dBm selama 24 jam. Ini menunjukkan bahwa prediksi arah beam tetap menjangkau area dominan dengan intensitas sinyal yang cukup baik. Secara keseluruhan, sistem prediksi berbasis CNN-GRU menunjukkan performa yang menjanjikan dalam mendukung beamforming adaptif, dengan akurasi spasial tinggi dan toleransi nilai sinyal yang masih dalam batas wajar.

REFERENSI

- [1] Y. Liu, X. Wang, G. Boudreau, A. Bin Sediq, and H. Abou-Zeid, "Deep Learning Based Hotspot Prediction and Beam Management for Adaptive Virtual Small Cell in 5G Networks," *IEEE Trans Emerg Top Comput Intell*, vol. 4, pp. 83–94, Feb. 2020, doi: 10.1109/TETCI.2019.2926769.
- [2] A. Ö. Kaya and H. Viswanathan, "Deep learning-based predictive beam management for 5G mmWave systems," in *IEEE Wireless Communications and Networking Conference, WCNC*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/WCNC49053.2021.9417452.
- [3] Ieee, "Secure MSC Coverage zone NC Cooperative user MSC Coverage zone LTE Fronthaul Coverage zone MRN NR Coverage zone MSC Coverage zone LTE SC MCN BBU pool BBU pool BBU pool."
- [4] E. Zhang, T. Harada, and R. Thawonmas, "Using Graph Convolution Network for Predicting Performance of Automatically Generated Convolution Neural Networks," 2019.
- [5] A. R. Taufiqurrahman and I. Palupi, "Forest Fire Hotspot Prediction Model Using GAF CNN-LSTM."
- [6] F. Kurniawan, S. Sulaiman, S. Konate, and M. A. A. Abdalla, "Deep learning approaches for MIMO time-series analysis," *International Journal of Advances in Intelligent Informatics*, vol. 9, no. 2, pp. 286–300, Jul. 2023, doi: 10.26555/ijain.v9i2.1092.
- [7] Y. Li, Q. Xu, W. Li, and J. Nie, "Automatic Clustering-Based Two-Branch CNN for Hyperspectral Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 59, no. 9, pp. 7803–7816, Sep. 2021, doi: 10.1109/TGRS.2020.3038425.
- [8] J. Li *et al.*, "Cluster-Based 3-D Channel Modeling for Massive MIMO in Subway Station Environment," *IEEE Access*, vol. 6, pp. 6257–6272, 2018, doi: 10.1109/ACCESS.2017.2779119.

- [9] H. Al Kassir, Z. D. Zaharis, P. I. Lazaridis, N. V. Kantartzis, T. V. Yioultsis, and T. D. Xenos, "A Review of the State of the Art and Future Challenges of Deep Learning-Based Beamforming," 2022, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/ACCESS.2022.3195299.
- [10] 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. 2020, doi: 10.1109/TVT.2019.2949122.
- [11] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," 2019, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/ACCESS.2019.2912200.
- [12] H. El-Amir and M. Hamdy, *Deep Learning Pipeline*. Apress, 2020. doi: 10.1007/978-1-4842-5349-6.
- [13] J. Li, B. Ai, R. He, M. Yang, Z. Zhong, and Y. Hao, "A cluster-based channel model for massive MIMO communications in indoor hotspot scenarios," *IEEE Trans Wirel Commun*, vol. 18, no. 8, pp. 3856–3870, Aug. 2019, doi: 10.1109/TWC.2019.2919026.
- [14] Venkateswararao, K., Swain, P., Christophorou, C., & Pitsillides, A. (2019). Dynamic selection of Virtual Small Base Station in 5G Ultra-Dense Network using Initializing Matching Connection Algorithm. *2019 IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS)*, 1-6. <https://doi.org/10.1109/ANTS47819.2019.9118045>.
- [15] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning", doi: 10.1007/s12525-021-00475-2/Published.
- [16] A. Paszke *et al.*, "PyTorch: An Imperative Style, High-Performance Deep Learning Library," Dec. 2019, [Online]. Available: <http://arxiv.org/abs/1912.01703>
- [17] N. Ketkar, "Introduction to PyTorch," in *Deep Learning with Python*, Apress, 2017, pp. 195–208. doi: 10.1007/978-1-4842-2766-4_12.
- [18] S. Skansi, "Convolutional Neural Networks," 2018, pp. 121–133. doi: 10.1007/978-3-319-73004-2_6.
- [19] B. Leibe and D. Stutz, "Understanding Convolutional Neural Networks," 2014.
- [20] X. Zhu, Z. Cui, T. Zhang, Y. Li, and J. Yang, "Going Deeper in Frequency Convolutional Neural Network: A Theoretical Perspective," Aug. 2021, [Online]. Available: <http://arxiv.org/abs/2108.05690>
- [21] A. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A survey of the recent architectures of deep convolutional neural networks," *Artif Intell Rev*, vol. 53, no. 8, pp. 5455–5516, Dec. 2020, doi: 10.1007/s10462-020-09825-6.
- [22] V. Nguyen, J. Cai, and J. Chu, "Hybrid CNN-GRU model for high efficient handwritten digit recognition," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Aug. 2019, pp. 66–71. doi: 10.1145/3357254.3357276.
- [23] D. Liang, J. Zhang, S. Jiang, X. Zhang, J. Wu, and Q. Sun, "Mobile Traffic Prediction Based on Densely Connected CNN for Cellular Networks in Highway Scenarios."
- [24] , A., Basotia, V., & Kumar, R. (2024). Analysis on Probability Mass Function and Probability Density Function. *Irish Interdisciplinary Journal of Science & Research*. <https://doi.org/10.46759/ijrsr.2024.8102>.
- [25] Weng, C., & Zhuang, S. (2014). CDF formulation for solving an optimal reinsurance problem. *Scandinavian Actuarial Journal*, 2017, 395 - 418. <https://doi.org/10.1080/03461238.2016.1167114>.
- [26] Hamdi, K. (2009). On the statistics of signal-to-interference plus noise ratio in wireless communications. *IEEE Transactions on Communications*, 57. <https://doi.org/10.1109/TCOMM.2009.11.060425>.
- [27] Mohsin, H., Kadhim, K., & Khudhier, Z. (2019). Study and performance analysis of received signal strength indicator (RSSI) in wireless communication systems.
- [28] Shah, A., & Shaikh, A. (2011). Transmission bandwidth efficiency enhancement techniques. .